

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TİROİT
HASTALIĞININ TEŞHİSİ**

YÜKSEK LİSANS TEZİ

Abdulbaki YILDIZ

**Enstitü Anabilim Dalı : ELEKTRİK - ELEKTRONİK
MÜHENDİSLİĞİ**
Tez Danışmanı : Doç. Dr. Yavuz SARI

Haziran 2019

T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

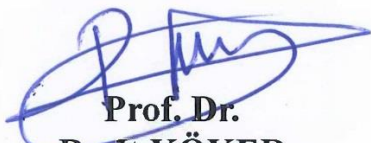
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TİROİT
HASTALIĞININ TEŞHİSİ


YÜKSEK LİSANS TEZİ


Abdulkaki YILDIZ

Enstitü Anabilim Dalı : ELEKTRİK - ELEKTRONİK
MÜHENDİSLİĞİ

Bu tez 13 / 06 / 2019 tarihinde aşağıdaki jüri tarafından
oybirliği/oyçokluğu ile kabul edilmiştir.


Prof. Dr.
Raşit KÖKER
Jüri Başkanı


Doç. Dr.
Yavuz SARI
Üye


Doç. Dr.
Devrim AKGÜN
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Abdülbaki YILDIZ

13.06.2019

TEŐEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Yavuz SARI'ya teşekkürlerimi sunarım.

Ayrıca eğitim hayatım boyunca maddi ve manevi her türlü desteği bana sağlayan aileme teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vii
ÖZET.....	viii
SUMMARY	ix

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

KAYNAK ARAŞTIRMASI

2.1. Yapay Zekâ	4
2.1.1. Uzman sistemler.....	5
2.1.2. Yapay sinir ağları	5
2.1.2.1. Tarihçe.....	6
2.1.2.2. Kronolojik tarihçe	7
2.1.2.3. Biyolojik sinir ağları	9
2.1.2.4. Yapay sinir hücresi.....	12
2.1.2.5. Tek katmanlı algılayıcılar	17
2.1.2.6. Adaline ağı	17
2.1.2.7. Madaline ağı.....	19
2.1.2.8. Çok katmanlı algılayıcı (ÇKA).....	19
2.1.3. Genetik algoritmalar	25
2.1.4. Bulanık önermeler.....	25
2.1.5. Zeki etmenler	26
2.2. Knn.....	27

BÖLÜM 3.

TİROİT HASTALIĞI.....	29
3.1. Tiroit Bezi Tanımı ve İşlevi	29
3.2. Tiroit Bezi Hastalıkları.....	30
3.2.1. Guatr.....	30

3.2.2. Nodül.....	30
3.2.3. Tiroidit	30
3.2.4. Hipertiroidi.....	30
3.2.5. Hipotiroidi.....	30
3.3. Hipertiroidi Belirtileri	31
3.4. Hipotiroidi Belirtileri	31
3.5. Tiroit Tanısı.....	32
3.5.1. Kan testleri	32
3.5.2. Tiroit ultrasonografisi.....	32
3.5.3. Tiroit sintigrafisi	32
3.5.4. Tiroit ince iğne aspirasyon biyopsisi	32
3.6. Tiroit Tedavisi.....	33

BÖLÜM 4.

ARAŞTIRMA BULGULARI.....	34
4.1. 1. Grup Tiroit Verilerinin Özellikleri.....	34
4.1.1. 1. grup tiroit verilerinin Weka’da ÇKA ile sınıflandırılması.....	35
4.1.2. 1. grup tiroit verilerinin Weka’da Knn ile sınıflandırılması	43
4.1.3. 1. grup tiroit verilerinin Matlab’da Ysa Toolbox’ı ile sınıflandırılması	43
4.2. 2. Grup Tiroit Verilerinin Özellikleri.....	50
4.2.1. 2. grup tiroit verilerinin Weka’da ÇKA Ağı ile sınıflandırılması.....	50
4.2.2. 2. grup tiroit verilerinin Weka’da Knn ile sınıflandırılması	53
4.2.3. 2. grup tiroit verilerinin Matlab’da Ysa Toolbox’ı ile sınıflandırılması	54

BÖLÜM 5.

TARTIŞMA VE SONUÇ.....	58
-------------------------------	-----------

KAYNAKLAR	60
------------------------	-----------

ÖZGEÇMİŞ.....	62
----------------------	-----------

SİMGELER VE KISALTMALAR LİSTESİ

ADALINE	: Adaptif Linear Element
BFG	: BFGS quasi-Newton backpropagation
CGB	: Conjugate gradient backpropagation with Powell-Beale restarts
CGF	: Conjugate gradient backpropagation with Fletcher-Reeves updates
CGP	: Conjugate gradient backpropagation with Polak-Ribière updates
ÇKA	: Çok Katmanlı Algılayıcı
Knn	: K nearest neighbord
LM	: Levenberg-Marquardt backpropagation
MADALINE	: Many Adaptif Linear Element
MAPE	: Mean Absolute Percentage Error
MSE	: Mean Squared Error
OSS	: One-step secant backpropagation
RP	: Resilient backpropagation
SCG	: Scaled conjugate gradient backpropagation
TBG	: Tiroksin Bağlayıcı Globulin
TSH	: Tiroit Stimulan Hormon
T3	: Triiyodotironin
T4	: Tiroksin
YSA	: Yapay Sinir Ağı

TABLolar LİSTESİ

Tablo 2.1. Toplama fonksiyonu örnekleri.....	14
Tablo 2.2. Aktivasyon fonksiyonu örnekleri.	15
Tablo 2.3. XOR problemi giriş ve çıkışlarını gösteren doğruluk tablosu.	20
Tablo 4.1. 1.grup tiroit verileri için tiroit hastalığı tanısında incelenen özellikler ve değer aralıkları.	34
Tablo 4.2. 1.Grup verilerinde incelenen özelliklere ait normal kabul edilen değer aralıkları.....	35
Tablo 4.3. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.....	37
Tablo 4.4. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.....	37
Tablo 4.5. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.....	37
Tablo 4.6. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.....	37
Tablo 4.7. k-en yakın komşu algoritması uygulama sonuçları.	43
Tablo 4.8. Matlab uygulamasında kullanılan 1.Grup tiroit verilerinde eğitim ve test setine ait veri sayıları.	43
Tablo 4.9. Eğitim fonksiyonu performanslarının karşılaştırılması.	44
Tablo 4.10. Ağ tiplerinin performanslarının karşılaştırılması.....	46
Tablo 4.11. Transfer fonksiyonlarının performanslarının karşılaştırılması.	47
Tablo 4.12. Gizli katman nöron sayılarının karşılaştırılması.....	48
Tablo 4.13. 2.grup tiroit verileri için tiroit hastalığı tanısında incelenen değerler.....	50
Tablo 4.14. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.....	52
Tablo 4.15. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.....	52
Tablo 4.16. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.....	52
Tablo 4.17. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.....	52

Tablo 4.18. k-en yakın komşu algoritması uygulama sonuçları.	54
Tablo 4.19. Matlab uygulamasında kullanılan 2.Grup tiroit verilerinde eğitim ve test setine ait veri sayıları.	54
Tablo 4.20. Eğitim fonksiyonu (training functions) performanlarının karşılaştırılması.....	54
Tablo 4.21. Ağ tiplerinin performanslarının karşılaştırılması.....	55
Tablo 4.22. Transfer fonksiyonlarının performanslarının karşılaştırılması.	55
Tablo 4.23. Gizli katman nöron sayılarının karşılaştırılması.	55



ŞEKİLLER LİSTESİ

Şekil 2.1. Sinir sistemi hiyerarşik yapısı.....	9
Şekil 2.2. İnsan beyninin yapısı.....	10
Şekil 2.3. Beynin bölümleri.....	11
Şekil 2.4. Sinir hücresi yapısı.....	12
Şekil 2.5. Yapay sinir hücresi.....	12
Şekil 2.6. Bir yapay sinir hücresi örneği.....	16
Şekil 2.7. Üç adet girdi ve bir adet çıktıdan oluşan tek katmanlı algılayıcı modeli... 17	
Şekil 2.8. Örnek ADALINE ağı.....	18
Şekil 2.9. İki ADALINE ağından oluşan MADALINE ağı.....	19
Şekil 2.10. Çok katmanlı algılayıcı ağının yapısı.....	21
Şekil 2.11. Havanın yağışlı olma durumunu gösteren üyelik fonksiyonu grafiği.....	26
Şekil 2.12. Havanın sıcaklık durumunu gösteren üyelik fonksiyonu grafiği.....	26
Şekil 2.13. k en yakın komşu algoritması.....	27
Şekil 4.1. 1.grup verilerinin ÇKA ağ topolojisi.....	35
Şekil 4.2. Tablo 4.6'daki en başarılı sonuca ait ÇKA ağ topolojisi.....	38
Şekil 4.3. Tablo 4.9'daki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.....	44
Şekil 4.4. Tablo 4.9'daki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.....	45
Şekil 4.5. Tablo 4.9'daki en başarılı sonuca ait sinir ağı eğitim durumu grafiği.....	45
Şekil 4.6. Tablo 4.10'daki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.....	46
Şekil 4.7. Tablo 4.10'daki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.....	47
Şekil 4.8. Tablo 4.12'deki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.....	48
Şekil 4.9. Tablo 4.12'deki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.....	49
Şekil 4.10. Tablo 4.12'deki en başarılı sonuca ait sinir ağı eğitim durumu grafiği... 49	
Şekil 4.11. 2.grup verilerinin ÇKA ağ topolojisi.....	51
Şekil 4.12. Tablo 4.17' deki 5,3 nöron sayısı ile yapılan denemenin ağ topolojisi... 53	
Şekil 4.13. Tablo 4.23'deki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.....	56
Şekil 4.14. Tablo 4.23'deki en başarılı sonuca ait sinir ağı eğitim durumu grafiği... 56	
Şekil 4.15. Tablo 4.23'deki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.....	57

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TİROİT HASTALIĞININ TEŞHİSİ

ÖZET

Günümüz dünyasında bilgisayar teknolojileri kullanımı, toplum ve insan hayatının her alanında vazgeçilmez bir noktaya gelmiştir. Genelde bilgisayar teknolojileri ve özelde yapay zekâ ve yapay sinir ağları alanında son zamanlarda görülen ve artan ivmeyle devam eden hızlı gelişmeler yaşanmaktadır. Sağlık hizmetleri sektörü de bu konularda önemli çalışmalara sahne olmaktadır.

Bu çalışmanın amacı yapay sinir ağları teknolojisinin tiroit hastalığı teşhisinde kullanılmasıdır. Tiroit bezi, insan vücudunun boyun bölgesinde bulunur ve beyinde bulunan hipofiz bezinden gelen talimatlarla hormon salgılayarak vücut metabolizmasını düzenler. Tiroit hastalığı, tiroit bezinde oluşan işlev bozukluğu sebebi ile ortaya çıkar. Tiroit bezinin aşırı etkin olması durumunda hipertiroidi hastalığı, gereği kadar etkin olmaması durumunda da hipotiroidi hastalığı ortaya çıkar. Hipertiroidi ve hipotiroidi hastalığının teşhisi T3, T4 ve TSH hormon miktarlarının değerlerine bakılarak yapılabilmektedir. Yapılan çalışmada bu değerler giriş verileri olarak alınmış, çeşitli öğrenme yöntemleriyle hastalık teşhisi yapılarak başarı oranları kıyaslanmıştır.

Uygulama farklı kaynaklardan alınan iki veri grubu için ayrı ayrı yapılmıştır. 1. grup, Sakarya İl Sağlık Müdürlüğünden alınan izinle Sakarya İli Kamu Hastahanelerinden elde edilen 300 kişiye ait verilerden oluşmaktadır. Bu kişilerden 100'ü sağlıklı, 100'ü hipertiroidi ve 100'ü de hipotiroidi hastasıdır. 2. grup UCI machine learning veri tabanından alınan 215 kişiye ait verilerden oluşmaktadır. Bu kişilerden 150'si sağlıklı, 35'i hipertiroidi ve 30'u hipotiroidi hastasıdır. 1. veri grubunda 3, 2. veri grubunda 5 giriş bulunmaktadır. Her bir veri grubu Weka programı ve Matlab programı Yapay Sinir Ağları Toolbox'ında farklı öğrenme yöntemleri ile eğitilerek sonuçlar analiz edilmiştir. Tiroit Hastalığının teşhisinde Matlab Yapay Sinir Ağları Toolbox'ında eğitim fonksiyonu olarak LM, ağ tipi olarak feedforward ve transfer fonksiyonu olarak tansig kullanılması durumunda en başarılı sonuçlar alındığı görülmüştür.

Anahtar kelimeler: Makine öğrenmesi, yapay zekâ, yapay sinir ağları, çok katmanlı algılayıcı, (Knn) k en yakın komşu, tiroit hastalığı.

DIAGNOSIS OF THYROID DISEASE WITH MACHINE LEARNING METHODS

SUMMARY

The use of computer technologies in today's world has become an indispensable point in every aspect of society and human life. In the field of computer technologies in general and artificial intelligence and artificial neural networks in particular, there have been rapid developments that have been observed recently and with increasing acceleration. The health services sector is also the scene of important studies on these issues.

The aim of this study is to use artificial neural network technology in the diagnosis of thyroid disease. The thyroid gland is located in the neck region of the human body and regulates body metabolism by secreting hormones by instructions from the pituitary gland in the brain. Thyroid disease is caused by dysfunction of the thyroid gland. Hyperthyroidism occurs when the thyroid gland is overactive, and hypothyroidism occurs if it is not sufficiently effective. Diagnosis of hyperthyroidism and hypothyroidism can be made by looking at the levels of T3, T4 and TSH hormones. In the present study, these values were taken as input data and success rates were compared by diagnosing the disease with various learning methods.

The application was conducted separately for two data groups from different sources. 1. group consists of data of 300 people obtained from Sakarya Public Hospitals with the permission of Sakarya Provincial Health Directorate. Of these, 100 are healthy, 100 are hyperthyroid and 100 are hypothyroid. The second group consists of 215 people from UCI machine learning database. Of these, 150 were healthy, 35 had hyperthyroidism and 30 had hypothyroidism. There are 3 entries in the 1st data group and 5 entries in the 2nd data group. Each data group was trained with different learning methods in the Artificial Neural Networks toolbox of Weka program and Matlab program and the results were analyzed. In the diagnosis of Thyroid Disease, the most successful results were obtained by using LM as the training function, feedforward as the network type and tansig as the transfer function in the Matlab Artificial Neural Networks toolbox.

Keywords: Machine learning, artificial intelligence, artificial neural networks, multilayer perceptron, k nearest neighborhood (Knn), thyroid disease.

BÖLÜM 1. GİRİŞ

Yapay Zekâ'nın insanlar gibi hatta insanlardan daha iyi düşünebilen, kararlar alabilen bir yazılım geliştirebileceği fikri ile basit bir ileri programlama olduğu fikri tartışılmakla birlikte bu alanda yapılan çalışmalar gün geçtikçe çeşitlenmekte ve birbirini tetiklemektedir.

Yapay zekâ kullanımı finans, meteoroloji, savunma sanayii, sağlık hizmetleri, sigorta işlemleri, bankacılık ve müşteri tanıma sistemleri, havacılık ve ulaşım gibi alanlarda gelişerek devam ederken bu alan insanlar üzerinde umut ve korku ikileminde bir etki oluşturarak ilgi alanı olmaya artarak devam etmektedir. Son yıllarda yaşanan Facebook skandalı bunun en belirgin örneklerindedir. Cambridge Analytica eski çalışanı Christopher Wylie tarafından itiraf edilen skandala göre; Cambridge Analytica şirketi yapay zekâ temelli öğrenme algoritmalarını kullanarak herhangi bir Facebook kullanıcısının 68 beğenisinden yola çıkarak; bu kişinin deri rengini, siyasi yönelimlerini ve diğer bazı özel bilgilerini % 85 doğruluk oranıyla ölçebildi. Ayrıca her bir Facebook kullanıcısının davranış özelliklerini, 70 beğenisiyle arkadaşlarından, 150 beğenisiyle ailesinden ve 300'ün üzerinde beğenisiyle kendisinden daha iyi tanımlayabildiklerini ortaya koydu [1].

Yapay zekâ alanında yapılan çalışmalar, insanlarda endişe ve umut arasında bir etki oluşturarak devam etmekle birlikte teknoloji alanında birçok kolaylıklar da getirdi. Özellikle tıp alanında insanlardan kaynaklanan hataları en aza indirmek ve kesintisiz takip ve teşhis yapma açısından birçok fayda sağladı.

Bu çalışmada yapay zekâ alanının bir alt başlığı olarak görülen yapay sinir ağları teknolojisi ile ÇKA ve Knn algoritmaları kullanılarak tiroit hastalığı teşhisinde hekimlere yardımcı olmak amaçlanmıştır.

İnsan vücudunun boyun bölgesinde bulunan, erkelerde daha net gözükken ve “adem elması” olarak da adlandırılan bölgenin altında bulunan tiroit bezinin, vücudun işleyişinde çok önemli etkisi vardır. Tiroit bezi, T3 olarak bilinen triiyodotironin ve T4 olarak bilinen tiroksin hormonlarını üreterek kan dolaşımına gönderir ve bu şekilde vücut metabolizmasını düzenler.

SOLMAZ, R. ve arkadaşları UCI machine learning veri tabanından aldıkları 215 kişiye ait tiroit verileriyle yapmış oldukları çalışmalarında sınıflama yöntemi ile %96.57, kümeleme yöntemi ile %90.68 doğruluk oranlarıyla sonuç bulduklarını belirtmişlerdir [2].

Temurtaş F., tiroit verileriyle yaptığı çalışmasında olasılıksal YSA ile %94.81 oranında başarı elde etmiştir [3].

Keleş A. ve Keleş A., UCI machine learning veritabanından aldıkları 215 kişiye ait tiroit verileriyle yapmış oldukları çalışmalarında NEFCLASS-J ile %95.33 doğruluk oranıyla başarı elde ettiklerini belirtmişlerdir [4].

Kodaz, H. ve arkadaşları UCI machine learning veritabanından aldıkları 215 kişiye ait tiroit verileriyle yapmış oldukları çalışmalarında yapay bir bağışıklık sistemi (IG-AIRS) ile %95.90 doğruluk oranıyla başarı elde ettiklerini belirtmişlerdir [5].

Doğantekin E. ve arkadaşları UCI machine learning veritabanından aldıkları tiroit verileriyle geliştirilmiş diskriminant analizi ve dalgacık destek vektör makinesi yöntemini kullanarak %91.86 doğruluk oranıyla başarı elde ettiklerini belirtmişlerdir [6].

Bu çalışmada iki ayrı veri grubunda tiroit hastalığı tanısı için yapılan tahlil sonuçları kullanılmıştır. 1.grup, Sakarya İl Sağlık Müdürlüğünden alınan izinle Sakarya İli Kamu Hastahanelerinden elde edilen 300 kişiye ait verilerden oluşmaktadır. 1.grup verilerinde kişinin sağlıklı, hipertiroidi ve hipotiroidi olma durumunu tesbit etmekte kullanılan TSH, sT3 ve sT4 olmak üzere 3 adet değer incelenmiştir.

2. veri grubu olarak isimlendirilen diğer veri grubunda ise, tiroit bezinin az çalışması durumunda görülen hipotiroidi ve fazla çalışması durumunda görülen hipertiroidi

hastalarının ve normal sağlıklı bireylerin tiroit hastalığının teşhisinde kullanılan 5 adet tetkik verileri kullanılarak hastanın durumu hakkında makine öğrenmesi yöntemi ile tesbit yapılmıştır. 2.grup veriler ise UCI machine learning veri tabanından alınan 215 kişiye ait tiroit verilerinden oluşmaktadır.

2.grup'ta tiroit hastalığının teşhisinde kullanılan beş özellik incelenmiştir. Bu özellikler:

- 1. Özellik: T3-resin update testi(yüzdelik değer). T3RU olarak da bilinen T3 reçine alımı. TBG (Tiroksin Bağlayıcı Globulin) hormonunun bağlanmasını ölçen kan testidir. TBG oranının çok düşük olması böbrekler ile ilgili bir soruna işaret edebilir veya vücudun protein miktarının az olduğunu gösterebilir.
- 2. Özellik: T4 testi ya da tiroksin testi. T4 değerinin yüksek çıkması tiroit bezinin aşırı aktif(hipertiroidi) olduğunu gösterir.
- 3. Özellik: T3 testi, triiyodotironin hormonunun seviyesini kontrol için yapılır.
- 4. Özellik: TSH testi. Sensitif immunometrik assay kullanılarak yapılan TSH ölçümü.
- 5. Özellik: 200 mikrogram tirotropin salgılatıcı hormonun enjeksiyonundan sonra TSH değerinin bazal değere kıyasla en yüksek mutlak farkı.

Giriş bilgilerini içeren bu 5 özelliğe karşılık çıkış bilgisi olarak sağlıklı, hipertiroidi ve hipotiroidi olmak üzere üç sınıf kullanılmıştır. Her iki grupta da sınıflama yöntemi olarak çok katmanlı algılayıcı ağı ve Knn algoritması kullanılmıştır ve performansları karşılaştırılmıştır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Yapay Zekâ

Zekâ, beynin bilgiyi alıp mevcut bağlantıları dikkate alarak doğru analiz edip bir çıktı üretmesi olarak tanımlanabilir. Hayatımız boyunca beynimiz; göz, kulak, dil, el ve burun başta olma üzere diğer duyu organlarımız ve onlara etki eden fiziksel ve bilişsel bütün etkenler aracılığıyla devamlı elektrik sinyali olarak bilgileri alır, bunları mevcut bağlantılarla yorumlar, hıfz eder ve yine daha önceki bütün bağlantıları dikkate alarak bir cevap üretir. İnsan beyninin bu davranışı temelde yapay zekâ alanının odak noktası, ilgi alanı ve aynı zamanda ilham kaynağıdır.

Yapay zekâ çalışmaları temelde bir ihtiyaçtan doğmuştur fakat bu ihtiyaçları bilgisayar teknolojilerine yöneltmenin öncesinde en temelde bilişim teknolojilerinin donanım ve yazılım temelinde büyük gelişmeler göstermesi bu bilim dalının önünü açan ana etmendir. Yapay zekâ, varoluşundan beri ihtiyaçlarına sürekli pratik çözümler geliştirmenin gayreti içerisinde olan insanlığın sosyal, ticari, askeri, tıp ve ekonomi gibi alanlarda makineleşmenin getirdiği pratikler ve bu pratiklerin yeni ihtiyaçları doğurması sonucu oluşan zeminde, kendi nörolojik ve bilişsel aktivitelerini çok basit düzeyde de olsa gelişen bu yazılım ve donanım zemininde taklit etmesi olarak yorumlanabilir.

İlk olarak 1950'li yıllarda ortaya konulan “yapay zekâ” kavramı 1990'lı yıllardan itibaren oldukça hızlı artan bir ivmeyle gelişme gösterdi [7]. Günümüzde yapay zekâ ile tasarlanmış robotlar Rusya'da olduğu gibi haber spikeri olarak kullanılabilir.

Yapay zekânın tanımı ve içeriği konusunda yapılan birçok araştırmalar olmakla birlikte bu alanın önemli çalışmacılarından biri olan Alan Turing, “Turing testi” olarak anılan çalışması ile yapay zekânın önemli hedeflerinden birini ortaya koymuştur.

Turing Testi bir bilgisayarın insan gibi düşünüp düşünemeyeceğini tesbit etmek amacıyla geliştirilen bir sorgulama yöntemidir. İngiliz matematikçi Alan Turing

tarafından “Computing machinery and intelligence” adlı makalesiyle gündeme gelmiştir. Alan Turing’in bir bilgisayarın insandan ayırt edilemeyeceğini saptamak amacıyla ortaya koyduğu bu çalışmasında birbirinden tamamen yalıtılmış iki oda bulunmaktadır. Bu odalardan birinde bilgisayarın başında sorgulayıcı konumunda bir insan bulunmaktadır. Diğer odada ise sorgulayıcının bağlantı kurduğu iki bilgisayardan birinde insan, diğerinde ise sorulan sorulara cevap veren bir yazılım bulunmaktadır. Sorgulayıcı konumundaki insanın herhangi bir sınırlama olmaksızın sorduğu her türlü soruya karşılık, karşıdan gelen cevapların hangisinin bilgisayar başındaki insandan, hangisinin ise yazılım aracılığıyla çalışan bilgisayardan geldiğini ayırt edememesi durumunu yapay zekâ çalışmalarının hedeflerinden biri olarak tesbit etmiştir [8].

Yapay zekâ, uzman sistemler, genetik algoritmalar, yapay sinir ağları, zeki etmenler ve bulanık önermeler başta olmak üzere birçok alt bilim dalını içeren kapsamlı bir bilim dalıdır [7].

2.1.1. Uzman sistemler

Bir problemin, gerçek hayatta uzmanlarının çözdüğü şekilde bilgisayar ortamında çözülmesi, bu probleme ait verilerin (bilgilerin) saklanması ve bu veriler- kullanılarak bir çıkarım elde edilmesi esasına dayanan sistemlerdir.

Bir problemin çözümü, herhangi bir uzmanın veriyi temin etmesi, temin edilen verinin hafızada saklanması ve bu veriler arasındaki ilişkilerden yola çıkılarak bir çözümün geliştirilmesi esasına dayanır. Aynı şekilde bütün bu adımların bilgisayar ortamında gerçekleştirilmesi uzman sistemler olarak karşımıza çıkmaktadır.

2.1.2. Yapay sinir ağları

Yapay sinir ağları ve makine öğrenmesini içinde barındıran “Yapay zekâ” kavramı ilk olarak 1956 yılında Dartmouth College’inde Marvin Minsky ve John McCarthy tarafından düzenlenen konferansta McCarthy tarafından dile getirilmiştir.

Yapay zekânın özel bir alanı olarak görülen yapay sinir ağları teknolojisi ile birlikte, günümüzde bilgisayarlar, olaylar hakkında karar verebilmekte, olaylar ve kavramlar

arasında ilişki kurabilmekte ve mevcut ilişki üzerinden yeni çıkarımlarda bulunabilmektedir.

Yapay sinir ağları, biyolojik sinir sistemine benzer şekilde proses elemanlarının birbirlerine hiyerarşik olarak bağlanması ile oluşan bir ağdır ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır [7].

Genel işlev olarak bir yapay sinir ağı kendisine gösterilen bir girdi setine karşılık olası bir çıktı seti belirlemektedir [7]. Yapay sinir ağları kendisine gösterilen veri setindeki girdiler ve çıktılar arasındaki ilişkilerden genelleme yaparak bir çıkarımda bulunur ve bu çıkarım ile daha önce görmediği yeni veriler hakkında bir sonuç üretir.

2.1.2.1. Tarihçe

İnsan beyninin yapısı ve nasıl çalıştığı tarih boyunca sürekli merak ve araştırma konusu olmuştur. Basit sayısal işlemleri yapan ilkel aletlerden, günümüz bilgisayarlarına kadar olan gelişmeler hep bu merakın neticeleridir.

Bilim adamlarının, insan beyni, insanın dış çevreden bilgi alıp yorumlama yöntemleri ve nörobiyoloji alanına ilgi duyması ve bu ilgi neticesinde elde edilen bilgilerin bilgisayar sistemlerine uyarlanması ile yapay sinir ağlarının gelişimi başlamıştır.

W.James, ‘Psikolojinin İlkeleri’ isimli eserinde belleği birincil ve ikincil bellek olarak ikiye ayırmış ve beyin fonksiyonları hakkında günümüzde de geçerliliğini devam ettiren bazı bilgileri ortaya koymuştur [9].

McCulloch ve Pitts gibi bilim adamlarının ileri sürdüğü beyin fonksiyonlarının mühendislik alanlarına uyarlanması fikri yapay sinir ağları teknolojisinin gelişmesine önemli katkı sağlamış ve bu bilim adamları ilk yapay sinir ağı modelini geliştirmişlerdir [10].

1949 yılında Donald Hebb ‘Organization of Behavior’ isimli eserinde bahsettiği “Hebbian öğrenme” kuralıyla yapay sinir ağının bağlantı sayısı ile öğrenme arasındaki ilişkiyi ortaya koydu [11]. 1951 yılında ilk nöro-bilgisayar üretildi. 1954 yılında Farley and Clark tarafından rassal ağlar ile adaptif tepki üretme kavramı öne sürüldü ve 1958

yılında Rosenbelt tarafından geliştirilen algılayıcı model çok katmanlı algılayıcıların öncülü oldu [7].

Bernard Widrow ve Marcian Hoff, Rosenblatt'ın algılayıcı modeline göre daha gelişmiş bir öğrenme algoritmasına sahip yapay sinir ağı modelleri olan ADALİNE' ı ve daha sonra da MADALİNE'ı geliştirdiler.

1960 ve 1980'li yıllar arasında bazı bilim adamlarının XOR probleminin çözülememesinden dolayı yapay sinir ağlarına dayalı algılayıcıların bilimsel bir gerçekliğinin olmadığını öne sürmesinden dolayı bu alanda yapılan çalışmalarda bir duraklama yaşandı [7].

1980'li yıllarda Rummelhart'ın paralel programlama konusunda ortaya koyduğu eser çok katmanlı algılayıcı modelinin temelini oluşturdu [12, 13]. Çok katmanlı algılayıcıların XOR problemini çözmesinin yanında Hopfield ve Boltzman makinelerinin sınırlamalarına da çözümler getirmesi bu ağlara yönelik ilgiyi artırdı.

1988 yılında Broomhead ve arkadaşları tarafından filtreleme problemlerine kabul edilebilir çözümler geliştiren Radyal tabanlı fonksiyonlar modeli geliştirildi [14]. Daha sonra bu ağların gelişmiş biçimi olan Probabilistik Ağlar [15] ve Genel Regrasyon Ağları [16] ortaya çıkarıldı.

Bilgisayar donanım ve yazılım teknolojisindeki hızlı gelişmeler neticesinde özellikle 1990'lı yıllardan sonra yapay zekâ ve yapay sinir ağları alanında yapılan çalışmaların da önü açılmış ve yapay sinir ağları alanında yapılan çalışmalar artık teorik olmaktan çıkarak ev, işyeri, okul, sağlık sektörü ve askeri alan gibi hayatın birçok alanında insanların bire bir etkileşimde olduğu yapılar haline gelmiştir.

2.1.2.2. Kronolojik tarihçe

1890- W.James 'Psikolojinin İlkeleri' isimli eserinde belleği iki bölüme ayırmış, beynin yapısı ve fonksiyonları ile ilgili günümüzde de geçerliliğini devam ettiren bilgiler ortaya koymuştur.

1911- İnsan beyninin birbirleriyle bağlantılı sinir hücrelerinden oluştuğu fikrinin benimsenmesi.

1943- Yapay sinir hücreleri ile ilgili hesaplama teorisinin geliştirilmesi.

1949- Nörobiyolojik öğrenme prosedürünün bilgisayarlara uyarlanabilecek şekilde geliştirilmesi.

1956-1962- ADALINE ve Widrow öğrenme algoritmasının geliştirilmesi.

1957-1962- Tek katmanlı algılayıcının geliştirilmesi.

1965-Makine öğrenmesi üzerine ilk eserin yayınlanması.

1967-1969- Grosberg öğrenme algoritması olmak üzere bazı öğrenme algoritmalarının geliştirilmesi.

1969- Tek katmanlı algılayıcıların problemleri çözme becerilerinin olmadığını isbat edilmesi.

1969- Bazı bilim adamlarının XOR problemine çözüm geliştiremediği iddiasıyla ortaya attığı yapay sinir ağlarının geleceğinin olmaması iddiasının etkisiyle diğer yapay zekâ çalışmalarına yönelmesi.

1969-1972- Doğrusal ilişkilendiricinin geliştirilmesi.

1972- Korelasyon matrisi düzeneğinin ortaya konulması.

1974- Geriye yayılım modelinin geliştirilmesi.

1978- Öğretmensiz öğrenme(ART modeli) geliştirilmesi.

1982- Kohonen öğrenmesi ve SOM modelinin geliştirilmesi.

1982- Hopfield ağlarının geliştirilmesi.

1982- Çok katmanlı algılayıcının geliştirilmesi.

1984- Boltzman makinesinin geliştirilmesi.

1985- Çok katmanlı algılayıcıların genelleştirilmiş Delta öğrenme kuralı çerçevesinde geliştirilmesi.

1988- RBF modeli geliştirildi.

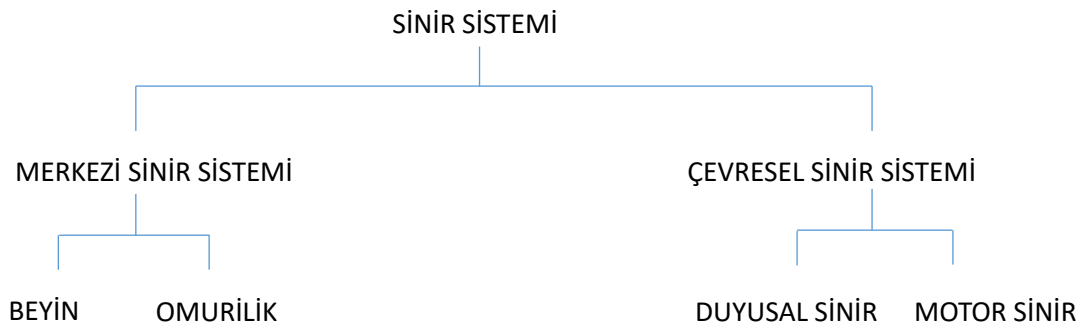
1988- PNN modeli geliştirildi.

1991- GRNN modeli geliştirildi.

1991'den günümüze gelene kadar çok sayıda alanda bilnlerce çalışma ortaya konulmuştur.

2.1.2.3. Biyolojik sinir ağları

Yapay sinir ağları insanın nörobiyolojik sisteminden ilham alınarak tasarlanmıştır. İnsanların sinir sistemleri birbirleriyle iletişim halinde olan ortalama 100 milyar sinir hücresinden oluşmaktadır ve Şekil 2.1'de verilen hiyerarşik yapısından anlaşılacağı gibi merkezi ve çevresel sinir sistemi olarak iki kısma ayrılır. Çevresel sinir sistemi vücudun bütün bölgelerinden gelen bilgileri merkezi sinir sistemine taşır ve merkezi sinir sisteminin uyarılara karşı verdiği cevabı ilgili organlara gönderir. Merkezi sinir sistemini oluşturan beyin ve omurilikteki hücreler birbirleriyle bağlantılı halde merkezi yapıyı oluşturmakla birlikte vücudumuzdaki bütün sinir hücreleriyle de bağlantılıdır.




Şekil 2.1. Sinir sistemi hiyerarşik yapısı.

Yapay sinir ağları, Şekil 2.2'de görülen insan beyninin yapısından ilham alınarak geliştirilmiş bir teknolojidir. 1.5 kg'lık insan beyninde yaklaşık olarak 10^{10} adet sinir

hücresi olduğu tahmin edilmektedir. Her bir sinir hücresinin birden fazla sinir hücresiyle bağlantılı olduğunu hesaba katarsak insan beyninde $6 \cdot 10^{13}$ 'den fazla sinir hücresi bağlantısı olduğunu söyleyebiliriz. Nöronlar birbirleriyle elektrik akımı veya kimyasal akım ile bilgi aktarımında bulunabilir.


Sinir hücreleri bağlantıları ile birlikte beynin çalışmasını sağlayan en önemli yapılardandır. Sinir hücreleri insanın kendi vücudundan ve çevresinden gelen etkileri anlamlandırmasını ve bu etkilere karşı nasıl cevap üreteceğini organize eder.



Şekil 2.2. İnsan beyninin yapısı [17].


Şekil 2.3' de görüldüğü gibi insan beyninde vücudun değişik bölgelerine cevap veren ve farklı görevleri olan birçok bölge bulunmaktadır. Örnek olarak beynimizde, koklama görevini yerine getiren bir bölge, işitme görevini yerine getiren başka bir bölge, tatma, görme, hissetme gibi ve bunlarla bağlantılı birçok fonksiyonu yerine getiren ayrı ayrı merkezi bölgeler mevcuttur.

BEYİN



Şekil 2.3. Beynin bölümleri [18].

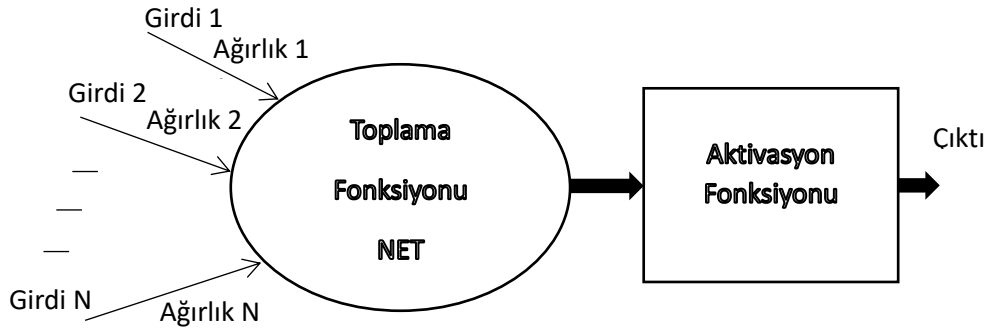
Şekil 2.4'te yapısı verilen bir biyolojik sinir hücresi soma, somanın içerisinde bulunan çekirdek, dentritler, snapslar ve axon'dan oluşmaktadır. Soma dış uyaranlardan ve diğer sinir hücrelerinden gelen bilgiyi elektrik sinyalleri şeklinde işleme tabi tutar. Eğer bu bilgi belirli bir eşik değerinin üzerinde ise bu değere göre kendi elektrik sinyalini üretir ve bunu axon aracılığı ile dentritlere gönderir. Dentritler de bu sinyalleri snapslar aracılığı ile diğer nöronlara gönderir. Sinir hücreleri birbirleriyle elektrik akımı olarak doğrudan bağlantı kurabileceği gibi bazen de snaps ve dentritler aracılığı ile kimyasal bağlantı da kurabilir.



Şekil 2.4. Sinir hücresi yapısı [19].

2.1.2.4. Yapay sinir hücresi

İnsan vücudundaki sinir ağları sinir hücrelerinden oluştuğu gibi yapay sinir ağları da adına proses elemanı ya da nöron denilen yapay sinir hücrelerinden oluşmaktadır. Yapay Sinir Ağlarında kullanılan her bir proses elemanı Girdiler, Ağırlıklar, Toplama Fonksiyonu, Aktivasyon Fonksiyonu ve Hücrenin Çıktısı olmak üzere Şekil 2.5’de görülen ve aşağıda anlatılan 5 temel kavram ile temsil edilir.



Girdiler: Bir yapay sinir hücresine dış dünyadan veya kendisi gibi diğer bir yapay sinir hücresi olan nöronlardan gelen verilerdir.

Ağırlıklar: Bir yapay sinir hücresine gelen bilginin girdiği nörona etkisinin nümerik olarak ifadesidir. Bir yapay sinir hücresine gelen bilginin ağırlığının sıfır olması demek bu verinin o nörona birebir etkisinin olmadığını gösterir, bu etkisiz olma durumu ağırlık

tümünü dikkate aldığımızda anlamlı bir etki durumunun bir parçası olduğundan genel ağ açısından sıfır olan ağırlığın da bir değeri vardır. Yine ağırlıklar eksi değerler olabileceği gibi pozitif değerler de olabilir. Ağırlıklar değişken olabileceği gibi sabit değerler de olabilirler [7].

Toplama Fonksiyonu: Toplama fonksiyonu genelde bir nöronun kendisine gelen bütün girdilerin nümerik değerlerini ve her bir değerın ağırlık katsayısını dikkate alarak hesaplayan fonksiyondur. Toplama fonksiyonu bazen gelen verilerin nümerik değerleri ve ağırlıklarını dikkate alarak hesapladığı gibi bazen de sadece o yapay sinir hücresine gelen girdilerin sayısını dikkate alarak da hesaplayabilir. Bunun için değişik fonksiyonlar bulunmaktadır. En yaygın olan fonksiyon ağırlıklı toplamı bulan fonksiyondur. Bu fonksiyonda yapay sinir hücresine her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece o nörona gelen net girdi hesaplanmış olur. Bu durumda, ilgili nöronun Net girdisi Denklem 2.1’de gösterilmektedir.

$$NET = \sum_i^n G_i A_i \quad (2.1)$$

Denklem 2.1.’de G girdileri, A ağırlıkları, n ise ilgili nörona gelen toplam veri sayısını göstermektedir. Toplama fonksiyonu olarak tek bir formül yoktur, Tablo 2.1’de görüldüğü gibi değişik toplama fonksiyonu çeşitleri bulunmaktadır. Bir problem için en uygun toplama fonksiyonunu belirten belirlenmiş bir formül yoktur. Bunun için genelde deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir. Aynı zamanda bir yapay sinir ağında bulunan bütün nöronların aynı toplama fonksiyonu ile işlem göreceği diye bir kural da yoktur. Her bir nöron farklı toplama fonksiyonları kullanabileceği gibi hepsi ya da birkaçı aynı toplama fonksiyonunu da kullanabilir [7].

Aktivasyon Fonksiyonu: Yapay sinir hücresine gelen net girdi, aktivasyon fonksiyonundan geçirilerek o hücrenin çıktısı belirlenir. Literatürde birçok farklı aktivasyon fonksiyonları tanımlanmış olup, bunlardan bazıları Tablo 2.2’de verilmiştir. Aktivasyon fonksiyonunun çok katmanlı algılayıcılarda türevi alınabilir bir fonksiyon olması gerekmektedir.

Net giriş(Toplama Fonksiyonu)	Açıklama
$\text{Net Girdi} = \prod_i G_i A_i$	Her bir nöronun gelen değerler bağlantı yolundaki ağırlık değerleri ile çarpılır ve daha sonra elde edilen değerler de birbirleri ile çarpılarak bir sonraki nöronun net girdisi bulunur.
$\text{Net Girdi} = \text{Max}(G_i A_i), i = 1 \dots N$	N adet girdinin her birinin ilgili oldukları ağırlık değerleriyle çarpılmasından sonra en büyük değer o nöronun net girdisi olarak belirlenir.
$\text{Net Girdi} = \text{Min}(G_i A_i), i = 1 \dots N$	N adet girdinin her birinin ilgili oldukları ağırlık değerleriyle çarpılmasından sonra en küçük değer o nöronun net girdisi olarak belirlenir.
<p>Çoğunluk</p> $\text{Net Girdi} = \sum_i \text{sgn}(G_i A_i)$	N adet girdinin her birinin ilgili oldukları ağırlık değerleriyle çarpılmasından sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı o nöronun net girdisi olarak belirlenir.
<p>Kümülatif toplam</p> $\text{Net Girdi} = \text{Net}(\text{eski}) \sum_1 (G_i A_i)$	Yapay sinir hücresine gelen veriler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Tablo 2.1. Toplama fonksiyonu örnekleri [7].

Ağdaki bütün nöronların aynı fonksiyonu kullanması gerekmez. Aynı anda bazı nöron ya da prosesler başka bir aktivasyon fonksiyonunu kullanırken diğer birkaç nöron başka bir aktivasyon fonksiyonunu kullanabilir. Günümüzde Çok Katmanlı Algılayıcı modelinde yaygın olarak kullanılan fonksiyon sigmoid fonksiyonudur. Bu fonksiyon Denklem 2.2’de gösterilmektedir.

Aktivasyon fonksiyonu	Açıklama
Lineer fonksiyon $F(\text{NET}) = \text{NET}$	Gelen girdiler değişikliğe uğramadan nöronun çıktısı olarak belirlenir.
Step fonksiyonu $F(\text{NET}) = \begin{cases} 1 & \text{if NET} > \text{eşik_değer} \\ 0 & \text{if NET} \leq \text{eşik_değer} \end{cases}$	Nörona gelen NET girdi verisinin belirli bir eşik değerinden büyük veya küçük eşit olması durumuna nöronun çıkışı 1 veya 0 olur.
Sinus fonksiyonu $F(\text{NET}) = \text{Sin}(\text{NET})$	Öğrenilmesi istenilen olayın sinüs fonksiyonuna uygun dağılım göstermesi halinde kullanılabilir.
Eşik değer fonksiyonu $F(\text{NET}) = \begin{cases} 0 & \text{if NET} \leq 0 \\ \text{NET} & \text{if } 0 < \text{net} < 1 \\ 1 & \text{if NET} \geq 1 \end{cases}$	Nörona gelen Net girdinin 0 veya 0'dan küçük olması durumunda 0, 0 ve 1 arasında olması durumunda Net girdi, diğer durumlarda 1 çıkışının üretildiği fonksiyon.
Hiperbolik tanjant fonksiyonu $F(\text{NET}) = (e^{\text{NET}} + e^{-\text{NET}}) / (e^{\text{NET}} - e^{-\text{NET}})$	Nörona gelen NET girdinin tanjant fonksiyonundan geçirilmesi ile bulunur.

Tablo 2.2. Aktivasyon fonksiyonu örnekleri [7].

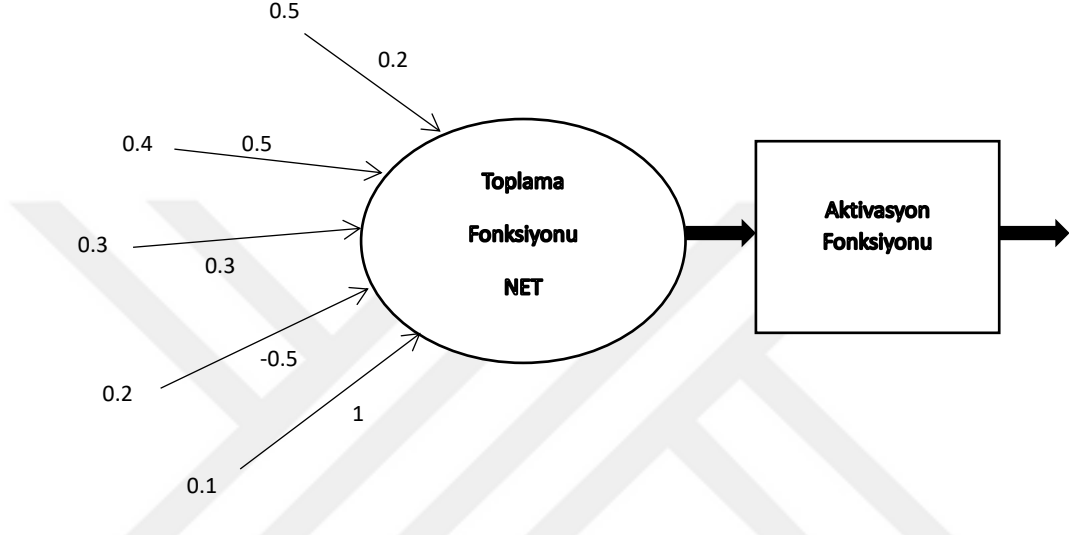
$$F(\text{NET}) = \frac{1}{1+e^{-\text{NET}}} \quad (2.2)$$

Denklem 2.2'deki NET ifadesi, ilgili yapay sınır hücreğine gelen NET girdi değerini göstermektedir. Bu değer daha önce ilgili nörona gelen bütün verilerin toplama fonksiyonundan geçirilmesi ile hesaplanır [7].

Hücrenin Çıktısı: Aktivasyon fonksiyonu ile üretilen çıktıdır. Bu çıktı doğrudan ağına dışına ya da ağda başka ara katman varsa ağ üzerindeki herhangi bir nörona gönderilebilir. Bir proses elemanının birden fazla girdisi olabilir fakat sadece bir çıktısı olmalıdır. Giriş ve ara katman nöronlarındaki her bir çıktı birden fazla nöronla ilişkilendirilebilir fakat bu ara katman ve giriş nöronlarının birden fazla çıktısı olduğu

anlamına gelmez. Bir yapay sinir hücresinden bir sonraki nöronlara gönderilen bütün girdiler tek bir çıktıyı temsil eder.

Şekil 2.6'da bir yapay sinir hücresi örneği verilmiştir. Bu örnekte yapay sinir hücresine gelen veri sayısı 5'tir. Bu veriler ve her bir verinin ağırlık değeri Şekil 2.6'da görülmektedir.



Şekil 2.6. Bir yapay sinir hücresi örneği.

Bu değerlere göre yapay sinir hücresine gelen NET bilgi, Denklem 2.1 kullanılarak aşağıdaki gibi hesaplanır:

$$NET = 0.5*0.2 + 0.4*0.5 + 0.3*0.3 + 0.2*(-0.5) + 0.1*1$$

$$NET = 0.1 + 0.2 + 0.09 + (-0.1) + 0.1$$

$$NET = 0.39$$

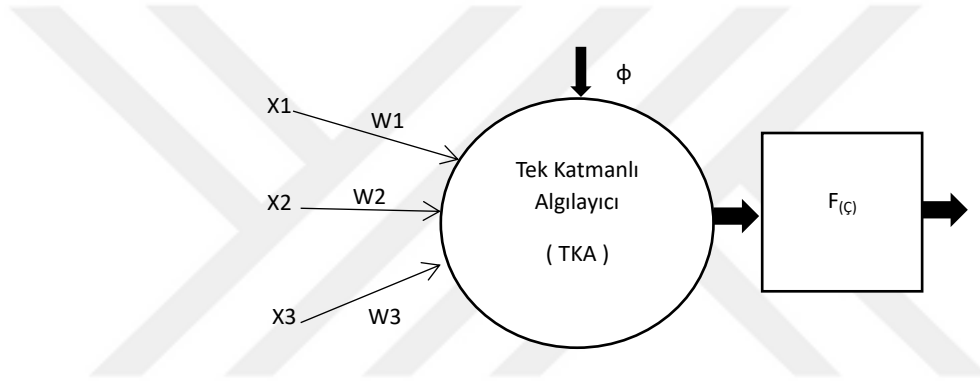
Bu durumda yapay sinir hücresinin sigmoid fonksiyonuna göre çıktısı(Ç), Denklem 2.2 kullanılarak aşağıdaki gibi hesaplanır:

$$\text{Ç} = \frac{1}{1 + e^{-0.39}} = 0.5962826993$$

2.1.2.5. Tek katmanlı algılayıcılar

Tek katmanlı yapay sinir ağları sadece girdi ve çıktı katmanlarından oluşmaktadır. Her ağın bir veya daha fazla girdisi ve çıktısı vardır. Girdi katmanındaki bütün veriler çıktı katmanına bağlanmaktadır. Tek katmanlı algılayıcıların çıkışı doğrusal bir fonksiyondur [7].

Şekil 2.7’de üç girdisi ve bir çıktısı olan ve çıkışın sıfır olmasını engelleyen ve daima 1 olan eşik değerine sahip tek katmanlı algılayıcı örneği verilmiştir. Bu örnekte girdiler X_i , ağırlıklar W_i ve ağırlık çıkışı ζ ile gösterilmektedir. Eşik değeri ise ϕ ile gösterilmektedir ve daima 1’dir.




Bu örnekte ağırlık çıkışı giriş değerlerinin ilgili ağırlık değerleriyle çarpılmasından sonra herbirinin toplanması ve elde edilen değere eşik değerinin de eklenmesiyle bulunur. Çıkış değeri bulunduğundan sonra aktivasyon fonksiyonundan geçirilir. Bu durumda eğer çıkış 0’den büyükse 1.sınıfta aksi takdirde 2.sınıfta kabul edilir [7].

$$f(\zeta) = \begin{cases} 1 & \text{Eğer } \zeta > 0 \text{ ise} \\ 0 & \text{aksi takdirde} \end{cases}$$

2.1.2.6. Adaline ağı

ADALINE Widrow ve Hoff tarafından 1959 yılında tasarlanmıştır. ADALINE ismi, Adaptif doğrusal eleman anlamındaki Adaptif Linear Element isminin kısaltılmış hali olarak ifade edilmektedir.



Şekil 2.8’de örnek bir ADALINE ağı görülmektedir. Bu ağ, X_1, X_2, \dots, X_N şeklinde N adet girdiden oluşmaktadır. Eşik değerini temsil eden ϕ , çıkışın sıfırdan farklı bir değer almasını sağlar.

ADALINE en küçük ortalamalı kareler yönetimi olarak ifade edilen delta öğrenme kuralına dayanır. Bu kuralın esası, ağıdaki beklenen değer ile mevcut değer arasındaki hatayı en aza indirmektir. ADALINE ağının net girdisi NET ve çıktısı (\check{C}), Denklem 2.3, 2.4, 2.5 ve 2.6’da yapılan işlemlerle hesaplanmaktadır.

$$NET = \sum_{i=1}^m W_i X_i + \phi \quad (2.3)$$

$$NET = \phi + X_1 W_1 + X_2 W_2 + \dots + X_n W_n \quad (2.4)$$

$$\check{C} = 1 \text{ Eğer } NET \geq 0 \text{ ise} \quad (2.5)$$

$$\check{C} = 0 \text{ Eğer } NET < 0 \text{ ise} \quad (2.6)$$

Beklenen değer B ile gösterildiğinde, ağın hatası (E) Denklem 2.7’den elde edilir.

$$E = B - \check{C} \quad (2.7)$$

Bundan sonra ağırlıklar hatayı azaltmak için her defasında değiştirilmektedir. Bunun için Denklem 2.8’deki formül kullanılmaktadır.

$$W_i(t) = W_i(t-1) + \alpha * E * X_i \quad (2.8)$$

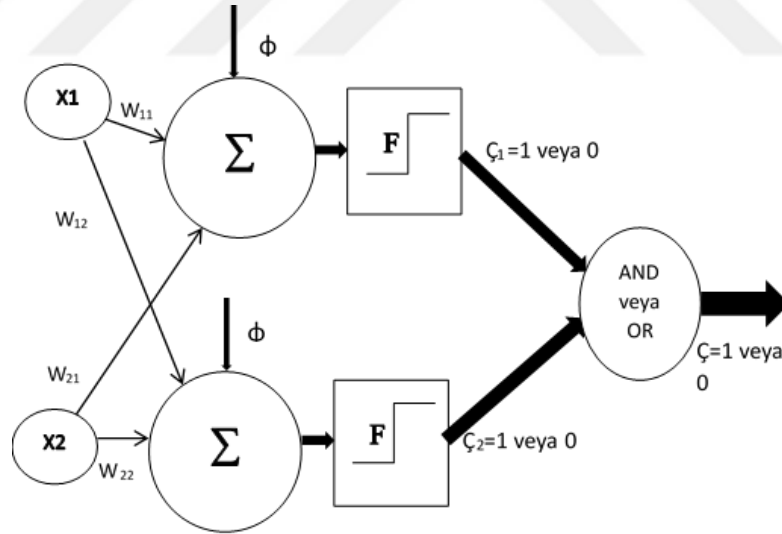
Bu formülde $W(t)$ ağırlıkların t zamanındaki yeni değerleri, $W(t-1)$ ise ağırlığın değişmeden önceki değerini, α öğrenme katsayısını, E beklenen değer ile çıkan değer arasındaki farkı, X' de girişleri göstermektedir [7].

Denklem 2.9' da verilen formül ile en uygun eşik değeri hesaplanır. Bu denklemde Q_y yeni eşik değerini, Q_e önceki eşik değerini göstermektedir [7].

$$Q_y = Q_e + \alpha (B - \zeta) \quad (2.9)$$

2.1.2.7. Madaline ağı

MADALINE modeli (Şekil 2.9), birden fazla ADALINE ağıının AND veya OR sonlandırıcısıyla birleştirilmesi ile elde edilir. Eğer ağıın sonunda AND kapısı bulunursa bütün ADALINE ağılarının 1 çıkışını üretmesi sonucu MADALINE ağıının çıkışı 1 olur, aksi takdirde çıkış 0 olur. ADALINE ağıları OR kapısı ile birleştirildiğinde ise herhangi bir ADALINE ağıının çıkışının 1 olması durumunda MADALINE ağıının çıkışı 1 olur [7].



2.1.2.8. Çok katmanlı algılayıcı (ÇKA)

Çok katmanlı algılayıcılar doğrusal olmayan problemleri çözmek için tasarlanmış yapay sinir ağıları modelidir. Daha önceden Minsky tarafından XOR problemi (Tablo 2.3)

üzerinden dile getirilen yapay sinir ağlarının doğrusal olmayan problemleri çözememesi problemi çok katmanlı algılayıcı modeliyle çözüme kavuşturulmuştur. Minsky'in bu iddiası bir süre yapay sinir ağları çalışmalarının duraksamasına yol açmıştı. Fakat Rumelhart ve arkadaşları tarafından geliştirilen çok katmanlı algılayıcı modeli yapay sinir ağları çalışmalarını tekrar bir daha duraksamamak üzere gündeme getirmiştir [20].

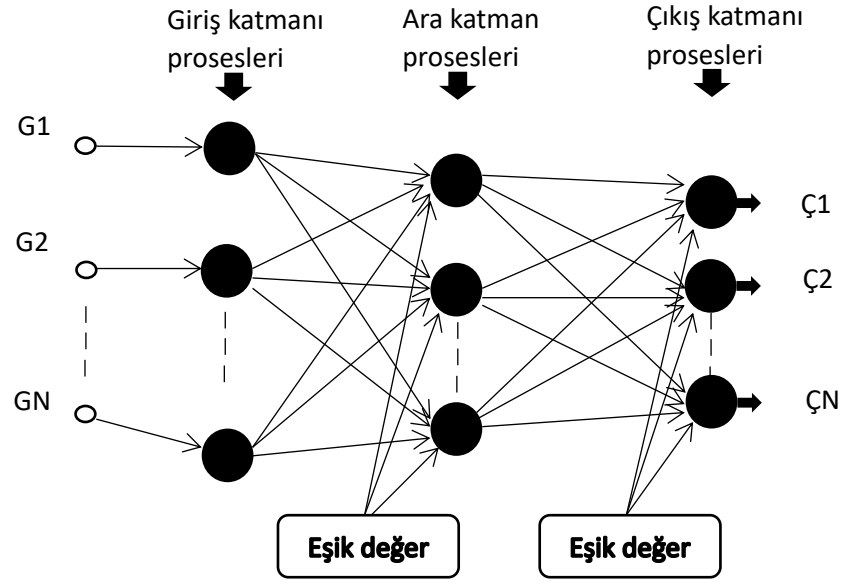
1.Giriş	2.Giriş	Çıkış
0	0	0
0	1	1
1	0	1
1	1	0

Tablo 2.3. XOR problemi giriş ve çıkışlarını gösteren doğruluk tablosu.

Çok katmanlı algılayıcı modeli Delta Öğrenme Kuralı yöntemine göre tasarlanmıştır. Bu ağ modeli ağın beklenen çıktı değeri ile mevcut çıktı değeri arasındaki hata denilen farkı ağa yayarak azaltma yöntemine dayandığı için bu ağa hata yayma modeli ya da geriye yayım modeli de denilmektedir.

Çok katmanlı algılayıcı modelinin yapısı

Şekil 2.10'da yapısı verilen çok katmanlı algılayıcı modeli girdi katmanı, ara katman ve çıktı katmanı olmak üzere en az üç katmandan oluşan bir ağ modelidir. En az denilmesinden kasıt Girdi katmanı ve Çıktı katmanı arasında problemin çözümüne yönelik olarak birden fazla ara katman kullanılabilmesinden dolayıdır. Bunun için belirli bir kural yoktur. Problemin tabiatına göre girdi ve çıktıları arasındaki doğrusal olmayan ilişkiyi tanımlamaya yönelik olarak birden fazla ara katman kullanılıp kullanılmayacağı ve her bir ara katmanda kaç tane proses olacağı, her bir problemin çözümüne yönelik olarak kullanıcı tarafından problemin sisteme sunulması esnasında belirlenir.



Girdi Katmanı: Dışarıdan gelen girdileri (G_1, G_2, \dots, G_N) olarak ara katmana gönderir. Bu katmanda, gelen veriler herhangi bir işleme tabi tutulmadan ara katmana gönderilir. Girdi katmanında birden fazla proses olabilir. Girdi katmanındaki her bir proses kendisinden sonraki katman olan ara katmandaki bütün proseslerle bağlantılıdır.

Ara Katmanlar: Ara katmandaki prosesler girdi katmanından gelen verileri her birine özel olan ağırlık değerleriyle birlikte alarak işleme tabi tutarlar ve kendisinden sonraki katmana gönderirler. Ara katmandaki her bir proses kendisinden sonraki ara katman ya da çıkış katmanı proseslerinin hepsi ile bağlantılıdır.

Çıktı Katmanı: Ara katmandan gelen verileri bir işleme tabi tutarak çıkış üreten katmandır. Çıkış katmanı proseslerinin her biri bir önceki katman olan ara katman proseslerinin hepsi ile bağlantılı olduğundan birden fazla girişi olabilir fakat her bir çıkış katmanı prosesinin tek bir çıkışı olmalıdır.

ÇKA ağı öğretmenli öğrenme stratejisini kullanır. Bu ağ modelinde ağa hem örnekler hem de örneklerden elde edilmesi gereken sonuçlar verilmektedir. Ağ kendisine gösterilen örneklerden problemin çözümüne yönelik bir Denklem geliştirir ve daha sonra daha önce hiç görmediği verilere ait çıktıları bu denklem üzerinden çözüme kavuşturur [7].

ÇKA'da öğrenme kuralı olan Genişletilmiş Delta Kuralı kullanılır. Bu kurala göre öncelikle ağa, eğitim seti denilen örnekler ve örneklerden elde edilmesi gereken çıktılar sunulur.

Genişletilmiş Delta Kuralı iki aşamadan oluşur:

1.aşama: ileriye doğru hesaplama

2.aşama: geriye doğru hesaplama

İleriye doğru hesaplama

Girdi katmanından gelen bütün veriler kendi ağırlık değeriyle çarpılarak ara katman prosesine gelir ve ara katman prosesine bu şekilde gelen bütün veriler toplanarak o prosesin net girdisi hesaplanmış olur. Giriş katmanından gelen veriler değişikliğe uğramadan ara katmana gönderilir. G_k giriş katmanının k. prosesinden gelen bilgiyi gösterir ve değişikliğe uğramadan C_k^i olarak ($C_k^i = G_k$) ara katman prosesine gönderilir.

$$NET_{aj} = \sum_{k=1}^n A_{kj} C_k^i \quad (2.10)$$

Denklem 2.10'da NET_{aj} , j.ara katmanın net girdisidir. A_{kj} , k. giriş katmanının j.ara katmana bağlanan verinin ağırlık değeridir.

Ara katman proseslerine gelen veriler toplama fonksiyonundan geçirildikten sonra ilgili katmanın net girdisi hesaplanmış olur. Daha sonra bu net girdi aktivasyon fonksiyonundan geçirildikten sonra o ara katman prosesinin çıkışı hesaplanmış olur. Aktivasyon fonksiyonu olarak türevi alınabilir bir fonksiyon kullanmak yeterlidir. ÇKA modelinde yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid, tanjant, threshold, lineer ve hard limiter fonksiyonlarıdır.

Yukarıda bahsedilen tanımlamaya göre sigmoid fonksiyonu kullanılması halinde ilgili ara katmanın çıktısı, Denklem 2.11'deki gibi ifade edilir.

$$C_{ja} = \frac{x}{1 + e^{-(NET_{ja} + \beta_{ja})}} \quad (2.11)$$

Denklem 2.11’de, β_{ja} , ara katmandaki j. prosese ait eşik değeri göstermektedir. Ara katmandaki bütün proseslerin çıkışı kendisine gelen giriş değerlerinin toplama fonksiyonundan geçirilmesi ve bu şekilde bulunan değerinde sigmoid fonksiyonundan geçirilmesi ile hesaplanır.

Geriye doğru hesaplama

Ağa girilen veriler sonucunda ağın ürettiği çıktı ile beklenen çıktı arasındaki fark hatayı verir. Denklem 2.12’de ζ_m , m.çıkış elemanının ürettiği çıktıdır. B_m ise m.çıkış elemanından beklenen değerdir. E_m ise hatayı göstermektedir.

$$E_m = B_m - \zeta_m \quad (2.12)$$

Çıktı katmanındaki toplam hatayı (TH) bulmak için Denklem 2.13 kullanılmaktadır.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (2.13)$$

Ara katman ile çıktı katmanı arasındaki ağırlıkları değiştirmek için j. proses elemanını, çıktı katmanı prosesi olan m. elemana bağlayan ağırlık katsayısındaki değişim miktarı ΔA^a ile gösterildiğinde, herhangi bir t. sayıdaki iterasyonda değişim miktarı Denklem 2.14’de gösterilmektedir.

$$\Delta A_{jm}^a(t) = \gamma \delta_m \zeta_j^a + a \Delta A_{jm}^a(t-1) \quad (2.14)$$

Bu formülde γ öğrenme katsayısını, a momentum katsayısını göstermektedir. Denklem 2.14’deki m. çıkış katmanı prosesinin hatasını gösteren δ_m Denklem 2.15’de gösterilmektedir.

$$\delta_m = f'(NET) \cdot E_m \quad (2.15)$$

Denklem 2.15’deki formülde $f'(NET)$ aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonu kullanılması halinde formül Denklem 2.16’daki gibi olacaktır.

$$\delta_m = \zeta_m(1 - \zeta_m) \cdot E_m \quad (2.16)$$

Değişim miktarı bulunduktan sonra ağırlıkların t. iterasyondaki yeni değerleri Denklem 2.17’de gösterilmektedir.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (2.17)$$

Benzer yöntemle eşik değerlerinin de ağırlıklarının değiştirilmesi gerekmektedir. Eşik değer ünitesinin çıktısının 1 olması nedeniyle çıktı katmanındaki proseslerin eşik değer ağırlıkları β^c ‘deki değişim miktarı Denklem 2.18’de gösterilmektedir.

$$\Delta\beta_m^c(t) = \gamma\delta_m + \alpha\Delta\beta_m^c(t-1) \quad (2.18)$$

Eşik değer t. iterasyondaki ağırlığının yeni değeri Denklem 2.19’da gösterilmektedir.

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (2.19)$$

Girdi katmanı ile ara katman arasındaki ağırlıkların değişimi ΔA^i ile gösterildiğinde değişim miktarı Denklem 2.20’de gösterilmektedir.

$$\Delta A_{kj}^i(t) = \gamma\delta_j^a \zeta_k^i + \alpha\Delta A_{kj}^i(t-1) \quad (2.20)$$

δ^a ile gösterilen hata terimi sigmoid fonksiyonu kullanıldığı takdirde Denklem 2.21’deki gibi hesaplanır.

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) + \sum_m \delta_m \Delta A_{jm}^a \quad (2.21)$$

Bu durumda ağırlıkların yeni değerleri Denklem 2.22’de gösterilmektedir.

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (2.22)$$

β^a ile gösterilen ara katmandaki eşik değer ağırlıklarındaki değişim miktarı Denklem 2.23’deki gibi hesaplanır.

$$\Delta\beta_j^a(t) = \gamma\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (2.23)$$

Ağırlıkların t. iterasyondaki yeni değerleri Denklem 2.24’deki formülle bulunur [7].

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (2.24)$$

2.1.3. Genetik algoritmalar

Genetik algoritmalar bir problem durumunda en uygun çözümleri bulmak için tasarlanmış algoritmalarlardır. Bu algoritmada problemin çözümüne ait her bir özelliğe gen denir. Genlerin bir araya gelmesiyle problemin çözümünü gösteren kromozomlar meydana gelmiş olur.


Başlangıçta problemin çözümüne yönelik olarak rastgele kromozomlar belirlenir. Belirlenen bu kromozomlar çaprazlama yöntemi ile daha iyi çözümler geliştirebilmek için bir araya getirilir. Bu aşamada yeni çözümler elde etmek adına her bir kromozomdaki özellikler değişime uğrayabilir. Problemin çözümüne yönelik olarak kromozomlarda bulunan özelliklerin değiştirilmesine mutasyon denir. İstenen çözüme en yakın sonuç bulununcaya kadar kromozomların bir araya gelmesi, mutasyon ve mutasyon sonucunda elde edilen yeni bulguların problemin çözümüne yönelik olarak verdiği cevapların uygunluğunun test edilmesi işlemi devam eder.

2.1.4. Bulanık önermeler


Bilgisayar sistemleri 1 ve 0 ile temsil edilen ikili mantık ile çalışmaktadır. Bu mantık fiziksel nesnelere ve kesin olarak ayrılmış durumları bilgisayar sistemlerinde ifade edebilmekte iken insanların günlük hayatında karşılaştığı ve kesin ve net çizgilerle ayrılmamış olayları, duygusal ve soyut ilişkileri ifade edememektedir. İnsanlar günlük hayatlarında bir problemle karşılaştığında bu problemi birçok açıdan olabilirlik, kabul edilebilirlik sınırları içerisinde değerlendirir ve buna göre kararlar alırlar. Futbol maçı yapmak isteyen insanların havanın çok az yağışlı ve sıcak olması durumunda futbol maçı yapacaklarını düşünelim. Bu durumda havanın kesin ve net ifadelerle az yağışlı ve sıcak olma durumu klasik matematik önermelerinde “30 derece sıcak ve bir sayısal değer verilerek şu sayı değerinde az yağmurlu” gibi tek bir değer ile ifade edilirken bulanık mantık ise bu kümelerin kapsamını genişleterek her bir olayı bu kümede belirlenen optimum değere yakınlığına göre bir üyelik katsayısı ile tanımlayarak kabul edilebilir değerler kümesi belirler.

Şekil 2.11’deki grafikte verilen yağış durumunu ele aldığımızda; metrekaeye düşen yağış miktarının 40 mm olması durumu optimum değerdir ve üyelik değeri 1’dir, 0 mm

ile 80 mm arasındaki sonsuz sayıdaki değerlerde optimum değere yakınlığına göre bir üyelik derecesi olarak “kabul edilebilir” olarak değerlendirilir.



Sıcaklık verisinin üyelik değerini gösteren Şekil 2.12'deki grafikte de 30 derece sıcaklık değeri optimum değerdir ve üyelik katsayısı 1'dir. 22 derece ile 38 derece sıcaklık değerleri arasındaki verilerde optimum değere yakınlığına göre 0 ile 1 arasında bir üyelik katsayısı olarak değerlendirilir.



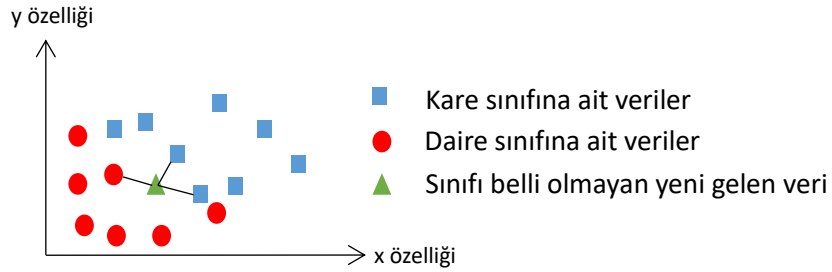
2.1.5. Zeki etmenler

Zeki etmenler birden fazla yapay zekâ tekniğini kullanabilen, bağımsız kararlar alabilen ve online(gerçek zamanlı) çalışabilen sistemlerdir. Bu konu hakkında Russel ve Norving tarafından ayrıntılı bilgiler verilmiştir [21].

2.2. Knn

Knn, k en yakın komşu algoritması İngilizce olan k nearest neighbor cümlesinin kısaltılmış hali olarak ifade edilmektedir. Bu algoritma makine öğrenme yöntemleri arasında en kolay olan sınıflandırma algoritmalarından biridir. Bu yöntemde eğitim seti ve test seti olmak üzere iki veri grubu bulunmaktadır. Eğitim setinde verilerin özellikleri ve hangi sınıfa ait oldukları belirlidir. Algoritma yeni sınıflandırılacak bir veri için mevcut değerlerden bu veriye en yakın olan k tanesinin Euclid uzaklıklarını belirler. Belirlenen bu k adet verinin içerisinde hangi sınıfın verileri daha fazla ise yeni gelen veri o sınıfa ait kabul edilir.

Şekil 2.13'deki grafikte kırmızı renkte daire sınıfına ait veriler ve mavi renkte kare sınıfına ait veriler olduğu varsayalım. Bu grafikte üçgen şeklindeki veri, sınıfı bilinmeyen yeni gelen veriyi göstermektedir. Knn algoritması, k sayısının 3 olarak belirlendiği bu durumda yeni gelen veriye sınıfı belirli olan veriler içerisinde Euclid hesabına göre en yakın olan 3 veriyi belirler ve bu 3 veri içerisinde hangi sınıfın verileri fazla ise yeni gelen veriyi o sınıfa dahil eder.



Knn algoritmasında test setindeki verinin eğitim verileri sınıflarına olan uzaklık sayılarını belirlemek için kullanılan k sayısı (veri setinin özelliğine göre) 1,2,3,4,5 gibi herhangi bir sayı olabilir. K sayısını belirlemede problem uzayının niteliği ve niceliği önemlidir. Eğer k sayısı gereğinden büyük bir sayı olarak belirlenirse, test verisinden çok daha uzaktaki veriler de dikkate alınacağından, yanlış sınıflandırma olasılığı artar.

K-en yakın komşu algoritmasında sınıflandırmada kullanılan komşulardan uzak olanlarının sınıflandırmaya etkilerinin azaltılması için komşu uzaklığı ve ağırlık

katsayısı arasında ters orantı olacak şekilde bir ağırlık katsayısı belirlenir. Bu deęer $w=1/d^2$ formülü ile ifade edilir. Burada w yeni veriye d uzaklıęındaki komşunun ağırlık deęerini gösterir [22].



BÖLÜM 3. TİROİT HASTALIĞI

3.1. Tiroit Bezi Tanımı ve İşlevi

Tiroit bezi, boynun ön tarafında, soluk borusunun her iki yanında yerleşmiş bulunan, yaklaşık 1 cm uzunluğundaki isthmus glandula thyroidea ile birbirine bağlı uzunluğu yaklaşık 5 cm civarında koni şeklinde olan Lobus dexter ve sinister olarak adlandırılan sağ ve sol lob olmak üzere iki lobdan oluşan, C5 T1 vertabralar arasında yer alan bir salgı bezidir. Tiroit dokusu çapları 0,02 ve 0,9 cm arasında değişen folikül hücrelerinden oluşmaktadır. Tiroit bezi büyük oranda lenfatik kılcal damarlar ile örülmüş bir organdır.

Tiroit bezi, vücut metabolizmasını ve hızını düzenleyen T3(triiodotironin) ve T4(tiroksin) hormonlarını salgılayarak dolaşım sistemine gönderir. Fazla hormon salgılanması durumunda vücut metabolizması hızlanır ve hipertiroidi hastalığı örülür. Bu durumda kalp hızı artacağından dolayı kalp çarpıntısı, bağırsak hareketleri de hızlanacağından dolayı ishal görülebilir [23].

Tiroit hormonunun gereğinden az salgılanması durumuna hipotiroidi denilmektedir. Bu durumda kalp hızı azalır ve bağırsak hareketlerinin yavaşlamasından dolayı kabızlık görülebilir [23].

Beyinde bulunan hipofiz bezinden salgılanan TSH (Tiroit Uyarıcı Hormon – Tiroit Stimulan Hormon) ile tiroit bezinin çalışması kontrol edilir. Kandaki tiroit hormonlarının(T3 ve T4) azalması durumunda beyindeki hipofiz bezinden salgılanan TSH artar ve bu sayede tiroit bezi T3 ve T4 salgısını artırır. Eğer kandaki T3 ve T4 miktarı artarsa bu sefer hipofiz bezi TSH salgısını azaltır ve bunun neticesinde tiroit bezi T3 ve T4 salgı miktarını azaltır [23].

3.2. Tiroit Bezi Hastalıkları

3.2.1. Guatr

Tiroit bezinin normal kabul edilenden fazla büyümesi sonucu oluşan hastalıktır. Hormon salgılarında bir değişiklik olmadığı takdirde bir belirti göstermez [23].

3.2.2. Nodül

Tiroit bezi içerisinde tiroit bezi dokusuna benzemeyen farklı dokuların oluşması durumudur. Nodül olan hastaların yaklaşık %5 oranında kansere yakalanma riski vardır. Nodüller soğuk, sıcak ve ılık olmak üzere 3 kategoride incelenir. Sıcak nodüllü hastalarda kansere yakalanma riski %5 oranının daha altındadır [23].

3.2.3. Tiroidit

Tiroit bezinin iltihaplanması sonucu oluşur.

3.2.4. Hipertiroidi

T3 ve T4 hormonlarının gereğinden fazla salgılanması sonucu ortaya çıkar. Bu hastalığın nedenleri arasında vücudun kendi tiroit organını yabancı bir doku olarak algılaması sonucu oluşan Graves hastalığı, Toksik Nodüler Guatr, Tiroiditler, gereğinden fazla iyot alınması ve aşırı tiroit hormonu içeren ilaç kullanılması gibi nedenlerle vücuda ihtiyaçtan fazla tiroit hormonu girişi gibi sebepler sayılabilir [23].

3.2.5. Hipotiroidi

Tiroit bezinin az çalışması dolayısı ile T3 ve T4 hormonlarının gereğinden az salgılanması sonucu ortaya çıkar. Bu hastalığın nedenleri arasında Hashimoto Tiroidit, Tiroit bezi ameliyatları, Radyoaktif iyot tedavisi ve ışın tedavisi sayılabilir [23].

3.3. Hipertiroidi Belirtileri

- Ani görülen aşırı kilo kayıpları
- Aşırı terleme
- Uyku düzensizliği
- Ellerde titreme
- Kalp çarpıntısı
- Ciltte incelme ve hassaslık görülmesi
- Saçlarda kırılma, incelme ve dökülme görülmesi
- Bağırsak hareketlerindeki hızlanma sonucu görülen ishal
- Sinirlilik hali
- Gözlerde ileri doğru çıkma görülmesi (pörtleğ göz)
- Hanımlarda adet düzensizlikleri
- Guatr oluşması
- Erkeklerde meme büyümesi
- Sıcağı tahammül edememe
- Kemik erimesi [23].

3.4. Hipotiroidi Belirtileri

- Halsizlik
- Güç kaybı
- Normal dışı üşüme
- Ses kısılması ve kalınlaşması
- Ellerde, bacaklarda, yüz bölgesinde ve gözlerin etrafında şişme oluşabilir
- Ciltte kuruma ve kalınlaşma
- Terlemede azalma görülür
- Saçlarda kuruluk ve saç dökülmesi
- Uyku bozukluğu
- Depresyon
- Bağırsak hareketlerindeki yavaşlamaya bağlı kabızlık
- Adet bozukluğu

- Aşırı kilo alma
- Hatırlamada güçlük, hafıza zayıflığı
- Nabız düşüşü ve hareketlerde yavaşlama [23].

3.5.Tiroit Tanısı

Tiroit tanısı kan testleri, ultrasonografi, sintigrafi ve ince iğne aspirasyon biyopsisi yöntemleriyle yapılmaktadır.

3.5.1. Kan testleri

Kandaki T3, T4 ve TSH hormonlarının miktarlarının ölçülmesiyle yapılır. Tiroit bezinin durumunu gösteren en belirleyici ölçüm TSH miktarının belirlenmesi ile olur. Eğer kandaki TSH miktarı olması gerekenden az ise tiroit bezinin fazla çalıştığı kanaatine varılır, TSH miktarı olması gerekenden fazla ise tiroit bezinin az çalıştığı kanaatine varılır [23].

3.5.2. Tiroit ultrasonografisi

Tiroit bezinin büyüklüğü, eğer nodül varsa nodülün yerinin tesbiti yapılır ve hacmi belirlenir. Tedavi neticesinde nodülün küçülüp küçülmediği de bu yol ile belirlenir.

3.5.3. Tiroit sintigrafisi

Teknesyum isimli bir maddenin kana enjekte edilerek yapılan nükleer tıp yöntemidir. Bu tetkik, TSH'ı düşük ve nodülü olan hastalara uygulanır. Nodülün sıcak veya soğuk olduğunu belirlemek için yapılır [23].

3.5.4. Tiroit ince iğne aspirasyon biyopsisi

Tiroit bezi nodüllerinde kanser tetkiki için yapılan taramadır. Hastadaki nodüllerden bir örnek kesit alınır ve patolojide incelenir. İltihap veya kanser olup olmadığı kanaatine varılır. Bu tetkik sonucunda hastaya ilaç tedavisi veya ameliyat uygulanacağı kararı verilir [23].

3.6. Tiroit Tedavisi

Guatr görülen hastalarda hormon salgılarında anormal bir durum olmadığı müddetçe herhangi bir tedaviye ihtiyaç yoktur.

Tiroiditte tetkik sonuçlarına göre doktor tarafından uygun bir tedavi uygulanır.

Nodüler guatrda kanser riski fazla olan veya kanser bulgularına rastlanılan hastalarda ameliyat yapılması gerekmektedir. Kanser olmayan hastalarda nodülün boyutu ve yeri önemlidir. Birden fazla nodülü olan veya nodül boyutu çok büyük olan hastalarda cerrahi yöntem tercih edilebilir. Bunun dışında küçük boyutlu ve tek nodüllü hastalarda ilaçsız takip önlemleri alınabilir veya ilaç tedavisi uygulanabilir. Bu hastalar kesinlikle iyotlu gıdaları hayatlarından çıkarmalı, iyotsuz tuz tüketmelidir [23].

Hipertiroidi hastalarına öncelikle kandaki hormon miktarlarının normal seviyeye getirilmesi amacıyla ilaç tedavisi uygulanır. 2 aylık kontrol süreçleriyle birlikte yaklaşık 1 yıl süreyle bu tedaviye devam edilir. 1 yıl sonunda hastanın durumunda bir iyileşme görülmez ise ilaç dozajı arttırılabilir veya iyod tedavisi ya da ameliyat yapılabilir [23].

Hipotiroidi tedavisi ise şimdilik ömür boyu sürecek bir ilaç tedavisidir. Bu hastalar 6 ay da bir doktor kontrolünden geçirilerek hastalık durumuna göre ilaç dozajı ayarlanır [23].

BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu araştırmada iki farklı veri grubu üzerinde Weka programı ve Matlab programı YSA toolboxında sınıflandırmalar yapılarak başarı yüzdeleri karşılaştırılmıştır. Araştırmada, 1.Grup Tiroit Verileri olarak isimlendirilen veriler Sakarya ili Kamu Hastahanelerinden alınan 300 kişiye ait tiroit verilerini içermektedir. Diğer veri grubu olan ve 2.Grup Tiroit Verileri olarak isimlendirilen veriler UCI machine learning veri tabanından alınan ve 215 kişiye ait tiroit verilerini içermektedir.

4.1. 1.Grup Tiroit Verilerinin Özellikleri

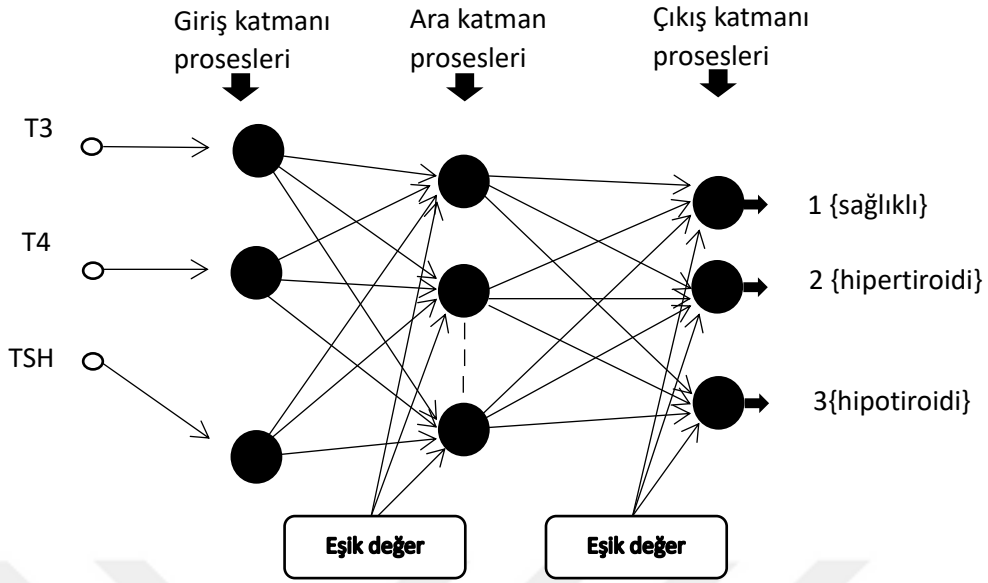
Bu araştırmada 1.Grup'ta kullanılan 300 kişinin tiroit verileri Sakarya İl Sağlık Müdürlüğünden alınan izinle Sakarya İli Kamu Hastahanelerinden elde edilmiştir.

1.grup veri setinde, tiroit bezi az çalışan hastaları gösteren “hipotiroidi”, tiroit bezi gereğinden fazla çalışan hastaları gösteren “hipertiroidi” ve normal çalışan insanları gösteren “normal” olmak üzere 3 sınıflandırma yapılmıştır. Her bir veriye ait toplam 3 özellik bulunmaktadır. Bu özellikler Tablo 4.1’de görülmektedir.

Özellik	Değer Aralığı
T3	[1.72 - 15.12]
T4	[0.63 - 37.71]
TSH value	[0 - 97.2]
Sınıf	{ 3, 2, 1 }

Tablo 4.1. 1.grup tiroit verileri için tiroit hastalığı tanısında incelenen özellikler ve değer aralıkları.

1.grup veri setinin ağ topolojisi Şekil 4.1’de görülmektedir. Bu veri setinde 1. sınıf olarak temsil edilen 100 adet sağlıklı kişi, 2. sınıf olarak temsil edilen 100 hipertiroidi ve 3.sınıf olarak temsil edilen 100 hipotiroidi hastası olmak üzere toplamda 300 kişiye ait Tablo 4.1’deki özellikler incelenmiştir. İncelenen bu üç özelliğe ait normal kabul edilen değerler aralığı Tablo 4.2’de verilmiştir.



Özellik	Normal Kabul Edilen Değer Aralığı
TSH	0.35 - 4.94 mIU/l
sT3	2.62 - 5.69 pm/l
sT4	9.00 - 19.04 pm/l

Tablo 4.2. 1.Grup verilerinde incelenen özelliklere ait normal kabul edilen değer aralıkları.

4.1.1. 1. grup tiroit verilerinin Weka'da ÇKA ile sınıflandırılması

Weka'da 1. Grup ve 2. Grup tiroit verileriyle yapılan tüm uygulamalarda, eğitim seti tüm verilerin %66'sı olarak alınmış ve geriye kalan veriler test verileri olarak belirlenmiştir.

Weka'da çok katmanlı algılayıcı algoritması, geri yayılım olarak gradyan inişine dayalı yinelemeli algoritmayı, aktivasyon fonksiyonu olarak da sigmoid fonksiyonunu kullanmaktadır. Weka, varsayılan olarak öğrenme katsayısını 0.3, momentumu da 0.2 olarak belirlemiş ve tavsiye etmiştir [24].

Weka'da ÇKA ile;

öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.3'da,

öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.4’de,

öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.5’de ve,

öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.6’da verilmektedir.

Tablo 4.3’de farklı ara katman sayıları ve nöronlarla yapılan 8 denemeden 1. gizli katman nöron sayısı 5, 2. gizli katman nöron sayısı 15 ve 1. gizli katman nöron sayısı 5, 2. gizli katman nöron sayısı 19 olan denemelerde en yüksek doğru sınıflandırma yüzdesi olan 95 değeri elde edilmiştir.

Tablo 4.4’de farklı ara katman sayıları ve nöronlarla yapılan 8 denemenin içerisinde en başarılı sınıflandırma yüzdesi olan 92 değeri, 1 ara katman ve 35 nöron ile elde edilmiştir.

Tablo 4.3 ve Tablo 4.4 dikkate alınarak değerlendirildiğinde Weka’da çok katmanlı algılayıcı algoritmasında farklı sayıda ara katman kullanımı ile öğrenme katsayısının 0.3 ve momentumun 0.2 olması durumunda, 1. gizli katman nöron sayısının 5, 2. gizli katman nöron sayısının 15 ve 1. gizli katman nöron sayısının 5, 2. gizli katman nöron sayısının 19 olduğu durumlarda en doğru sonuç elde edilmiştir. Bu sınıflandırma sonucunda ulaşılan en yüksek doğruluk değeri % 95’dir.

Tablo 4.5’de farklı ara katman sayıları ve nöronlarla yapılan 8 denemenin içerisinde en başarılı sınıflandırma yüzdesi olan 99 değeri gizli katmandaki nöron sayısının 5 olduğu durumda elde edilmiştir.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.3	0.2	500	84
8	-	-	0.3	0.2	500	85
35	-	-	0.3	0.2	500	93
45	-	-	0.3	0.2	500	86
5	3	-	0.3	0.2	500	94.11
5	15	-	0.3	0.2	500	95
5	19	-	0.3	0.2	500	95
5	15	5	0.3	0.2	500	32

Tablo 4.3. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.2	0.8	500	81.3
8	-	-	0.2	0.8	500	82.3
35	-	-	0.2	0.8	500	92
45	-	-	0.2	0.8	500	82
5	3	-	0.2	0.8	500	62.7
5	15	-	0.2	0.8	500	83.3
5	19	-	0.2	0.8	500	69.6
5	15	5	0.2	0.8	500	38

Tablo 4.4. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.3	0.2	21 000	99
8	-	-	0.3	0.2	21 000	93
35	-	-	0.3	0.2	21 000	96
45	-	-	0.3	0.2	21 000	94
5	3	-	0.3	0.2	21 000	98
5	15	-	0.3	0.2	21 000	98
5	19	-	0.3	0.2	21 000	98
5	15	5	0.3	0.2	21 000	97

Tablo 4.5. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.2	0.8	21 000	92
8	-	-	0.2	0.8	21 000	95
35	-	-	0.2	0.8	21 000	98
45	-	-	0.2	0.8	21 000	99
5	3	-	0.2	0.8	21 000	100
5	15	-	0.2	0.8	21 000	97
5	19	-	0.2	0.8	21 000	97
5	15	5	0.2	0.8	21 000	98


Tablo 4.6. 1. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.

Tablo 4.6’da farklı ara katman sayıları ve nöronlarla yapılan 8 denemenin arasında % 100 doğru sınıflandırma değeri 1. gizli katmanda 5 ve 2. gizli katmanda 3 nöron kullanılması durumunda elde edilmiştir.

Tablo 4.5 ve Tablo 4.6 dikkate alınarak değerlendirildiğinde öğrenme katsayısının 0.2 ve momentumun 0.8 olması durumunda en yüksek doğruluk yüzdesi olan 100 değeri elde edilmiştir.

Tablo 4.3, 4.4, 4.5 ve 4.6 birlikte değerlendirildiğinde öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olması durumunda en doğru sonuca ulaşıldığı belirlenmiştir.

Tablo 4.6’daki en başarılı sonuca ait ağız topolojisi Şekil 4.2’de gösterilmiştir.



Şekil 4.2. Tablo 4.6’deki en başarılı sonuca ait ÇKA ağ topolojisi.

Tablo 4.6’da Weka’da 1. gizli katmanda 5 ve 2. gizli katmanda 3 nöron kullanılarak yapılan deneme sonucunda elde edilen % 100’lük başarı sonucunun yürütme bilgileri ve Weka sonuç ekranı bilgisi aşağıda verilmiştir.

=== Run information ===

Scheme:weka.classifiers.functions.MultilayerPerceptron -L 0.2 -M 0.8 -N 21000 -V 0 -

S 0 -E 20 -H "5, 3" -G -R

Relation: sakaryatiroit

Instances: 300

Attributes: 4

TSH

T3

T4

Class

Test mode:split 66.0% train, remainder test

=== Classifier model (full training set) ===

Sigmoid Node 0

Inputs Weights

Threshold -10.28773892125182

Node 8 10.981898492295343

Node 9 4.421652211810602

Node 10 0.4913383336351275

Sigmoid Node 1

Inputs Weights

Threshold 4.623481328043151

Node 8 -7.1913259142244526

Node 9 -5.261106588331236

Node 10 -3.6614484193422125

Sigmoid Node 2

Inputs Weights

Threshold -4.623059631741695

Node 8 -10.40174438719148

Node 9 5.201841780542601

Node 10 3.6795000640694497

Sigmoid Node 3

Inputs Weights

Threshold -291.9042253152762

Attrib TSH -292.41018270459716

Attrib T3 -5.403948831664757

Attrib T4 2.9214518938993406

Sigmoid Node 4

Inputs Weights

Threshold -181.4479823985831

Attrib TSH -203.65892396128592

Attrib T3 33.28029850135296

Attrib T4 -2.3832990180925324

Sigmoid Node 5

Inputs Weights

Threshold -139.74332282877504

Attrib TSH -93.18399077724692

Attrib T3 -63.43822901767963

Attrib T4 -5.367459733199663

Sigmoid Node 6

Inputs Weights

Threshold -167.4425684367513

Attrib TSH -185.97523549263147

Attrib T3 -0.07570265354141745

Attrib T4 9.597052525722722

Sigmoid Node 7

Inputs Weights

Threshold -91.02292149784776

Attrib TSH -114.95540791940574

Attrib T3 59.53355301960934

Attrib T4 -2.4925790502664094

Sigmoid Node 8

Inputs Weights

Threshold 5.320110023592699

Node 3 -48.83001317430335

Node 4 -64.37156363417034

Node 5 -8.337001437505712

Node 6 -65.4155487930644

Node 7 2.0374823333906895

Sigmoid Node 9

Inputs Weights

Threshold 50.18582068577335

Node 3 -31.55299677150706

Node 4 -23.721388693253452

Node 5 -24.979669520788974

Node 6 -20.61053352524984

Node 7 -16.533450694768078

Sigmoid Node 10

Inputs Weights

Threshold 64.90216812593147

Node 3 -30.364667609204815

Node 4 -20.025528514288197

Node 5 -26.925030759207793

Node 6 -31.79858804960405

Node 7 -18.875462450984884

Class 3

Input

Node 0

Class 2

Input

Node 1

Class 1

Input

Node 2

Time taken to build model: 27.02 seconds

==== Evaluation on test split ====

==== Summary ====

Correctly Classified Instances	102	100	%
Incorrectly Classified Instances	0	0	%
Kappa statistic	1		
Mean absolute error	0.0108		
Root mean squared error	0.0406		
Relative absolute error	2.431	%	
Root relative squared error	8.5801	%	
Total Number of Instances	102		

==== Detailed Accuracy By Class ====

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	1	0	1	1	1	1	3
	1	0	1	1	1	1	2
	1	0	1	1	1	1	1
Weighted Avg.	1	0	1	1	1	1	

==== Confusion Matrix ====

a b c <-- classified as

39 0 0 | a = 3

0 30 0 | b = 2

0 0 33 | c = 1

4.1.2. 1.grup tiroit verilerinin Weka'da Knn ile sınıflandırılması

Tablo 4.7'de verilen K-en yakın komşu algoritması ile yapılan sınıflandırma sonuçlarından, en yüksek doğruluk değerinin % 84.3137 olarak k=6 olması durumunda elde edildiği görülmektedir.

K Sayısı	Doğru Sınıflandırma Yüzdesi (%)
1	81.3725
2	82.3529
3	77.451
4	81.3725
5	82.3529
6	84.3137

Tablo 4.7. k-en yakın komşu algoritması uygulama sonuçları.

4.1.3. 1.grup tiroit verilerinin Matlab'da Ysa Toolbox'ı ile sınıflandırılması

Matlab'da Ysa Toolbox'ı kullanılarak sınıflandırılan 1.grup tiroit verilerinin eğitim ve test setindeki kişi sayıları Tablo 4.8'de görülmektedir.

	Eğitim seti kişi sayısı	Test seti kişi sayısı
Sımf 1: Sağlıklı kişi	70	30
Sımf 2: Hipertiroidi	70	30
Sımf 3: Hipotiroidi	70	30
Toplam	210	90

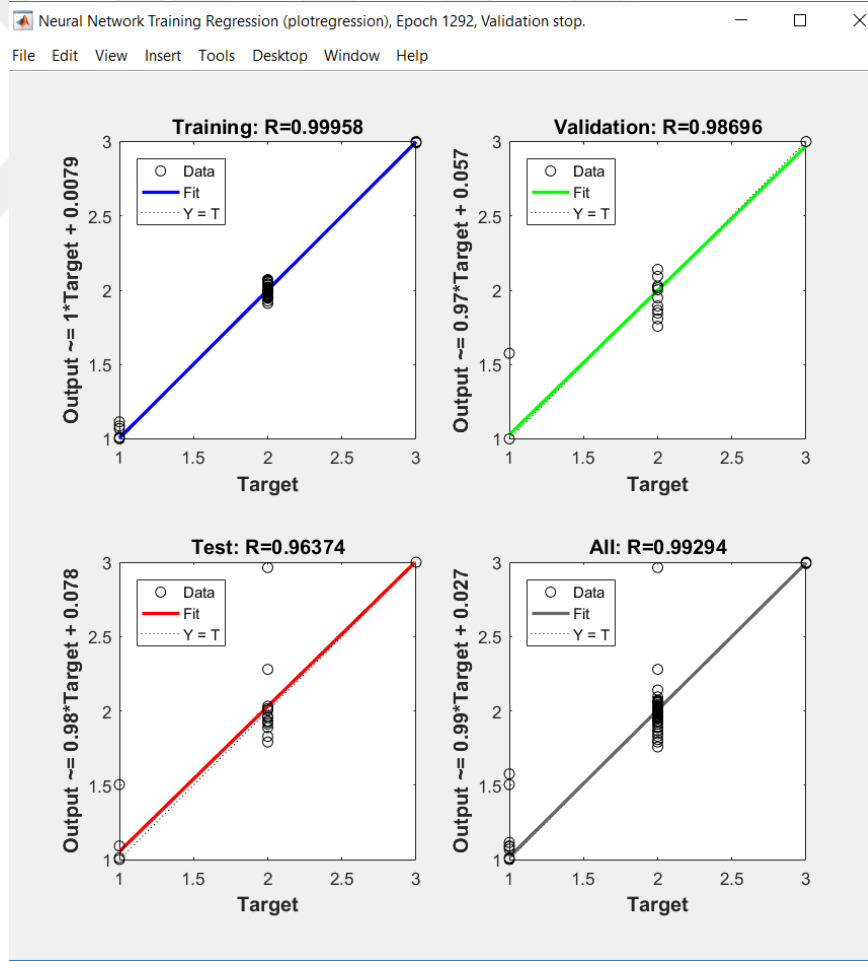
Tablo 4.8. Matlab uygulamasında kullanılan 1.Grup tiroit verilerinde eğitim ve test setine ait veri sayıları.

Ağ Tipi Feed-forward backprop, Adaptasyon Öğrenme Fonksiyonu(Adaption Learning Function) GDM, Transfer Fonksiyonu(Transfer Function) Tansig ve gizli katman nöron sayısı 40 olarak belirlendiğinde yapılan denemelerde en başarılı Eğitim Fonksiyonu(Training Function) MSE performans ölçütüne göre % 99.2 oranıyla Levenberg-Marquardt (LM) fonksiyonu olduğu Tablo 4.9'da görülmektedir. LM fonksiyonu MAPE değerlendirme ölçütüne göre %97 doğruluk oranıyla en başarılı test sonucunu vermiştir.


Eğitim Fonksiyonu	Eğitim Süresi (sn.)	Devir Sayısı	Eğitim Başarısı	Test Başarısı
LM	5	1292	%99.2	%97
CGF	4	611	%97.8	%92
CGP	2	808	%97.4	%91
BFG	15	1638	%97.5	%90
CGB	3	187	%92	%90
SCG	2	1926	%96.2	%89
OSS	4	1588	%93	%88
GDA	24	20000	%86	%74
GDX	3	2292	%79	%71
RP	7	2616	%82.4	%70
GD	23	20000	%81	%70
GDM	25	20000	%79	%68

Tablo 4.9. Eğitim fonksiyonu performanslarının karşılaştırılması.


Tablo 4.9'daki LM eğitim fonksiyonu ile yapılan en başarılı denemeye ait Yapay Sinir Ağının Eğitim Regresyon analizi grafikleri (Artificial Neural Network Training Regression analysis charts) Şekil 4.3'de, iterasyona bağlı performans grafiği Şekil 4.4'de, Eğitim Durumu grafiği ise Şekil 4.5'de görülmektedir.



Şekil 4.3. Tablo 4.9'daki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.



Şekil 4.4. Tablo 4.9'daki en başarılı sonuca ait sinir ağıнын iterasyona bağılı performans grafiğı.



Şekil 4.5. Tablo 4.9'daki en başarılı sonuca ait sinir ağı eğitim durumu grafiğı.

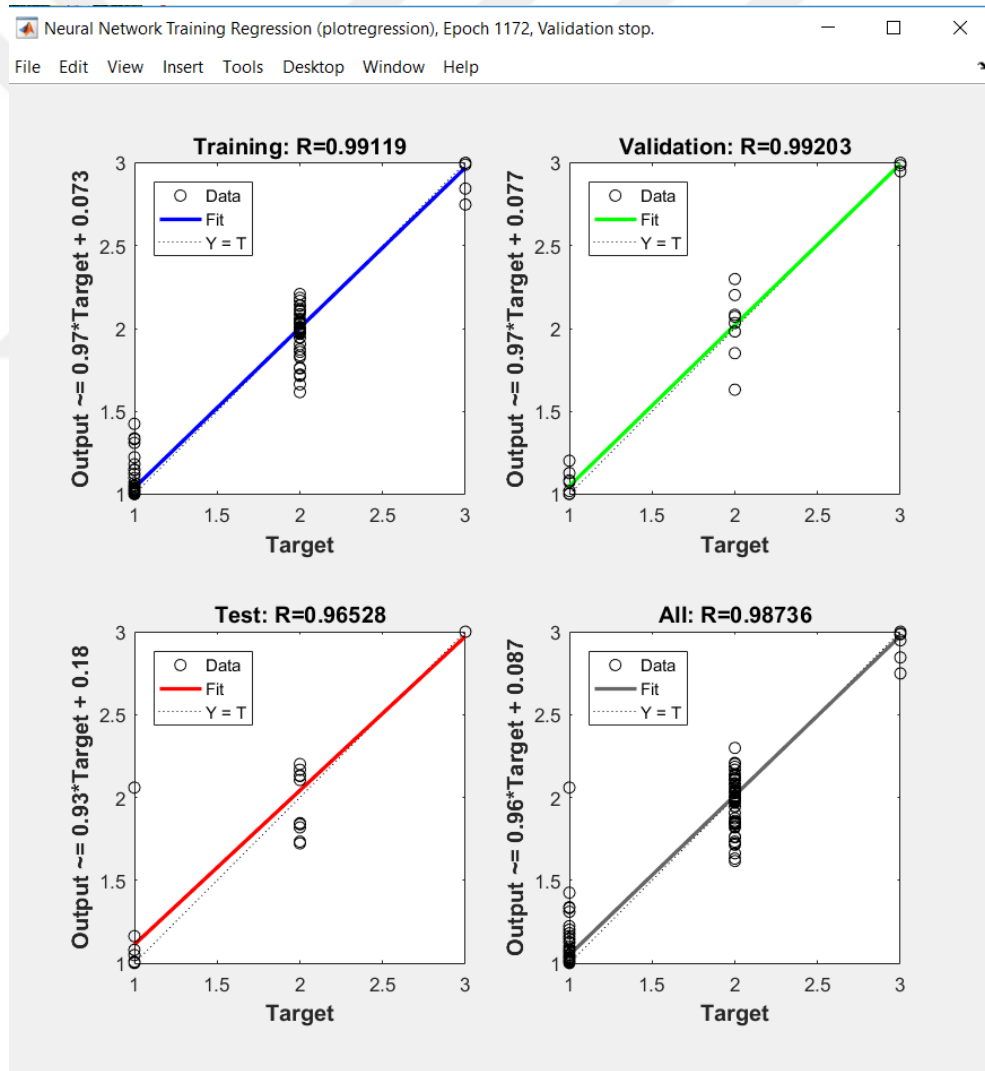
Eğitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Transfer Fonksiyonu Tansig ve gizli katman nöron sayısı 40 olarak belirlendiğinde yapılan denemelerde en başarılı Ağ Tipi MSE performans ölçütüne göre % 98.7 oranıyla Feed-forward backprop ağı olduğu Tablo 4.10'da görülmektedir. Feed-forward backprop ağı MAPE

değerlendirme ölçütüne göre % 95.3 doğruluk oranıyla en başarılı test sonucunu vermiştir.

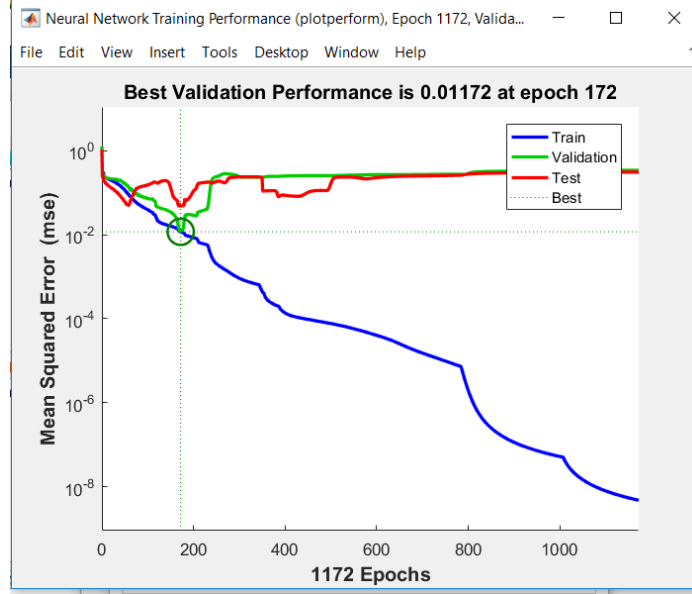
Ağ Tipi	Eğitim Süresi(sn.)	Devir Sayısı	Eğitim Başarısı	Test Başarısı
Feed forward	4	1172	% 98.7	% 95.3
NARX	74	1496	% 98	% 95
Elman	709	1145	% 96	% 93
Layer recurrent	741	1128	% 95	% 93
Cascade	4	1042	% 97.6	% 90

Tablo 4.10. Ağ tiplerinin performanslarının karşılaştırılması.

Tablo 4.10'daki en başarılı denemeye ait Yapay Sinir Ağının Eğitim Regresyon analizi grafikleri Şekil 4.6'da, iterasyona bağlı performans grafiği ise Şekil 4.7'de görülmektedir.



Şekil 4.6. Tablo 4.10'daki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.



Şekil 4.7. Tablo 4.10'daki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.

Eğitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve gizli katman nöron sayısı 40 olarak belirlendiğinde yapılan denemelerde en başarılı transfer fonksiyonu MSE performans ölçütüne göre % 98.7 oranıyla Tansig olduğu Tablo 4.11'de görülmektedir.

Transfer Fonksiyonu	Eğitim Süresi (sn.)	Devir Sayısı	Eğitim Başarısı	Test Başarısı
Tansig	4	1057	% 98.7	% 95
Logsig	4	1156	% 97.6	% 91
Purelin	1	28	% 73	% 68

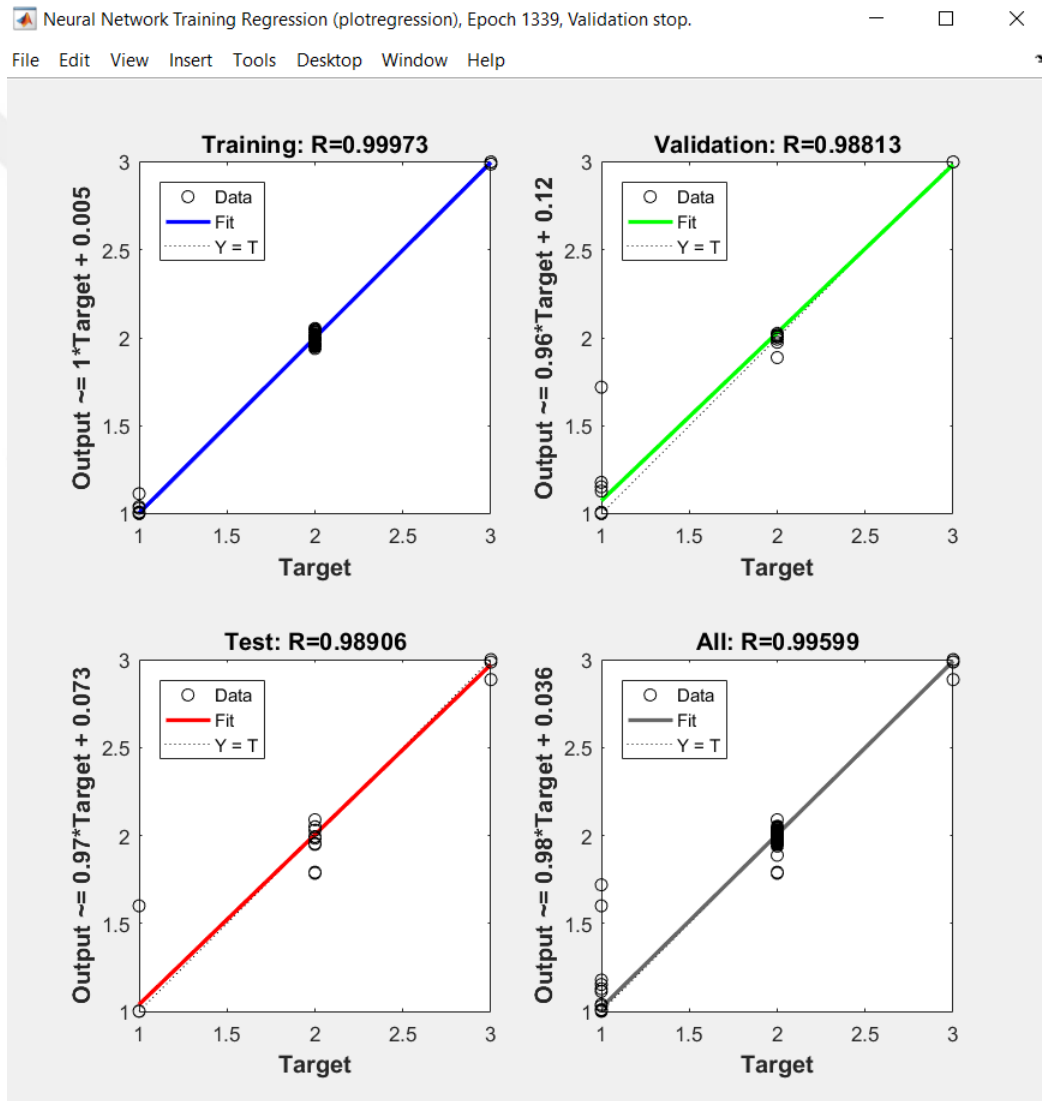
Tablo 4.11. Transfer fonksiyonlarının performanslarının karşılaştırılması.

Tablo 4.12'de görüldüğü gibi, Eğitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve Transfer Fonksiyonu Tansig olarak belirlendiğinde yapılan denemelerde MSE performans ölçütüne göre en yüksek başarı oranı % 99.5 ile gizli katman nöron sayısının 15 olduğu denemede bulunmuştur. Test performansı da MAPE ölçütüne göre 15 nöronla yapılan denemede en yüksek oran olan 98.4 değerini vermiştir.


Tablo 4.12'deki en başarılı denemeye ait Yapay Sinir Ağının Eğitim Regresyon analizi grafikleri Şekil 4.8'de, iterasyona bağlı performans grafiği Şekil 4.9'da, Eğitim Durumu grafiği ise Şekil 4.10'da görülmektedir.

Gizli Katman Nöron Sayısı	Eğitim Süresi (sn.)	Devir Sayısı	Eğitim Başarısı	Test Başarısı
5	6	3688	% 99.9	% 96
8	2	1036	% 97	% 90
10	2	1117	% 98	% 93
15	3	1339	% 99.5	% 98.4
20	3	1148	% 99.3	% 95
25	4	1217	% 97.2	% 94
30	5	1523	% 99	% 91
35	3	1047	% 98.2	% 92
41	4	1030	% 97.5	% 89
45	4	1053	% 96.9	% 91

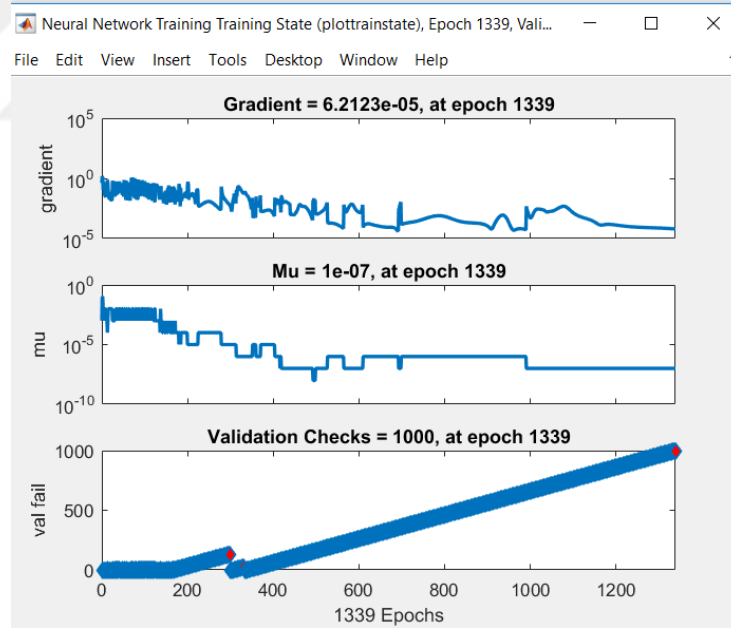
Tablo 4.12. Gizli katman nöron sayılarının karşılaştırılması.



Şekil 4.8. Tablo 4.12'deki en başarılı sonuca ait sinir ağınnın eğitim regresyon analizi grafikleri.



Şekil 4.9. Tablo 4.12'deki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.



Şekil 4.10. Tablo 4.12'deki en başarılı sonuca ait sinir ağı eğitim durumu grafiği.

1.Grup verileriyle yapılan tüm uygulama sonuçları birlikte değerlendirildiğinde, Knn algoritmasının % 84 civarında, çok katmanlı algılayıcı ağının % 100' e yakın doğruluk oranı ile sonuçlar vermesi çok katmanlı algılayıcı ağının iyi bir öğrenme gerçekleştirdiğini göstermektedir.

4.2. 2.Grup Tiroit Verilerinin Özellikleri

Bu arařtırmada 2.grup'ta kullanılan veriler Avustralya James Cook Üniversitesi Matematik ve İstatistik Bölümünden Danny Cooman'a aittir. Bu veriler UCI machine learning veri tabanında bulunmaktadır. Bu veri grubunda toplam 215 kişiye ait tiroit verisi bulunmaktadır. Bu örneklerden 35'i hipertiroidi, 30'u hipotiroidi hastası ve 150'si sağlıklı insanların verilerinden oluşmaktadır.

Bu 2.grup veri setinde, tiroit bezi az çalışan hastaları gösteren "hipotiroidi", tiroit bezi gereğinden fazla çalışan hastaları gösteren "hipertiroidi" ve normal çalışan insanları gösteren "normal" olmak üzere 3 sınıflandırma yapılmıştır. Her bir veriye ait Tablo 4.13'de gösterilen 5 özellik bulunmaktadır.

Özellik	Değer Aralığı
T3 resin	[65, 144]
Thyroxin	[0.5, 25.3]
Triiodothyronine	[0.2, 10.0]
Thyroidstimulating	[0.1, 56.4]
TSH value	[-0.7, 56.3]
Class	{ 3, 2, 1 }

Tablo 4.13. 2.grup tiroit verileri için tiroit hastalığı tanısında incelenen değerler.

Hastalar, Tablo 4.13'deki 5 özellikten yola çıkılarak 3 sınıfa ayrılmaktadır. Bu sınıflar; "Sınıf:1 (normal)" tiroit hastası olmayan insanları temsil ederken, "Sınıf:2 (hipertiroit)" hipertiroidi hastası olan insanları, "Sınıf:3 (hipotiroit)" hipotiroidi hastası olan insanları temsil etmektedir.

4.2.1. 2.grup tiroit verilerinin Weka'da ÇKA Ağı ile sınıflandırılması

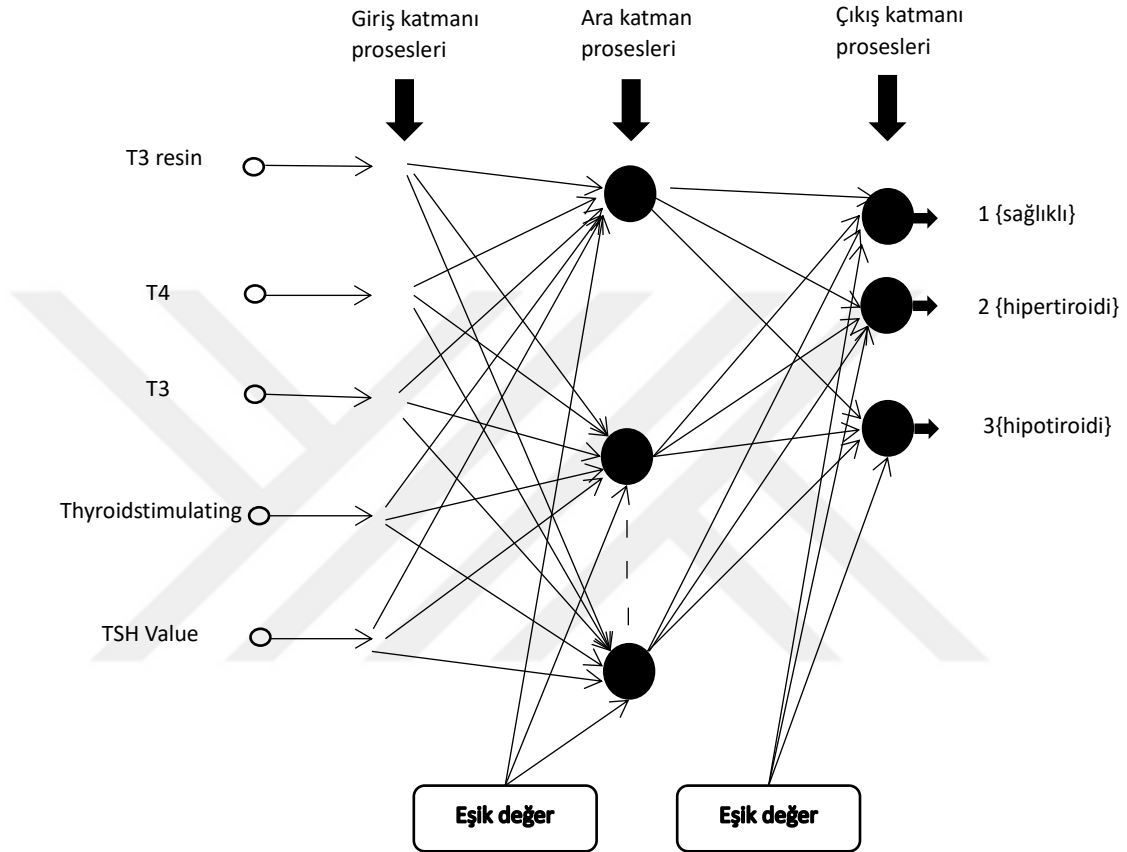
2.grup verilerinin ÇKA ağı ağ topolojisi Şekil 4.11'de verilmiştir. 2.grup verileriyle Weka'da ÇKA ile;

öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.14'de,

öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.15'de,

öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.16'da ve,

öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları Tablo 4.17'de verilmektedir.



Tablo 4.14'de farklı ara katman sayıları ve nöronlarla yapılan 5 denemenin dördünde en yüksek doğru sınıflandırma yüzdesi olan 94.5205 değeri elde edilmiştir.

Tablo 4.15'de farklı ara katman sayıları ve nöronlarla yapılan 5 denemenin dördünde en yüksek doğru sınıflandırma yüzdesi olan 94.5205 değeri elde edilmiştir.

Tablo 4.14 ve Tablo 4.15 dikkate alınarak değerlendirildiğinde Weka'da Multilayer Perceptron algoritmasında farklı sayıda ara katman kullanımı ile öğrenme katsayısının 0.2 ve momentumun 0.8 olması durumunda en doğru sonuç elde edilmiştir. Bu sınıflandırma sonucunda ulaşılan en yüksek doğruluk oranı % 94.5205'dir.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.3	0.2	500	94.5205
8	-	-	0.3	0.2	500	94.5205
5	3	-	0.3	0.2	500	94.5205
5	19	-	0.3	0.2	500	94.5205
5	15	5	0.3	0.2	500	63.01

Tablo 4.14. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.2	0.8	500	94.5205
8	-	-	0.2	0.8	500	94.5205
5	3	-	0.2	0.8	500	94.5205
5	19	-	0.2	0.8	500	94.5205
5	15	5	0.2	0.8	500	76.7121

Tablo 4.15. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 500 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.3	0.2	21 000	94.5205
8	-	-	0.3	0.2	21 000	94.5205
5	3	-	0.3	0.2	21 000	94.5205
5	19	-	0.3	0.2	21 000	94.5205
5	15	5	0.3	0.2	21 000	76.7123

Tablo 4.16. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.3, momentumun 0.2 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.

1.Gizli Katman Nöron Sayısı	2.Gizli Katman Nöron Sayısı	3.Gizli Katman Nöron Sayısı	Öğrenme Katsayısı	Momentum	Deneme Sayısı	Doğru Sınıflandırma Yüzdesi (%)
5	-	-	0.2	0.8	21 000	94.5205
8	-	-	0.2	0.8	21 000	94.5205
5	3	-	0.2	0.8	21 000	94.5205
5	19	-	0.2	0.8	21 000	94.5205
5	15	5	0.2	0.8	21 000	94.5205

Tablo 4.17. 2. Grup verileriyle ÇKA ile öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olduğu durumda yapılan sınıflandırma sonuçları.


Tablo 4.16’da öğrenme katsayısı 0.3, momentum 0.2 ve deneme sayısı 21000 olarak belirlendiğinde farklı ara katman sayıları ve nöronlarla yapılan 5 denemenin dördünde en yüksek doğru sınıflandırma yüzdesi olan 94.5205 değeri elde edilmiştir.

Tablo 4.17’de öğrenme katsayısı 0.2, momentum 0.8 ve deneme sayısı 21000 olarak belirlendiğinde farklı ara katman sayıları ve nöronlarla yapılan 5 denemenin tümünde en yüksek doğru sınıflandırma yüzdesi olan 94.5205 değeri elde edilmiştir.

Tablo 4.16 ve Tablo 4.17 birlikte değerlendirildiğinde öğrenme katsayısının 0.2 ve momentumun 0.8 olması durumunda yapılan tüm denemelerde aynı doğruluk yüzdesi değeri olan 94.5205 değeri elde edilmiştir.

Tablo 4.14, 4.15, 4.16 ve 4.17 dikkate alınarak değerlendirildiğinde öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olması durumunda en doğru sonuca ulaşıldığı belirlenmiştir. Bu değerlerle yapılan tüm denemelerde aynı doğruluk yüzdesi değeri olan 94.5205 değeri elde edilmiştir.

Tablo 4.17'deki 1.gizli katmanda 5, 2.gizli katmanda 3 nöron kullanılarak yapılan denemenin ağ topolojisi Şekil 4.12'de verilmiştir.



Şekil 4.12. Tablo 4.17' deki 5,3 nöron sayısı ile yapılan denemenin ağ topolojisi.

4.2.2. 2.grup tiroit verilerinin Weka'da Knn ile sınıflandırılması

Weka'da k-en yakın komşu (Knn) algoritması ile yapılan sınıflandırma sonuçları Tablo 4.18'de verilmiştir.

K Sayısı	Doğru Sınıflandırma Yüzdesi (%)
1	91.7808
2	91.7808
3	93.1507
4	93.1507
5	91.7808

Tablo 4.18. k-en yakın komşu algoritması uygulama sonuçları.

K-en yakın komşu algoritması ile yapılan sınıflandırma sonucunda en yüksek doğruluk değeri % 93.1507 olarak k=3 ve k=4 olması durumunda elde edilmiştir.

4.2.3. 2.grup tiroit verilerinin Matlab’da Ysa Toolbox’ı ile sınıflandırılması

Matlab’da Ysa Toolbox’ı kullanılarak sınıflandırılan 2.grup tiroit verilerinin eğitim ve test setindeki kişi sayıları Tablo 4.19’da görülmektedir.

	Eğitim seti kişi sayısı	Test seti kişi sayısı
Sınıf 1: Sağlıklı kişi	140	10
Sınıf 2: Hipertiroidi	25	10
Sınıf 3: Hipotiroidi	20	10
Toplam	185	30

Tablo 4.19. Matlab uygulamasında kullanılan 2.Grup tiroit verilerinde eğitim ve test setine ait veri sayıları.

Ağ Tipi Feed-forward backprop, Adaptasyon Öğrenme Fonksiyonu GDM, Transfer Fonksiyonu Tansig ve gizli katman nöron sayısı 40 olarak belirlendiğinde yapılan denemelerde en başarılı Eğitim Fonksiyonu, MSE performans ölçütüne göre % 99.2 oranıyla Levenberg-Marquardt(LM) fonksiyonu olduğu Tablo 4.20’de görülmektedir. LM fonksiyonu MAPE değerlendirme ölçütüne göre % 98 doğruluk oranıyla en başarılı test sonucunu vermiştir.

Eğitim Fonksiyonu	Eğitim Süresi (sn.)	Devir Sayısı	Eğitim Başarısı	Test Başarısı
LM	3	251	% 99.2	% 98
CGF	3	576	% 97.6	% 98
CGP	4	855	% 97.3	% 98
GDA	14	5790	% 95	% 96
GD	49	20000	% 94	% 96
SCG	3	1057	% 94.3	% 95
GDX	3	1255	% 92	% 95
RP	3	1420	% 97.9	% 91
CGB	1	284	% 96	% 91
GDM	26	10000	% 93	% 91
BFG	8	283	% 89	% 91
OSS	1	2	% 72	% 62

Tablo 4.20. Eğitim fonksiyonu (training functions) performanlarının karşılaştırılması.

Eđitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Transfer Fonksiyonu Tansig ve gizli katman nöron sayısı 40 olarak belirlendiđinde yapılan denemelerde en başarılı Ağ Tipi MSE performans ölçütüne göre % 99 oranıyla Feed-forward backprop ađı olduđu Tablo 4.21’de görölmektedir. Feed-forward backprop ađı MAPE deđerlendirme ölçütüne göre % 98 dođruluk oranıyla en başarılı test sonucunu vermiřtir.

Ađ Tipi	Eđitim Süresi(sn.)	Devir Sayısı	Eđitim Başarısı	Test Başarısı
Feed forward	2	242	% 99	% 98
Cascade	1	139	% 97.6	% 97
Layer recurrent	310	377	% 96	% 97
NARX	60	551	% 96	% 97
Elman	337	412	% 99	% 91

Tablo 4.21. Ağ tiplerinin performanslarının karşılařtırılması.

Eđitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve gizli katman nöron sayısı 40 olarak belirlendiđinde yapılan denemelerde en başarılı Transfer Fonksiyonu MSE performans ölçütüne göre % 99 oranıyla Tansig olduđu Tablo 4.22’de görölmektedir.

Aktivasyon Fonksiyonu	Eđitim Süresi (sn.)	Devir Sayısı	Eđitim Başarısı	Test Başarısı
Tansig	1	311	% 99	% 85
Logsig	1	333	% 97	% 81
Purelin	1	37	% 92	% 72

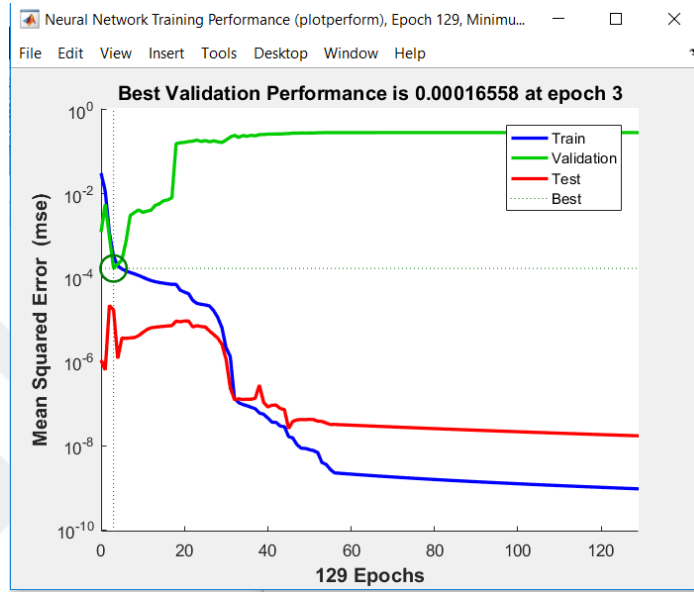
Tablo 4.22. Transfer fonksiyonlarının performanslarının karşılařtırılması.

Tablo 4.23’de Eđitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve Transfer Fonksiyonu Tansig olarak belirlendiđinde yapılan denemelerde MSE performans ölçütüne göre en yüksek başarı oranı % 99.9 ile gizli katman nöron sayısının 5 olduđu denemede bulundu. Test performansı da MAPE ölçütüne göre 5 nöronla yapılan denemede en yüksek oran olan 100 deđerini vermiřtir.

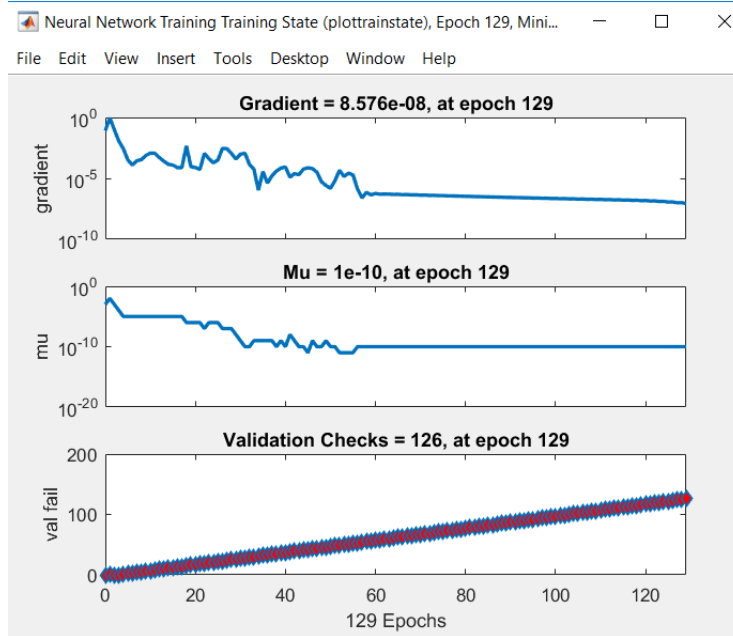
Gizli Katman Nöron Sayısı	Eđitim Süresi (sn.)	Devir Sayısı	Eđitim Başarısı	Test Başarısı
5	1	129	% 99.9	% 100
8	1	22	% 77	% 81
10	2	397	% 94	% 99
15	1	183	% 95.9	% 96
20	1	188	% 74	% 83
25	1	320	% 99.3	% 94
30	1	305	% 98	% 95
35	2	463	% 98	% 96
41	2	321	% 95.8	% 95
45	1	326	% 96	% 94

Tablo 4.23. Gizli katman nöron sayılarının karşılařtırılması.

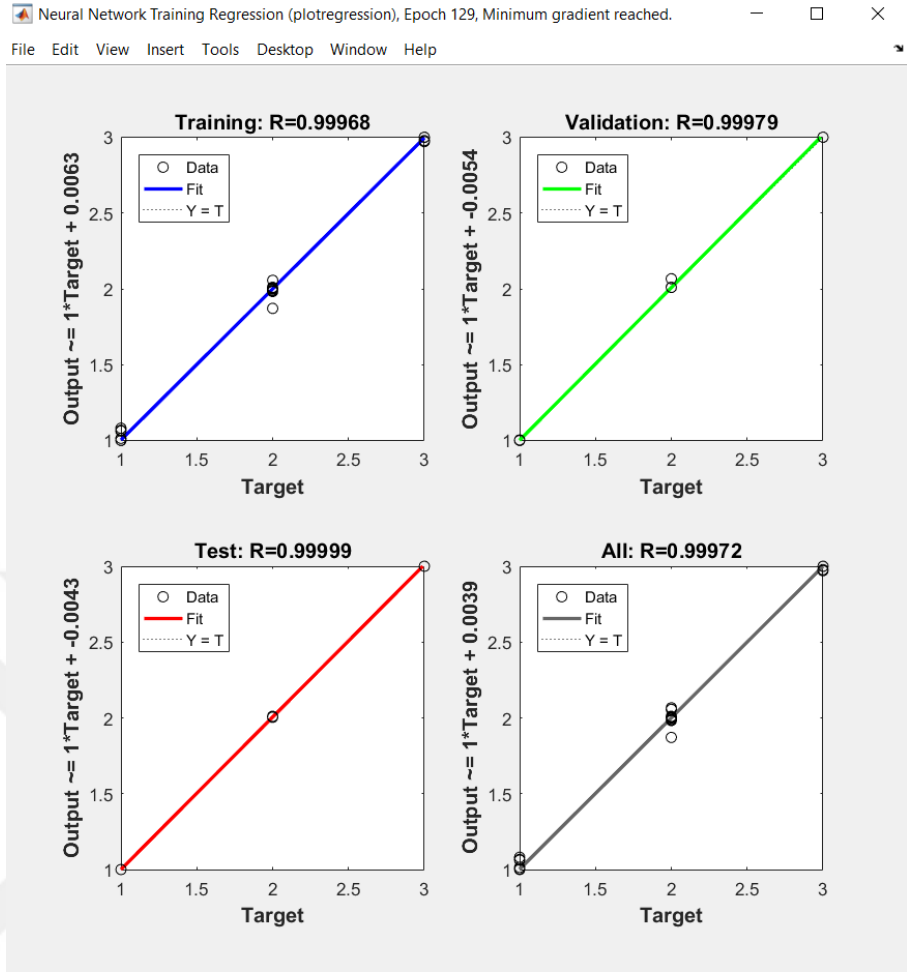
Tablo 4.23'deki en başarılı denemeye ait Yapay Sinir Ağının iterasyona bağlı performans grafiği Şekil 4.13'de, Eğitim Durumu grafiği Şekil 4.14'de ve Eğitim Regresyon analizi grafikleri Şekil 4.15'de görülmektedir. 2.Grup verileriyle yapılan tüm uygulamalar birlikte değerlendirildiğinde çok katmanlı algılayıcı ağının Knn algoritmasına göre daha başarılı sonuçlar verdiği görülmüştür.



Şekil 4.13. Tablo 4.23'deki en başarılı sonuca ait sinir ağının iterasyona bağlı performans grafiği.



Şekil 4.14. Tablo 4.23'deki en başarılı sonuca ait sinir ağı eğitim durumu grafiği.



Şekil 4.15. Tablo 4.23'deki en başarılı sonuca ait sinir ağının eğitim regresyon analizi grafikleri.

BÖLÜM 5. TARTIŞMA VE SONUÇ

Bu çalışmada tiroit hastalığının teşhisinde yapay sinir ağları teknolojisi kullanımı incelenmiştir. Çalışmada farklı kaynaklardan alınan iki ayrı veri grubu kullanılmıştır. Weka programı ve Matlab programı Yapay Sinir Ağları Toolbox'ında farklı öğrenme yöntemleri ile veri grupları eğitilerek sonuçlar analiz edilmiştir.

1. Grup Veriler de Weka'da ÇKA algoritması ile yapılan sınıflandırma sonucunda öğrenme katsayısının 0.2, momentumun 0.8, deneme sayısının 21000 ve gizli katman nöron sayısının 5-3 olması durumunda % 100 oranıyla en doğru sonuca ulaşıldığı belirlenmiştir.

1. Grup Veriler de K-en yakın komşu algoritması ile yapılan sınıflandırma sonucunda ise en yüksek doğruluk değeri % 84.3137 olarak k=6 olması durumunda elde edilmiştir.

1. Grup Matlab denemelerinde Eğitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve Transfer Fonksiyonu Tansig olarak belirlendiğinde, yapılan denemelerde MSE performans ölçütüne göre en yüksek başarı oranı % 99.5 ile gizli katman nöron sayısının 15 olduğu denemede bulunmuştur. Test performansı da MAPE ölçütüne göre 15 nöronla yapılan denemede en yüksek oran olan 98.4 değerini vermiştir.

2. Grup Veriler de Weka'da ÇKA algoritması ile yapılan sınıflandırma sonucunda öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olması durumunda en doğru sonuca ulaşıldığı belirlenmiştir. Bu değerlerle yapılan 5 denemenin beşinde de aynı doğruluk yüzdesi değeri olan 94.5205 değeri elde edilmiştir. Bu sınıflandırma sonucunda ÇKA algoritması hipotiroidi hastası olan 12 kişi içerisinde 2 kişiyi yanlışlıkla sağlıklı olarak sınıflandırmış ve sağlıklı olan 46 kişiden 2'sini de yanlışlıkla hipertiroidi sınıfında göstermiştir. 15 hipertiroidi hastasını ise hatasız bir şekilde sınıflandırmıştır.

2.Grup Veriler de K-en yakın komşu algoritması ile yapılan sınıflandırma sonucunda ise en yüksek doğruluk değeri % 93.1507 olarak k=3 ve k=4 olması durumunda elde edilmiştir.

2.Grup Matlab denemelerinde Eğitim Fonksiyonu LM, Adaptasyon Öğrenme Fonksiyonu GDM, Ağ Tipi Feed-forward backprop ve Transfer Fonksiyonu Tansig olarak belirlendiğinde yapılan denemelerde MSE performans ölçütüne göre en yüksek başarı oranı % 99.9 ile gizli katman nöron sayısının 5 olduğu denemede bulundu. Test performansı da MAPE ölçütüne göre 5 nöronla yapılan denemede en yüksek oran olan 100 değerini vermiştir.

Weka ile yapılan denemelerde öğrenme katsayısının 0.2, momentumun 0.8 ve deneme sayısının 21000 olması durumunda daha başarılı sonuçlar elde edilmiştir.

Matlab ile yapılan tüm denemelerde Eğitim Fonksiyonunun LM, Adaptasyon Öğrenme Fonksiyonunun GDM, Ağ Tipinin Feed-forward backprop ve Transfer Fonksiyonunun Tansig olduğu durumlarda diğerlerine göre daha başarılı sonuçlar elde edilmiştir.

Yukarıda Matlab ve Weka'da Knn algoritması ve çok katmanlı yapay sinir ağları kullanılarak bulunan doğruluk oranları dikkate alınarak değerlendirildiğinde Knn ile yapılan uygulama sonuçlarının düşük doğruluk oranıyla çıkmasına karşılık çok katmanlı yapay sinir ağları ile yapılan uygulama sonuçlarının % 100'e yakın doğruluk oranlarını vermesi eğitim ve test verilerinin her birinin giriş ve çıkış değerleri arasındaki karmaşık, doğrusal olmayan ve düzensiz ilişkilere rağmen kullanılan çok katmanlı yapay sinir ağlarının iyi bir öğrenme gerçekleştirdiğini göstermektedir.

KAYNAKLAR

- [1] Url-1 <https://www.btk.gov.tr/haberler/yapay-zekadaki-gelismeler-insan-aklinin-sinirlarinizorluyor?fbclid=IwAR2kB_co5Mf_P6yoKclRMDGx462JvXqoTzKHng8m8muqBmXuIFGiyYcsWeE >, Eriřim tarihi 11.02.2019.
- [2] Solmaz R, Günay M, Alkan A ve ark., Uzman sistemlerin tiroid teřhisinde kullanılması. Eriřim: (<http://ab.org.tr/ab13/bildiri/268.pdf>), Eriřim tarihi 11.03.2019.
- [3] Temurtař F, (2009), “A comparative study on thyroid disease diagnosis using neural networks” , Expert System With Applications, vol. 36 pp. 944-949,2009.
- [4] Keleř A.,Keleř A., (2008), “Expert system for thyroid diseases diagnosis”, Expert Systems with Applications, vol. 34, pp.242-246, 2008.
- [5] Kodaz, H., Özřen S., Arslan, A., Güneř, S., “Medical application of information gain based artificial immune recognition system (AIRS): Diagnosis of thyroid disease”, Expert System With Applications, vol. 36 pp. 3086-3092, 2009.
- [6] Dogantekin, E., Dogantekin, A., Avcı, D., “An expert system based on Generalized Discriminant Analysis and Wavelet Support Vector Machine for diagnosis of thyroid diseases”, Expert Systems with Applications, vol. 38, pp. 146–150, 2011.
- [7] Öztemel Ercan, (2016), *Yapay sinir aęları*, Papatya Yayıncılık Eęitim, İstanbul.
- [8] Turing, A.M. (1950), '*Computing Machinery and Intelligence*', Mind 59, pp. 433–460.
- [9] James, William. (1890). *Principles of Psychology*. Vol.1. New York: Holt.
- [10] McCulloch, W. S., & Pitts, W. A. (1943). A logical calculus of the ideas immanent in nervous activity. Buttetin of Mathematics and Biophysics, 5, 115-133.
- [11] Hebb, D. O. (1949). The organization of behaviour. The first stage of perception: growth of the assembly, 4, 60-78.

- [12] Rumelhart, D. E., & McClelland, J. L. (1986). Parallel distributed processing, explorations in the microstructure of cognition. Foundations, MIT Press Cambridge, MA, 1.
- [13] Rumelhart, D. E., & McClelland, J. L. (1988). Parallel distributed processing, explorations in the microstructure of cognition, A handbook of models, programs and exercises. MIT Press, Cambridge, MA.
- [14] Broomhead, D. S., & Lowe, D. (1988). Radial basis-functions, multi-variable functional interpolation and adaptive networks. Royal signals and radar establishment memorandum, 41-48.
- [15] Specht, D. F. (1988). Probabilistic neural networks for classification, mapping or associative memory. IEEE Conference on Neural Networks, 1, 525-532.
- [16] Specht, D. F. (1991). A general regression neural network. IEEE Transactions on Neural Networks, 2(6), 568-576.
- [17] Url-2 <http://www.megep.meb.gov.tr/mte_program_modul/moduller/Sinir%20Sistemi.pdf>, Eriřim tarihi 11.10.2018.
- [18] Url-3 <<https://www.beyin.gen.tr/beyin-bolumleri.html>>, Eriřim tarihi 09.11.2018.
- [19] Url-4 <<https://www.hucreler.gen.tr/sinir-hucresi.html>>, Eriřim tarihi 09.03.2019.
- [20] Rumelhart, D. E., Hinton, D. E., & Williams, R. J. (1986). Learning representation by backpropagating errors. Nature, 323(9), 533-536.
- [21] Russell, S., Norvig, P. (1995) Artificial Intelligence A Modern Approach. Prentice-Hall.
- [22] AKPINAR Haldun, (2017), *DATA Veri Madencilięi Veri Analizi*, Papatya Yayıncılık Eęitim, İstanbul.
- [23] Url-5 <<http://www.ozlenenrehber.com.tr/tr/dergi/70/tiroit-bezi-ve-hastaliklari-1173.html>>, Eriřim tarihi 18.03.2019.
- [24] Url-6<<http://weka.sourceforge.net/doc.dev/weka/classifiers/functions/MultilayerPerceptron.html#MultilayerPerceptron>>, Eriřim tarihi 25.03.2019.

ÖZGEÇMİŞ

Abdulkaki YILDIZ, 15.09.1987'de İzmit'de doğdu. İlk, orta ve lise eğitimini Kocaeli'de tamamladı. 2005 yılında Kocaeli Anadolu Lisesi'nden mezun oldu. 2005 yılında başladığı Selçuk Üniversitesi Teknik Eğitim Fakültesi Bilgisayar Sistemleri Öğretmenliği Bölümü'nü 2010 yılında bitirdi. 2015 yılında Kocaeli Üniversitesi Bilgisayar Mühendisliği Bölümü'nden mezun oldu. 2011 yılında Milli Eğitim Bakanlığı kadrosunda Teknik Öğretmen olarak çalışmaya başladı. 2014 yılında Sakarya Üniversitesi'nde öğretim görevlisi olarak çalışmaya başladı. 2018 yılı itibari ile Sakarya Uygulamalı Bilimler Üniversitesinde öğretim görevlisi olarak görev yapmaktadır. Sakarya Uygulamalı Bilimler Üniversitesi Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimine devam etmektedir.