

**YAPAY SİNİR AĞLARI VE LOJİSTİK REGRESYON YÖNTEMLERİ
İLE MEME KANSERİ KOLTUK ALTI LENF NODU DURUMUNUN
BELİRLENMESİ**

Rukiye KARAKIŞ

**YÜKSEK LİSANS TEZİ
ELEKTRONİK VE BİLGİSAYAR EĞİTİMİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

OCAK 2009

Rukiye KARAKIŞ tarafından hazırlanan YAPAY SİNİR AĞLARI VE LOJİSTİK REGRESYON YÖNTEMLERİ İLE MEME KANSERİ KOLTUK ALTI LENF NODU DURUMUNUN BELİRLENMESİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.



Prof. Dr. İnan GÜLER
Tez Yöneticisi

Bu çalışma, jürimiz tarafından oy birliği ile Elektronik ve Bilgisayar Eğitimi Anabilim Dalında Yüksek lisans tezi olarak kabul edilmiştir.

Başkan: : Doç. Dr. O. Ayhan ERDEM



Üye : Prof. Dr. İnan GÜLER



Üye : Doç. Dr. Mesut TEZ



Tarih : 15 / 01 / 2009

Bu tez, Gazi Üniversitesi Bilişim Enstitüsü tez yazım kurallarına uygundur.

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.



Rukiye KARAKIŞ

**YAPAY SİNİR AĞLARI VE LOJİSTİK REGRESYON YÖNTEMLERİ
İLE MEME KANSERİ KOLTUK ALTI LENF NODU DURUMUNUN
BELİRLENMESİ
(Yüksek Lisans Tezi)**

Rukiye KARAKIŞ

GAZİ ÜNİVERSİTESİ

BİLİŞİM ENSTİTÜSÜ

Ocak 2009

ÖZET

Meme kanseri günümüzde en sık rastlanılan kanser türlerinden biridir. Meme kanseri hastalığının evrelendirilmesinde ve tedavisinin belirlenmesinde koltuk altı lenf bezlerinin durumunun bilinmesi çok önemlidir. Koltuk altı lenf nodlarının durumu cerrahi işlemler ile belirlenmektedir ve bu cerrahi işlemlerin ciddi yan etkileri bulunmaktadır. Bu çalışmada meme kanseri hastalarının her hastanede kolaylıkla elde edilebilir klinik ve patolojik verilerine bakılarak yapay sinir ağları ile koltuk altı lenf nodlarının durumunun belirlenmesi amaçlanmıştır. Ankara Numune Eğitim ve Araştırma Hastanesi, Ankara Onkoloji Eğitim ve Araştırma Hastanesi'ne başvuran 270 meme kanseri hastasının klinik ve patolojik verileri, ileri beslemeli geri yayımlı çok katmanlı yapay sinir ağı ve lojistik regresyon ile sınıflandırılmış, oluşturulan modeller test verileri ile test edilmiştir. Yapay sinir ağının performansını ölçmek için Regresyon ve ROC (Receiver Operating Characteristics) istatistiksel analiz yöntemleri kullanılarak, ağın belirlilik, duyarlılık ve doğruluk sonuçları elde edilmiştir.

Bilim Kodu : 704.3.013

Anahtar Kelimeler : Meme kanseri, koltuk altı lenf nodu, yapay sinir ađı,
lojistik regresyon, ROC

Sayfa Adedi : 75

Tez Yöneticileri : Prof. Dr. İnan GÜLER

**PREDICTION OF THE AXILLARY LYMPH NODE
STATUS IN BREAST CANCER USING ARTIFICIAL NEURAL
NETWORK AND LOGISTIC REGRESSION ANALYSIS METHODS
(M.Sc. Thesis)**

Rukiye KARAKIŞ

GAZİ UNIVERSITY

INFORMATICS INSTITUTE

January 2009

ABSTRACT

Today one of the prevalent cancer types we come across in women is breast cancer. Classification and staging of axillary lymph nodes are most important points in diagnose and treatment of breast cancers. Prognosis for these lymph nodes can only be clarified by surgical operation which it self has serious side effects. In this study aimed patients with breast cancer can easily follow up recent statues of axillary lymph nodes and information about whether cancer spread beyond breast or not with checking out clinic, pathological data results easily in any hospital by artificial neural network. Clinic and pathologic data of 270 breast cancer patients applied to Ankara Numune Educational and Research Hospital, Ankara Oncology Educational and Research Hospital are tested and classified according to back propagation multilayer perceptron, and logistic regression. For testing artificial neural network performance, Regression and ROC (Receiver Operating Characteristics) statistical analysis system used to find out specificity, sensitivity, and accuracy of this test.

Science Code : 704.3.013
Key Words : Breast cancer, axillary lymph node, artificial neural network, logistic regression, ROC
Page Number : 75
Adviser : Prof. Dr. İnan GÜLER

TEŐEKKÜR

Tez alıőmamda benden zaman, fikir ve tecrübelerini esirgemeyen ve alıőmam boyunca bana yol gősteren danıőmanım Sayın Prof. Dr. İnan GÜLER'e, alıőma için gereken verileri saėlayan Genel Cerrah Do. Dr. Mesut Tez'e "Ankara Numune Eėitim ve Araőtırma Hastanesi" yardımlarından dolayı teőekkür ederim.

Tez alıőmalarım sırasında bana destek veren aileme ve arkadaőlarıma teőekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	vi
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ÇİZELGELERİN LİSTESİ	xi
ŞEKİLLERİN LİSTESİ	xiii
SİMGELER VE KISALTMALAR	xv
1. GİRİŞ	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI	3
2.1.Genel Bilgiler	7
2.1.1. Meme kanseri	7
2.1.1.1. Memenin anatomisi	7
2.1.1.2. Meme kanserinin evrelendirilmesi	8
2.1.1.3. Histolojik derecelendirme sistemi	10
2.1.1.4. Tanı ve tedavi	10
2.1.2. Yapay Zeka	11
2.1.2.1. Biyolojik sinir hücresi	13
2.1.2.2. Yapay sinir hücresi	14
2.1.2.3. Tek katmanlı algılayıcılar (TKA)	15
2.1.2.4. Çok katmanlı algılayıcılar (ÇKA)	16
2.1.2.5. Geriye yayılım algoritması	18
2.1.2.6. Hızlı öğrenme algoritmaları	20

	Sayfa
2.1.2.7. Newton öğrenme algoritması	23
2.1.2.8. Levenberg-Marquardt algoritması	24
2.1.3. Korelasyon Katsayısı ve Regresyon.....	24
2.1.4. Lojistik Regresyon	25
2.1.5. Receiver Operating Characteristics (ROC).....	26
3. MATERYAL VE YÖNTEM	28
4. BULGULAR VE TARTIŞMA	33
4.1. Meme Kanseri Verileri ile Lojistik Regresyon Analizi	33
4.2. Meme Kanseri Verileri ile Yapay Sinir Ağı Analizi.....	37
4.2.1. Meme kanseri sınırlı veri seti YSA analiz sonuçları.....	48
4.2.2. Tam ve sınırlı veri setleri ile oluşturulan ÇKA'ların kıyaslanması .	58
4.2.3. YSA'nın farklı veri seti ile test edilmesi.....	62
4.3. YSA ve LR Analizleri Karşılaştırılması	63
4.4. Tartışma	64
5. SONUÇ VE ÖNERİLER	67
KAYNAKLAR	69
ÖZGEÇMİŞ	75

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Meme kanserinin TNM'e göre evrelendirilmesi.....	9
Çizelge 2.2. Meme kanserinin histolojik derecelendirilmesi.....	11
Çizelge 2.3. Tıbbi testlerin analizinde kullanılan sınıflama tablosu	26
Çizelge 3.1. Veri setinin özellikleri	29
Çizelge 4.1. I.Model için denkleme giren ve girmeyen değişkenler.....	33
Çizelge 4.2. II. Model için denkleme giren değişkenler	34
Çizelge 4.3 Modellerin Hosmer ve Lemeshow testi sonuçları	34
Çizelge 4.4 İki modelin tam ve sınırlı veri setleri analiz sonuçları.....	35
Çizelge 4.5. Modellerin kıyaslanması.....	36
Çizelge 4.6. Levenberg–Marquardt algoritması ÇKA sonuçları	38
Çizelge 4.7. Öğrenme katsayısı değişen algoritma ÇKA sonuçları.....	39
Çizelge 4.8. Esnek geriye yayılım algoritması ÇKA sonuçları	40
Çizelge 4.9. Fletcher-Reeves eşlenik gradyan yöntemi ÇKA sonuçları	41
Çizelge 4.10. Powell-Beale eşlenik gradyan yöntemi ÇKA sonuçları.....	42
Çizelge 4.11. Polak-Ribiere eşlenik gradyan yöntemi için ÇKA sonuçları.....	43
Çizelge 4.12. Ölçekli eşlenik gradyan yöntemi için ÇKA sonuçları	44
Çizelge 4.13. Quasi-Newton eğitim algoritması ÇKA sonuçları.....	45
Çizelge 4.14. Tek adım sekant algoritması ÇKA sonuçları.....	46
Çizelge 4.15. Eğitim algoritmalarının gizli katmandaki nöron sayılarına göre r değerleri	47
Çizelge 4.16. Levenberg- Marquardt algoritması ÇKA sonuçları	48
Çizelge 4.17. Öğrenme katsayısı değişen algoritma ile ÇKA sonuçları	49

Çizelge	Sayfa
Çizelge 4.18. Esnek geriye yayılım algoritması ÇKA sonuçları	50
Çizelge 4.19. Fletcher-Reeves eşlenik gradyan algoritması ÇKA sonuçları	51
Çizelge 4.20. Powell-Beale eşlenik gradyan algoritması ÇKA sonuçları.....	52
Çizelge 4.21. Polak-Ribiere eşlenik gradyan algoritması ÇKA sonuçları.....	53
Çizelge 4.22. Ölçekli eşlenik gradyan algoritması ÇKA sonuçları	54
Çizelge 4.23. Quasi-Newton eğitim algoritması ÇKA sonuçları.....	55
Çizelge 4.24. Tek adım sekant algoritması ÇKA sonuçları.....	56
Çizelge 4.25. Sınırlı eğitim seti ile oluşturulan ÇKA'ların farklı nöron sayılarına göre r değerleri	57
Çizelge 4.26. Eğitim Algoritmaları tam veri seti hata ve zaman analizi.....	59
Çizelge 4.27. Eğitim algoritmaları sınırlı veri seti hata ve zaman analizi	61
Çizelge 4.28. Farklı meme kanseri veri seti performans sonuçları	63
Çizelge 4.29. YSA ve LR analiz sonuçları	64

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Biyolojik sinir hücresi.....	13
Şekil 2.2. Basit algılayıcı modeli	14
Şekil 2.3. Tek katmanlı algılayıcı	16
Şekil 2.4. Çok katmanlı algılayıcı.....	16
Şekil 2.5. Sinyal akış gösterimi.....	17
Şekil 2.6. Geri yayılım algoritması	18
Şekil 3.1. Eğitim algoritmasının özellik değişim penceresi.....	30
Şekil 3.2. a) Sınıflandırma tablosu, b) ROC eğrisi, c) Regresyon doğrusu	32
Şekil 4.1. Modellerin tam test seti ROC eğrileri.....	36
Şekil 4.2. Modellerin sınırlı test seti ROC eğrileri.....	36
Şekil 4.3. Levenberg-Marquardt eğitim algoritması test seti ROC eğrileri	38
Şekil 4.4. Öğrenme katsayısı değişen algoritma test seti ROC eğrileri	39
Şekil 4.5. Esnek geriye yayılım algoritması test seti ROC eğrileri.....	40
Şekil 4.6. Fletcher ve Reeves eşlenik gradyan yöntemi test seti ROC eğrileri.....	41
Şekil 4.7. Powell-Beale eşlenik gradyan yöntemi test seti ROC eğrileri.....	42
Şekil 4.8. Polak-Ribiere eşlenik gradyan yöntemi test seti ROC eğrileri	43
Şekil 4.9. Ölçekli eşlenik gradyan yöntemi test seti ROC eğrileri	44
Şekil 4.10. Quasi-Newton algoritması test seti ROC eğrileri	45
Şekil 4.11. Tek adım sekant algoritması test seti ROC eğrileri	46
Şekil 4.12. Eğitim algoritmalarının gizli katmandaki nöron sayılarına göre r değerleri	47
Şekil 4.13. Levenberg-Marquardt algoritması test veri ROC eğrileri.....	49

Şekil	Sayfa
Şekil 4.14. Öğrenme katsayısı değişen algoritma ile test veri ROC eğrileri.....	50
Şekil 4.15. Esnek geriye yayılım algoritması test veri ROC eğrileri.....	51
Şekil 4.16. Fletcher-Reeves eşlenik gradyan algoritması test veri ROC eğrileri.....	52
Şekil 4.17. Powell-Beale eşlenik gradyan algoritması.....	53
Şekil 4.18. Polak-Ribiere eşlenik gradyan algoritması test veri ROC eğrileri.....	54
Şekil 4.19. Ölçekli eşlenik gradyan algoritması test veri ROC eğrileri.....	55
Şekil 4.20. Quasi-Newton eğitim algoritması test veri ROC eğrileri	56
Şekil 4.21. Tek adım sekant algoritması test veri ROC eğrileri.....	57
Şekil 4.22. Sınırlı eğitim seti ile oluşturulan ÇKA'ların farklı nöron sayılarına göre r değerleri	58
Şekil 4.23. Eğitim algoritmaları tam veri seti zaman-hata analizi	59
Şekil 4.24. Eğitim algoritmaları eğitim veri seti ROC eğrileri	60
Şekil 4.25. Eğitim algoritmaları test veri seti ROC eğrileri.....	60
Şekil 4.26. Eğitim algoritmaları sınırlı veri seti zaman-hata analizi.....	61
Şekil 4.27. Eğitim algoritmalarının sınırlı eğitim seti ROC eğrileri.....	62
Şekil 4.28. Eğitim algoritmalarının sınırlı test seti ROC eğrileri.....	63

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
X	Giriş sinyali
W	Ağırlık vektörü
B	Bias (sapma) değeri
$\varphi(.)$	Aktivasyon değeri
Y	Çıktı sinyali
D	İstenilen çıktı
E	Hata sinyali
ε	Hata fonksiyonu
η	Öğrenme katsayısı
α	Momentum faktörü
∇	Gradyan operatörü
δ	Lokal gradyan
Δ	Ağırlık düzeltme değeri
H	Hessian matrisi
J	Jakobiyen matrisi
P	Yön vektörü

Kısaltmalar	Açıklama
ALND	Aksiller Lenf Nodu Diseksiyonu
AD	Aksiller Diseksiyonu
AUC	Area Under of Curve –ROC eğrisi altında kalan alan
ÇKA	Çok Katmanlı Algılayıcı
EL	Elli

ER	Östrojen Reseptör
LND	Lenf Nod Durumu
LR	Lojistik Regresyon
LY	Lenfatik Yayılım
Max	Maksimum
MD	Menopoz Durumu
Min	Minumum
Ort	Ortalama
R	Korelasyon Katsayısı
ROC	Receiver Operating Characteristics
SLN	Gözcü Lenf Nodu
SLNB	Gözcü Lenf Nodu Biyopsisi
SS	Standart Sapma
TÇ	Tümör Çapı
TD	Tümör Derecesi
TE	Tümör Evresi
TKA	Tek Katmanlı Algılayıcı
TT	Tümör Tipi
TY	Tümör Yerleşim
Y	Yaş
YSA	Yapay Sinir Ağı
YZ	Yapay Zeka

1. GİRİŞ

Meme kanseri kadınlarda en çok görülen kanser tipidir, kansere bağlı ölümler içinde akciğer kanserinin ardından ikinci sırada gelmektedir ve kadınlarda görülen tüm kanserlerin %31'ini oluşturmaktadır [1-3].

Normal vücut hücreleri kontrollü büyüyüp gelişirken kanser hücreleri kontrolsüz büyürler, bölünürler, bir araya gelerek tümörleri oluştururlar, kan ve lenf yoluyla vücuda yayılırlar. Meme kanseri hücreleri de koltuk altı lenf sistemine, kemik, akciğer, beyin gibi çeşitli organlara yayılabilirler.

Meme kanserinin evrelendirilmesinde, kontrolünde ve seyrine karar verilmesinde koltuk altı lenf nodlarının durumunun belirlenmesi çok önemlidir. Koltuk altı lenf nodlarının durumu Aksiller Diseksiyon (AD) ve Gözcü Lenf Nodu Biyopsi (SLNB) ameliyatları ile belirlenir. Bu işlemde, hastanın koltuk altı lenf nodları negatif çıksa da ameliyat işlemi gerçekleştirilmiştir. Ameliyat sonrası hastalarda ödem, kolda hareketsizlik, şişme gibi pek çok yan etki oluşmaktadır.

SLNB ve AD işlemlerinde oluşan sıkıntılardan dolayı koltuk altı lenf nodlarının cerrahi işlem gereksizsinin çözümü için hastaların klinik, patolojik, radyolojik, hormon ve gen bilgileri gibi çeşitli tümör belirleyici olabilecek özelliklerine bakılmış ancak yapılan çalışmalarda tek başına bu özelliklerin koltuk altı lenf nodlarını belirlemede yeterli olmadığı sonucuna ulaşılmıştır [4-11].

Yapay Sinir Ağları (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır [12]. YSA pek çok alanda olduğu gibi, özellikle tanı ve teşhis amaçlı olarak tıp alanında da kullanılmaktadır.

Bu çalışmada, meme kanseri hastalarının koltuk altı lenf nod durumlarını belirleyen SLNB ve AD ameliyatları olmaksızın, her hastanede kolaylıkla elde edilebilir olan klinik ve patolojik verilerinin girildiği yapay sinir ağının, hastaların koltuk altı lenf nod durumunu belirlemesi amaçlanmıştır. Çalışma için Ankara Numune Eğitim ve Araştırma Hastanesi ve Ankara Onkoloji Eğitim ve Araştırma Hastanesi'ne başvuran ve meme kanseri 270 kişinin verileri kullanılmıştır. Çok katmanlı ileri yayımlı yapay sinir ağı modeli sonuçları regresyon ve korelasyon katsayılarına bakılarak değerlendirilmiştir. Aynı zamanda tıbbi çalışmalarda tıp testlerinin doğruluklarını tespit amaçlı kullanılan Receiver Operating Characteristics(ROC) analiz yöntemi ile elde edilen eğitim ve test veri sonuçlarının belirlilik, duyarlılık ve doğruluk sonuçları değerlendirilmiştir. Yapay sinir ağının sonuçlarının kıyaslanması için lojistik regresyon istatistiksel analiz yöntemi kullanılmıştır. Lojistik regresyon ile hangi verilerin anlamlı olduğuna bakılmış, anlamlı olan verilerle yapay sinir ağı tekrar eğitilmiş ve test edilmiştir.

Yapılan çalışma ile hastaların koltuk altı lenf nodları durumu cerrahi işlemler gereksiz belirlenecektir. Böylece cerrahi işlem sonrası oluşan yan etkiler ortadan kalkacaktır.

Çalışma beş bölümden oluşmaktadır. İkinci bölümde koltuk altı lenf nodlarının durumunu belirlemek için yapılan çalışmalar incelenmektedir ve meme kanseri, yapay sinir ağları, regresyon, lojistik regresyon, ROC ile ilgili genel bilgiler verilmektedir. Üçüncü bölümde koltuk altı lenf nod durumunu belirlemek için kullanılan materyal ve yöntem anlatılmaktadır. Dördüncü bölümde elde edilen verilerin analizi, yapay sinir ağı ile eğitim ve test işlemleri sonuçları bulunmaktadır. Beşinci bölümde tez bir bütün halinde sonuç bakımından değerlendirilmekte ve irdelenmektedir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Meme kanseri kadınlarda en çok görülen kanser türüdür, kansere bağlı ölümler içinde akciğer kanserinin ardından ikinci sırada gelmektedir ve kadınlarda görülen tüm kanserlerin %31'ini oluşturmaktadır [1-2].

Meme kanseri tedavi çalışmaları M.Ö.'ye kadar dayanır. 18.yüzyılda Halstead tarafından geliştirilen radikal mastektomi ile meme ve koltuk altı lenf nodlarının tamamen alınmasıyla hastalık tedavi edilirken, 19. yüzyılda hastalığın meme etrafındaki lenf düğümlerine kademeli olarak yayıldığı anlaşılmıştır. 1960'larda Fisher tarafından, hastalığın yayıldığı alanın önceden belirlenmesi amaçlanmıştır. 1992'de Morton ve arkadaşları tarafından gözcü lenf nodu biyopsisi ortaya atılmıştır. Bu yöntemle koltuk altına kanser hücreleri yayılmamış ise lenf nodlarının tamamının çıkarılması engellenmiştir [3-4].

Meme kanserinin evrelendirilmesinde kullanılan en önemli belirleyicilerden biri hastanın koltuk altı lenf nodlarının durumunun bilinmesidir. Koltuk altı lenf nodlarında yayılım olup olmadığını belirlemek için Aksiller Diseksiyon (AD) ve Gözcü Lenf Nodu Biyopsisi (SLNB) cerrahi işlemleri kullanılmaktadır. AD, koltuk altı lenf nodlarının tamamen çıkarılıp incelenmesi işlemidir. SLNB, tümöre en yakın nodda yayılım olup olmadığını belirler, yayılım yoksa diğer lenf nodlarına işlem yapılmaz.

AD ve SLNB ameliyatlarında ana problem hastaların koltuk altı lenf nodlarında yayılım olup olmadığının ameliyat esnasında belirlenmesidir. AD ameliyatlarında %70 oranında negatif sonuç alınırken bu oran SLNB ameliyatlarında daha azdır. AD ameliyatlarının doğruluk oranı yüksektir, yanlış negatif belirleme oranı SLNB'de %2-%5'lerdedir. Cerrahi işlem sonrası hastalarda ödem, şişkinlik, kolda hareketsizlik gibi yan etkiler oluşmaktadır [5-11].

AD ve SLNB ameliyatlarındaki sıkıntılardan dolayı koltuk altı lenf nod durumunun belirlenmesi için hastaların klinik, patolojik, radyolojik verileri ile hormon reseptör durumları ve genetik bilgileri incelenmiştir. Tahmin edici bu parametrelerle hastalığın teşhis ve tedavi planlanması daha rahat yapılabilecektir [11,13].

Yapılan çalışmalar içinde tümör çapı, tümör ve lenf damarlaşması, lenfovasküler invazyon, histolojik derece gibi etmenler koltuk altı lenf nod belirlemede önemli bulunmuştur. Tümör belirleme ve koltuk altı lenf nodlarının durumunu tahmin etmede modern görüntüleme yöntemleri olan ultrason (US), manyetik rezonans görüntüleme (MRI), pozitron emisyon tomografi (PET) kullanılmaktadırlar. Meme kanserinde bazı genlerdeki değişimler lenf nod yayılımı ile ilişkilidir. S100A4 ve nm23 genlerinin koltuk altı lenf nodu yayılımı ile bağlantılı olduğu bulunmuştur. Progesteron reseptör durumu koltuk altı ile ilgili olduğu gerekçesi ile ölçülmektedir ancak çoğu çalışmada östrojen, progesteron, HER-2 hormon reseptör durumlarının koltuk altı lenf nodları ile ilişkili olmadığı sonucuna varılmıştır [14-18].

Tıpta pek çok alanda olduğu gibi son yıllarda meme kanserinde yapay sinir ağları (YSA), istatistiksel yöntemler gibi hastalık tanı, tahmin ve tedavi aşamalarında kullanılmaktadır. YSA kullanarak koltuk altı lenf düğümlerinin durumunun belirlenmesi sağlanırsa, AD ve SLNB ameliyatlarına gerek kalmayabilir [11,19].

YSA, çeşitli problemlere çözüm getirmek amacıyla insan beyninin bilgi işleme mekanizmasını taklit ederek geliştirilmiş bilgisayar yazılımlarıdır. YSA paralel dağılmış belleği ile öğrenme, hafızaya alma ve öğrendiklerini yeni bilgiler üretecek biçimde genelleme, değişkenler arasındaki ilişkileri ortaya koyma yeteneklerine sahiptirler. Bu özellikleri ile YSA karmaşık problemleri çözebilmektedir [20-21].

YSA'nın biyokimyasal analizlerde, genetik alanında yapılan çalışmalarda, kardiyoloji, gastroenteroloji, onkoloji, nöroloji, jinekoloji, radyoloji, patolojide, ECG ve EEG sinyallerini işlemede tahmin ve teşhis amaçlı kullanımı giderek yaygınlaşmaktadır [20, 22-23].

Çeşitli kanserlerin tanı ve seyrinin belirlenmesi için oluşturulan yapay sinir ağlarında en büyük problem eğitim için kullanılan veri setlerinin oldukça küçük olmasıdır. Daha büyük veri setleri ile oluşturulacak YSA modelleri, eğitim için gerekli faktörlerin doğru belirlenmesi, doğru durdurma ölçütlerinin, uygun yapı tahminlerinin bulunması ile kanser hastalığının tanı, teşhis ve seyrinin tahmininde daha faydalı olacaktır [25].

Meme kanseri tanısının konulması için hastaların görüntü bilgilerinden ve mevcut klinik ve patolojik verilerinden yola çıkılarak oluşturulan YSA modelleri için performans analizleri yapıldığında başarılı sonuçlar vermiştir [26-33].

Meme kanseri koltuk altı lenf nodlarının durumunu gösterebilecek tümör belirleyiciler ile ilgili pek çok istatistiksel çalışma yapılmıştır. Ancak konu ile ilgili YSA çalışmaları literatürde çok fazla yoktur.

Meme kanseri hastalarının koltuk altı lenf düğümlerinin durumunu belirlemek için hastaların S100A4 ve nm23 genleri bilgisi, östrojen ve progesteron reseptörleri durumu, tümör histolojik derecesi, yaşı, tümör boyutu verileri, oluşturulan çok katmanlı geri yayımlı YSA'ya girdi olarak sunulmuştur. Hangi verilerin daha belirleyici olduğunu belirlemek için farklı girdilerden oluşan ağlar oluşturulmuştur. S100A4 ve nm23 gen bilgileri ile oluşturulan ağın eğitim ve test verileri doğruluk sonuçları %88 ve %85 elde edilmiştir [34].

Koltuk altı lenf düğümlerinin tayin edilmesi için 7129 hastaya ait 49 adet gen ekspresyon mikro dizi veri bilgileri geri yayımlı sinir ağına sunulmuştur. Sinir ağı ER (östrojen reseptör) ve koltuk altı lenf düğüm durumunu %100 doğruluk oranları ile belirlemiştir [35].

50 hastanın koltuk altı lenf nodu durumunu tespit etmek için klinik ve patolojik 12 verisi ile yapay sinir ağı oluşturulmuştur ve ağ 31 hastanın verileri ile test edilmiştir.

12 veri ile oluşturulan ağın duyarlılık ve belirlilik değerleri %73 ve %90, sınırlı veri ile elde edilen ağın duyarlılık ve belirlilik değerleri %50 ve %96 olmuştur [36].

Koltuk altı lenf nodu durumunu tahmin etmek için 1139 meme kanseri hastasına ait tümör tipi, tümörün derecesi, tümör çapı, deri enfiltrasyon, lenfatik invazyon, PT4, G2/m, S fazı, ploidi indeksi değerleri giriş olarak ve lenf nod metastazı çıkış olarak seçilmiştir. Lojistik regresyon analizi sonrası lenfatik invazyon ve tümör çapı anlamlı bulunmuştur. 10 giriş değeri ile oluşturulan YSA'da %73 doğruluk, %82-84 belirlilik, %60-63 duyarlılık sonuçları elde edilmiştir. Lenfatik invazyon ve tümör çapı giriş değerleriyle oluşturulan ağda da yakın değerler elde edilmiştir [37].

Meme kanseri hastalarının tümör derece, çap, östrojen ve progesteron hormon durumları, p53, nm23, RB1, RB2, RB3 gibi gen bilgileri girilerek koltuk altı lenf nod durumu Öz Örgütlemeli Harita sinir ağı ile sınıflandırılmıştır. Doğruluk oranı %74 olarak elde edilmiştir [38].

224 meme kanseri hastasının yaş, tümör derece, duktal ya da lobular yayılım bilgisi, tümör boyutu, DNA indeksi, sitometrisi, östrojen, progesteron hormon bilgileri ve HER-2/neu onkogen bilgileri gibi 19 verisi yapay sinir ağı ile eğitilmiş ve %89,0 doğruluk değeri elde edilmiştir. Çalışmada aynı zamanda lojistik regresyon analizi yapılmış, doğruluk değeri YSA'ya göre küçük bulunmuştur [39].

YSA ile yapılan koltuk altı lenf nodu belirleme çalışmalarında seçilen veriler her hastanede kolaylıkla elde edilebilir türde değildir. Yapılan çalışmalarda çoğunlukla hastaların gen bilgileri kullanılmıştır ve bu çalışmalar cerrahi işlemlerin yerini alamamıştır. Bu çalışmada meme kanseri hastalarının literatürde koltuk altı lenf nod durumunu belirlemek için anlamlı bulunan ancak tek başına yeterli olmayan her hastanede kolaylıkla elde edilebilir verileri ile koltuk altı lenf nod durumunun belirlenmesi amaçlanmıştır. Böylelikle hastalara gereksiz cerrahi işlemler uygulanmayacaktır.

2.1. Genel Bilgiler

Çalışmanın bu kısmında meme kanseri ile ilgili genel bilgiler verilecektir. Aynı zamanda meme kanseri verilerini sınıflandırmak için kullanılacak YSA, ağ sonuçlarının performansını ölçmek için kullanılan regresyon ve ROC eğrileri hakkında genel bilgiler verilmektedir. Yapay sinir ağları ile yapılan çalışmanın karşılaştırılması için kullanılan lojistik regresyon (LR) istatistiksel analiz yöntemi hakkında da bilgiler sunulmuştur.

2.1.1. Meme kanseri

Meme kanseri günümüzde en sık görülen kanser türlerinden biridir. Kanser hücreleri, normal vücut hücrelerinden farklıdır. Normal vücut hücreleri sistemli bir şekilde büyür, bölünür ve ölür. Eğer yeni hücreler gerekmiyor ise her hücrenin içinde mevcut mekanizmalar, hücreye bölünmeyi durdurmasını söyler. Buna karşın kanser hücreleri büyümeye, bölünmeye devam ederler, vücudun diğer bölgelerine yayılırlar, birikerek tümörleri oluştururlar. Tümörler normal dokuları sıkıştırabilirler, içine sızabilirler ya da tahrip edebilirler. Kanser hücreleri oluştukları tümörden ayrılarak kan ya da lenf dolaşımı aracılığı ile vücudun diğer bölgelerine yayılabilirler. Kanser bu şekilde vücudun diğer bölgelerine yayılmasına “metastaz” denir. Meme kanseri de lenf sistemi, akciğer, beyin gibi çeşitli organlara yayılabilmektedir.

2.1.1.1. Memenin anatomisi

Meme süt bezleri, süt kanalları, yağ dokusu ve taşıyıcı lif dokusundan oluşur. Süt bezleri “lob” denilen gruplarda toplanırlar, her lob çok sayıda küçük lob içerir. Loblar sayısı bir düzineye varan süt bezlerini oluştururlar. “Duct” adı verilen kanallarla süt taşınır. Memede kas yoktur, pectoralis major ve pectoralis minör adı verilen iki kas memenin altındaki kaburgalara bağlıdır. Memenin içinde memeye oksijen ve besin taşıyan damarlar vardır. Damarda kan ile beraber dolaşımda olan

lenf sıvısı, damar duvarlarından sızar ve hücrelerin arasındaki boşlukta birikir. Lenf kanalları lenf sıvısını toplar ve ana kan dolaşımına geri kazandırılması sağlar. Bu kanallar boyunca lenf sıvısı, lenf bezleri adı verilen organlar tarafından süzülür. Memede toplanan lenf sıvısının büyük bir bölümü koltuk altına doğru toplanır, burada lenf bezleri tarafından süzöldükten sonra lenf sıvısı dolaşıma geri döner. Meme dokusu kan damarları ve lenf dolaşım sistemleri açısından gelişmiştir, dokunun lenf kanalları koltuk altında yer alan lenf bezlerine taşınırlar.

2.1.1.2. Meme kanserinin evrelendirilmesi

Doktorların tümörün boyutunu ve yerini belirlemek için yaptıkları sınıflandırmaya “evrelendirme” denir. Bunun için meme kontrolü, meme biyopsisi testleri, toraks grafisi, mamografi, kemik taraması, bilgisayarlı tomografi, ultrasonografik görüntüleme, manyetik rezonans taraması gibi çeşitli yöntemler ile hastalıkla ilgili veriler toplanır. Ek olarak hastanın genel sağlık taraması ve hastalığın başka organlara sıçrayıp sıçramadığının tespiti için kan testleri yapılır. Meme kanseri hastalığının sınıflandırılması için TNM evrelendirmesi yöntemi kullanılır. T tümörün boyutunu, N lenf bezlerinin durumunu, M ise kanserin metastaz yapıp yapmadığını belirtir.

T ve yanında bulunan rakamlar tümörün boyutunu, tümörün deriye ya da memeye, memenin altında bulunan göğüs duvarına sıçrayıp sıçramadığını ifade eder. Rakam büyükse tümör büyük ve yaygındır.

Tx: Tümörün boyutu belirlenmemiştir.

To: Tümör belirtisi yoktur.

Tis: Tümör bulgusu olmayan Paget hastalığı, sınırlı tümör

T1: Tümör en fazla 2 cm ya da daha azdır.

T2: Tümör 2 cm’ den büyük 5 cm’den küçüktür.

T3: Tümör 5 cm’den büyüktür.

T4:Tümörün büyüklüğü önemsenmemektedir, tümör göğüs duvarına ya da lenf bezlerine yayılmıştır.

N lenf bezlerinin durumunu ve yanındaki 0–3 rakamları kanserin memeye yakın lenf bezlerine yayılıp yayılmadığını gösterir. Rakam büyükse daha fazla ve daha uzak lenf bezlerine kanserin yayıldığını gösterir.

Nx: Lenf bezlerine yayılım belirlenememiştir. (Lenf Bezleri alınmış olabilir)

No: Bölgesel lenf bezlerine kanser yayılmamıştır.

N1: Aynı taraf koltuk altında bir ya da daha fazla lenf bezine yayılmıştır.

N2: Aynı taraf koltuk altında bir ya da fazla lenf bezinde metastaz, fakat bu lenf bezleri birbirlerine ya da etraf dokulara yapışmıştır.

N3: Kanser tümörün bulunduğu meme ile aynı tarafta bulunan ana dolaşım sistemi lenf bezlerine ya da her iki meme arasındaki lenf bezi zincirine sıçramıştır.

M uzak metastaz varlığını ifade eder.

Mx: Uzak metastazın varlığı tespit edilememiştir.

Mo: Uzak metastaz yoktur.

M1: Uzak metastaz vardır. Kanser uzak organlara yayılmıştır.

TNM' göre evrelendirme Çizelge 2.1'de verilmektedir.

Çizelge 2.1. Meme kanserinin TNM'e göre evrelendirilmesi

Evre	Tümörün Boyutu	Lenf Bezleri	Metastaz
I	2 cm'den az	Sıçrama yoktur	Yok
II	2–5 cm arası	Sıçrama yoktur veya tümörün bulunduğu göğüs ile aynı tarafta vardır	Yok
III	5 cm'den büyüktür	Tümörün bulunduğu göğüs ile aynı tarafta vardır	Yok
IV	Önemli değil	Önemli Değil	Var

Meme kanseri hastalarının koltuk altı lenf nod durumunun varlığı evrelendirmede çok önemlidir. Bu çalışmada hastaların koltuk altı lenf nod durumları (N) belirlemek için hastaların T evre bilgileri kullanılacaktır.

2.1.1.3. Histolojik derecelendirme sistemi

Meme kanserinde patologlar tümör tipini belirlemek için kanserli tümör hücrelerinin yapı ve fonksiyonlarına bakarak histolojik dereceler verirler. En yaygını “Scorff-Bloom-Richardson” sistemidir. Bu sistemde hücrelerin bölünme hızı, borusal yapılar oluşturan kanser hücrelerinin yapısı, hücre büyüklüğünün düzgünlüğünde görülen değişimlerine bakılarak, 1 ile 3 arasında rakamlar verilir ve sonuçlar toplanır.

Borsal Yapılar içerisinde Bulunan Kanser Hücrelerinin Yüzdesi	Puan
%75’den daha fazla	1
%10-%70 arasında	2
%10’dan daha az	3
Hücre Yapısında ve şeklinde olan değişiklikler	Puan
Küçük Düzgün Hücreler	1
Normal Hücre boy ve yapıda orta ölçekli farklılaşma	2
Belirgin Farklılaşma	3
Hücre Bölünmesi	Puan
7’ye kadar	1
8–14 arası	2
15 ya da daha fazla	3

Meme kanserinin histolojik derecelendirmesi Çizelge 2.2’de verilmiştir. Bu çalışmada hastaların koltuk altı lenf nod durumunun belirlenmesi için hastaların histolojik derecelendirme sistemi ile belirlenen tümör derece verileri kullanılacaktır.

2.1.1.4. Tanı ve tedavi

Meme kanserinde tanı konulurken önce hastanın yaş, ailenin sağlık öyküsü, menarj yaşı ve düzeni, menopoz yaşı, doğum yaşı, meme ile ilgili geçirdiği hastalıklar gibi bilgiler alınır. Uzman doktor tarafından fizik muayene yapılır. Şüphelenilen her hangi bir kitle bulundu ise mamografi, ultrasonografi, sitoloji gibi yöntemlerle kitle

ile ilgili bilgiler elde edilir. Kesin tanı biyopsi ile belirlenir. Biyopsi ile kitleden alınan parça laboratuvar ortamında patoloğlar tarafından incelenir. Kitle eğer kötü huylu ise meme koruyucu tedavi ya da mastektomi uygulanır. Meme koruyucu tedavi, kanserli kitlenin etrafındaki bir parça sağlıklı doku ile alınması işlemi olan lumpektomi, koltuk altı lenf bezlerinin alınması ve ardından radyasyon tedavisini içerir. Mastektomi, kanserin bulunduğu göğsün alınması ve koltuk altı lenf nodlarının çıkarılması işlemidir. Bu çalışmada, koltuk altı lenf nod durumunu belirlemek için hastaların klinik muayene sonucu elde edilen yaş ve menopoiz durum bilgileri, biyopsi ve görüntüleme yöntemleri ile elde edilen tümör tipi ve tümör yerleşim bilgileri, lenfatik yayılım bilgileri kullanılacaktır.

Çizelge 2.2. Meme kanserinin histolojik derecelendirilmesi

Derece (Grade)	Tanımlama	Puanları	Farklılaşma Durumu
1.derece	Hücreler normal görünürler, hızlı bölünmezler, küçük tüp benzeri yapılar oluştururlar	3, 4, 5	İyi farklılaşmış
2.derece	I. ve II. Derece tümörlerin arasında özelliklere sahiptirler	6, 7	Orta derecede farklılaşmış
3.derece	Hücreler, normal hücrelerden daha hızlı büyümekte ve bölünmektedirler	8, 9	Kötü farklılaşmış

2.1.2. Yapay Zeka

Zeka insanın algılama, düşünme, muhakeme, yargılama gibi sezgisel becerilerini kullanarak doğadaki olayları çözümlene yeteneğidir ve insana has bir özelliktir.

Yapay Zeka (YZ) bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır [40].

YZ bilgiyi kullanma, sembolik bilgi işleme, sezgisel problem çözme, eksik, belirsiz ve tam olmayan bilgi işleme, açık olarak formülize edilemeyen problemleri çözebilme, tecrübe ile öğrenme, yeni durumlara adapte olabilme, en fazla geliştiren kadar zeki olma, hata yapabilme yeteneklerine sahiptir.


YZ kavramının geçmişi modern bilgisayar bilimi kadar eskidir. YZ terimi ilk kez İkinci Dünya Savaşının ardından Stanford Üniversitesi'nde Profesör olan John McCarthy tarafından ortaya atılmıştır. Makinelerin düşünebileceğini ilk sorgulayan kişi Alan Mathison Turing'dir. Geliştirdiği Turing Testi ile makinelerin düşünebileceğini kanıtlamaya çalışmıştır. YZ çalışmaları sadece kendi içinde evrim geçirmemiş aynı zamanda da birçok disiplinden de etkilenmiştir.

YZ çalışmaları biyolojik sinir hücrelerini temel alan YSA'nın oluşmasını sağlamıştır. İlk çalışma 1943 yılında McCulloch ve Pitts tarafından yapılmıştır, ilk yapay sinir ağının temellerini oluşturmuşlardır. 1949 yılında Donald Hebb tarafından yapay hücrelerden oluşan sinir ağının değerlerinin değiştirilmesine dayanan öğrenme kuramı oluşturulmuştur. Rosenblatt tarafından geliştirilen algılayıcı model (perceptron) daha sonra çok katmanlı algılayıcıların temelini oluşturmuştur. 1960'lı yıllarda ağların yalnız doğrusal problemleri çözebildikleri, doğrusal olmayan problemlerde başarılı olmadıkları gerekçesi ile çalışmalar gerilemeye başlamıştır. 1980'li yıllarda bu problem çözülmüştür. 1982 yılında Hopfield yapay sinir ağlarının her yeni problem için mekanizmasını sürekli yenilemesi gerektiği belirtmiştir. Geri yayılım öğrenme algoritmasının geliştirilmesi ile çok zor problemlerin artık çözülebilmesi sağlanmıştır. Günümüze kadar YSA çalışmaları hız kesmeden devam etmiştir, danışmanlı ve danışmansız öğrenme metotları içinde çok sayıda kuram ve yöntem geliştirilmiştir [20-21].

YSA, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır [12]. YSA biyolojik sinir hücrelerinden esinlenilerek geliştirilmiştir.

2.1.2.1. Biyolojik sinir hücresi

İnsan beyni, nöron olarak adlandırılan yaklaşık 10^{11} hesap elemanından oluşmaktadır. Biyolojik sinir ağını oluşturan nöronlar; hücre gövdesi, akson, dentrit denilen üç temel elemandan oluşurlar (Şekil 2.1).




Şekil 2.1. Biyolojik sinir hücresi

Soma (hücre gövdesi), hücreyi denetler ve hücre etkinliklerinin tümünü yönetir. Hücre gövdesinden dentritler ve aksonlar olarak adlandırılan iki uzantı çıkmaktadır. Dentritler bilgiyi iletim hatları olarak kullanılan uzun fiberlerden oluşmuş aksonlar boyunca diğer nöronlardan alır ve hücre gövdesine taşırlar. Aksonlar gövdedeki bilgiyi diğer nöronların dentritlerine taşımakla sorumludurlar. Akson sonları ile dentritler arasında bilgilerin uzun süre saklandığı bilgi saklama yerleri oldukları düşünülen sinaps denilen küçük boşluklar bulunur. Sinapslar, nöronun kendi sinyalini komşu nörona tanıttığı bağlantı noktasıdır. Sinaptik bağlantılar mesajların nöronlar arası taşınmasını sağlarlar. Birden çok sinaps yoluyla ulaşan uyarım, belirli

bir eşiği aştığında ateşlenir ya da boşalır. İnsan beyninde öğrenme, yeni aksonlar üreterek, aksonların uyarılmasıyla, mevcut aksonların güçlerini değiştirerek gerçekleşmektedir [41].

2.1.2.2. Yapay sinir hücresi

Biyolojik sinir ağlarının yapı bileşenleri sinir hücreleridir benzer şekilde yapay sinir ağlarının da yapay sinir hücreleri bulunmaktadır (Şekil 2.2). YSA, insan sinir ağındaki gibi nöronlardan ve onlar arasındaki bağlantılardan oluşur. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen hücreler arası bağlantı güçleri kullanılır [43].



Şekil 2.2. Basit algılayıcı modeli

YSA'ya bilgi sayısal olarak dış dünyadan, diğer hücrelerden ya da kendi kendisinden gelebilir. Sinir hücresine bilgiler ağırlıklar yoluyla taşınırlar. Ağırlık değerleri bilginin önemini ifade eder, değişken ya da sabit değerler olabilirler, pozitif ya da negatif değerler alabilirler. Bir sinir hücresine gelen net bilgi yaygın olarak toplama fonksiyonu aracılığıyla hesaplanır. Her girdi değeri kendi ağırlığı ile çarpılır. Toplama fonksiyonu tüm girdiler için gelen bu değerleri toplayarak net hücre çıktısını hesaplar. Her hücre diğer hücrelerden bağımsız olarak bu net değerini hesaplar. Sapma (bias- b_k) değerinin aktivasyon fonksiyonuna giren değeri yükseltme

ya da düşürme etkisi vardır. Eşitlik 2.1’de kullanılan x_j gelen bilgileri, w_{kj} her girdi değerine ait ağırlıkları, b_k sapma değerini, v_k nöronun çıktı değerini ifade etmektedir.

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (2.1)$$


“Eş. 2.2”de görüldüğü gibi her sinir hücresinin net bilgisi eşik değerine sahip bir aktivasyon fonksiyondan geçirilerek gerçek bir çıktı oluşturulur. Genellikle kullanılan aktivasyon fonksiyonları eşik, sigmoid, hiperbolik tanjant vb. fonksiyonlardır. Aktivasyon fonksiyonu ($\varphi(\cdot)$) genellikle doğrusal olmayan bir fonksiyondur.

$$y_k = \varphi(v_k) \quad (2.2)$$

YSA herhangi bir konu ile ilgili veri setleriyle eğitilirken eğitim algoritmaları kullanılır. Öğrenilmesi istenen olay için oluşturulan eğitim seti ağa sunulurken hedef çıktı değerleri de ağa sunulabilir. Sadece girdi seti ağa sunulabilir, sistemin kendi kendine öğrenmesi istenilebilir ya da her girdi seti için sistemin kendisinin bir çıktı üretmesi sağlanabilir. Üretilen çıktının doğru ya da yanlış olduğunu gösteren sinyal üretilerek, bu sinyale göre sistem eğitime devam edilebilir. YSA yapılarında bulunan katman sayılarına göre tek ya da çok katmanlı olarak gruplandırılırlar [20].

2.1.2.3. Tek katmanlı algılayıcılar (TKA)


Tek katmanlı yapay sinir ağları giriş ve çıkış katmanlarından oluşur. Girdi ve çıktı katmanlarında birden fazla giriş ve çıkış değeri bulunmaktadır. Giriş katmanındaki her giriş değerini çıkış katmanına bağlayan sinaptik bağlantılar mevcuttur. Her bağlantı bir ağırlık değerine sahiptir. Aynı zamanda ağın çıktısının sıfır olmasını engelleyen bias sapma değeri mevcuttur (Şekil 2.3).



Şekil 2.3. Tek katmanlı algılayıcı


2.1.2.4. Çok katmanlı algılayıcılar (ÇKA)

Çok katmanlı algılayıcılar (ÇKA), bilgilerin girildiği girdi katmanı, bir veya daha fazla sinir hücresinden oluşan gizli katmanları ve bir çıktı katmanını içerir. Girdi sinyalleri ağ boyunca bir katmandan diğer katmana ileri yönde yayılırlar (Şekil 2.4).



Şekil 2.4. Çok katmanlı algılayıcı

Ağın farklı katmanları boyunca ileri ve geri yayılım olarak adlandırılan iki geçiş bulunur. İleri yayılımda, bir girdi vektörü ağın giriş katmanına uygulanır ve bu girdinin etkisi ağda katmandan katmana yayılır. İleri yayılım sırasında ağın sinaptik ağırlıkları belirlidir. Geri yayılımda sinaptik ağırlıkların tümü bir hata-düzeltilme kuralı ile uyumlu olarak düzenlenir. Bir hata sinyali üretmek için ağın gerçek çıktısı istenilen bir çıktıdan çıkartılır. Bu hata sinyali sinaptik bağlantıların tersi yönünde ağda geriye doğru yayılır. Sinaptik ağırlıklar ağın gerçek çıktısını istatistiksel anlamda arzu edilen çıktıya yakın hale getirmek için düzenlenir (Şekil 2.5).



Şekil 2.5. Sinyal akış gösterimi

ÇKA'nın üç ayırt edici özelliği bulunur.

- 1- Ağdaki her nöron modeli doğrusal olmayan bir aktivasyon fonksiyonuna sahiptir. Bu fonksiyon çoğunlukla lojistik fonksiyon $y = 1/(1 + \exp(-v_i))$ kullanılır. Problemin doğrusal olmaması önemlidir, eğer doğrusal ise zaten tek katmanlı algılayıcı ile çözülebilir.
- 2- Bir ağ bir ya da daha fazla gizli katman içerebilir. Bu gizli katmanlar giriş ya da çıkış arasında bulunurlar. Katman sayısını problemin zorluk derecesi belirler.
- 3- Ağdaki nöronlar arası bağlantılar yüksek derecedir, ağ bağlantısındaki bir değişiklik, nöron bağlantı sayılarını ve onların ağırlıklarındaki değişikliği gerektirir.


ÇKA için çok farklı öğrenme kuramları geliştirilmiş ve pek çok probleme uygulanmıştır ancak ÇKA bütün problemleri çözebilir diyemeyiz.

Fonksiyon sinyali giriş sinyalidir, ağdaki her şey onunla hesaplanır. Hata Sinyali, çıkış nöronundan başlayarak geriye doğru akmaktadır. Gizli katmanlar ağın giriş ve çıktı katmanları arasında bulunurlar. Gizli katmanlar ve çıktı katmanı giriş sinyallerini çıkış nöronlarına taşımak için kullanılırlar.

ÇKA'da doğrusal olmamanın varlığı ve ağın üst düzeydeki ilişkiselliği ağların teorik analizini üstesinden gelinmesi zor bir durum yapmaktadır. Ayrıca gizli nöronların kullanımı öğrenme sürecinin canlandırılmasını zorlaştırır, çünkü olası fonksiyonların aranması daha geniş bir uzayda gerçekleştirilmelidir [20-21, 41].

2.1.2.5. Geriye yayılım algoritması

Yapay sinir ağlarında eğitim işlemine başlarken ağırlık ve bias değerleri rasgele verilir. Ağa örnekler sunulur ve bilgi ileri doğru yayılır, çıktı katmanındaki nöronlarda hata değeri bulunur (Şekil 2.6).



Şekil 2.6. Geri yayılım algoritması

Çıktı nöronunda n . eğitim basamağında oluşan hata (e), istenilen çıktıdan (d) hesaplanan çıktının (y) çıkarılması ile hesaplanır (Eşitlik 2.3).

$$e_j(n) = d_j(n) - y_j(n), \quad j \text{ nöronu bir çıktı düğümüdür.} \quad (2.3)$$

Elde edilen bu hataların anlık hata enerjileri $e_j^2(n)/2$ ifadesi ile hesaplanır. Toplam hata enerjisi bütün nöronlardaki anlık hata enerjilerinin toplanması ile elde edilir. Hata kareler ortalaması, toplam hata enerjilerinin (ε_{ort}) bulunup eğitim küme sayısı N 'ye göre normalize edilmesi ile hesaplanır (Eşitlik 2.4).

$$E(n) = \varepsilon_{ort} = \frac{1}{N} \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.4)$$

Öğrenme sürecinin amacı hatayı minimize edecek ağırlık ve bias değerlerini ayarlamaktır. Bu işlem yapılırken eğitim setlerinin hepsi ağa bir kez sunulur, serbest parametreler ondan sonra ayarlanır ya da sunulan her örnekten sonra ağırlık ve bias değerleri güncellenir. Ağırlıklara yapılan düzenlemeler ağa sunulan her örnek için hesaplanan hatayla uyumlu olarak yapılır.

Geri besleme algoritmasında ağırlık ve bias değerlerini güncellemek için düzeltme değeri ($\Delta w_{ji}(n)$), hatanın ağırlıklara göre kısmi türevinin alınması ($\partial \varepsilon(n) / \partial w_{ji}(n)$) ile hesaplanır (Eşitlik 2.5).

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'(v_j(n)) y_i(n)$$

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (2.5)$$

$$\delta_j(n) = -e_j(n) \varphi'(v_j(n)) \quad (2.6)$$

“Eş. 2.5” de kullanılan η , geri besleme algoritmasının öğrenme oranı parametresidir, eksi işareti ağırlık uzayındaki hatayı düşürecek ağırlık değişimi için yön arayan gradyan azalanı ifade eder. Lokal gradyan ($\delta_j(n)$), ilgili nöron için karşılık gelen hata sinyali $e_j(n)$ ve ilgili aktivasyon fonksiyonunun türevinin $\phi'(v_j(n))$ çarpımına eşittir (Eşitlik 2.6).

Düzeltilme değeri, lokal gradyanların kullanımı ile “Eş. 2.7” deki ifade edilir.

$$\Delta w_{ji}(n) = -\eta \delta_j(n) y_i(n) \quad (2.7)$$

Ağ eğitim esnasında hata yüzeyi sabit bir noktada takılı kalabilir, minimum hataya yakınsayamayabilir. Bunu engellemek için düzeltme değerine, momentum katsayısı olarak ifade edilen bir değer eklenir (Eşitlik 2.8).

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) - \eta \delta_j(n) y_i(n) \quad \alpha \text{ momentum katsayısı} \quad (2.8)$$

Elde edilen bu düzeltme değeri eski ağırlıklara eklenerek yeni ağırlık değerleri elde edilir. Bu işlem doğru ağırlık değerleri elde edilene kadar devam eder [20-21, 42].

2.1.2.6. Hızlı öğrenme algoritmaları

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, hata fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için hata fonksiyonunun gradyanını ($\nabla \epsilon(w)$) kullanırlar (Eşitlik 2.9).

$$\nabla \epsilon(w) = \left[\frac{\partial \epsilon}{\partial w_1}, \frac{\partial \epsilon}{\partial w_2}, \dots, \frac{\partial \epsilon}{\partial w_n} \right] \quad (2.9)$$

Geriye yayılım algoritması ağ boyunca gradyan hesaplamalarını geriye doğru yapar. Bu algoritmada ağırlıklar, hata fonksiyonunun azalması yönünde kullanılır. Gradyan

azaltma ya da momentumlu gradyan azaltma teknikleri bazı problemleri çözmekte yavaş kalmaktadır.

Bunun için kullanılan yöntemlerden biri sabit olarak girilen öğrenme katsayısının değiştirilmesine dayanan geri yayılım yöntemidir. Öğrenme katsayısı çok büyük seçilirse öğrenme işleminin kararsız olmasına sebep olurken, küçük değerler seçilirse öğrenme çok geç yakınsayacaktır. İlk olarak, ağa giriş verileri sunulduktan sonra hata hesaplanır ve bu hata üzerinden ağırlık ve bias değerleri güncellenir. Veriler tekrar ağa sunulur, çıktı ve hata tekrar belirlenir. Eğer ağ hatası eski hatadan çok büyük olur ise yeni ağırlıklar ve bias güncelleme değeri göz ardı edilir, öğrenme katsayısı belli bir oranda küçültülür [43-46]. Eğer ağ hatası eski hatadan küçükse, öğrenme katsayısı artırılır (Eşitlik 2.10).

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (2.10)$$

En dik iniş gradyan azaltma yönteminde kullanılan sigmoid aktivasyon fonksiyonunun etkisi gradyan değerlerinin çok küçük olmasına, dolayısıyla ağırlık ve bias değerlerinin çok küçük değerlerle değiştirilmesine sebep olmaktadır, en uygun ağırlık ve bias değerlerinin bulunması zorlaşmaktadır. Esnek geriye yayılım algoritmasında ağırlık değerleri dışardan düzenlenebilen farklı bir değer ($\Delta_{ij}(n)$) ile düzenlenir [47]. Bu değer, performansın türevi bir önceki iterasyondaki değerden farklı ise belli bir oranda artırılır ya da azaltılır, değişim yok ise aynı kalır (Eşitlik 2.11).

$$\Delta w_{ij}(n) = \text{sign}\left(\frac{\partial E}{\partial w_{ij}}(n)\right) * \Delta_{ij}(n) \quad (2.11)$$

Eşlenik gradyan algoritmaları, en dik iniş yönteminden farklı olarak gradyanların hangi yönde ne kadar hareket edeceğini belirler. Doğru arama yönü bulunduğunda, bu yön boyunca hata fonksiyonunun minimumunu bulmak mümkündür. Bütün

eşlenik gradyan yöntemlerinde, ilk adımda p_k negatif gradyan değeri (g) alınarak arama yönüne başlanır [44-46, 48]. Yeni ağırlıklar “Eş. 2.12” deki gibi hesaplanır. Gradyanların ne kadar hareket edeceğini α_k hesaplar.

$$w_{k+1} = w_k + \alpha_k p_k \quad (2.12)$$

Bir sonraki adımda arama yönü, önceki arama yönünü kullanarak “Eş. 2.13” deki gibi hesaplar.

$$g = \nabla \varepsilon(w)$$

$$p_k = -g_k + \beta_k p_{k-1} \quad (2.13)$$

Arama yönünü etkileyen en önemli değişken olan β_k değeri üç farklı yöntemle “Eş. 2.14”, “Eş. 2.15” ve “Eş. 2.16” daki gibi gradyan (g) değerleri aracılığıyla hesaplanır.

$$\beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}}, \text{ (Fletcher ve Reeves'e göre)} \quad (2.14)$$

$$\beta_k = \frac{(g_k - g_{k-1})^T g_k}{g_{k-1}^T g_{k-1}}, \text{ (Polak ve Ribiere'e göre)} \quad (2.15)$$

$$\beta_k = \frac{(g_k - g_{k-1}) g_k^T}{(g_k - g_{k-1})}, \text{ (Powell-Beale'e göre)} \quad (2.16)$$

Hesaplanan gradyan değerleri ağırlık ve bias değerlerini güncellemek için kullanılır (Eşitlik 2.17).

$$\Delta w_k = -\eta g_k + \alpha \Delta w_{k-1} \quad (2.17)$$

2.1.2.7. Newton öğrenme algoritması

Newton öğrenme algoritması, hızlı eğitim algoritmalarından biridir, toplam hata fonksiyonunu minimize etmek için “Eş. 2.18” deki gibi hata fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinin alınmasıyla oluşan Hessian matrisini (H) kullanır.

$$H = \Delta^2 \varepsilon(w) \quad (2.18)$$

“Eş. 2.19” daki gibi Hessian matrisinin tersi (H^{-1}) ile ağırlıklar güncellenir.

$$w(n+1) = w(n) - H^{-1}(n)g(n) \quad (2.19)$$

Çok karmaşık ileri beslemeli bir ağda ikinci dereceden türevlerle işlem yapmak oldukça zor olacaktır. Quasi-Newton yöntemi ile Hessian matrisinin yaklaşık değeri kullanılarak bu problem aşılır (Eşitlik 2.20).

$$H(n) = J^T(n)J(n) + \delta I \quad (2.20)$$

“Eş. 2.20” kullanılan Jakobiyen matris (J) ağ hatalarının ağırlıklara göre birinci dereceden türevinin alınması ile belirlenir. Yeni ağırlıklar, Hessian matrisine göre daha kolay hesaplanabildiği için Jakobiyen matris ile yeniden düzenlenir (Eşitlik 2.21).

$$w(n+1) = w(n) - (H)^{-1} J^T(n)e(n) \quad (2.21)$$

Bu yöntem, en dik gradyan azalış yöntemlerine göre daha hızlı yakınsama özelliğine sahiptir, eşlenik gradyan kadar hızlı bir öğretim algoritmasıdır [44-46, 49].

2.1.2.8. Levenberg-Marquardt algoritması

Eşlenik gradyan ve Newton yöntemlerinin iyi yanlarını alarak oluşturulan hata fonksiyonunu minimize etme işlemini hızlı gerçekleştiren algoritmalarından biridir. İki yöntemin de iyi yanlarına sahip olduğu için oldukça hızlı ve çok kullanılan bir yöntemdir. Quasi-Newton yöntemi gibi Hessian matrisi yaklaşık değeri olan Jakobiyen matrisini kullanır (Eşitlik 2.22).

$$H(n) = J^T(n)J(n) + \mu I \quad (2.22)$$

Elde edilen yakınsak bu değerle ağırlık ve bias değerleri güncellenir (Eşitlik 2.23).

$$w(n+1) = w(n) - (H)^{-1} J^T(n)e(n) \quad (2.23)$$

“Eş. 2.22” de kullanılan μ Marquardt parametresi Hessian matrisi hesaplanırken kullanılır ve hata fonksiyonu azaldıkça azaltılır [50–51].

2.1.3. Korelasyon Katsayısı ve Regresyon

Korelasyon analizi, iki ya da daha çok değişken arasında ilişki olup olmadığını, ilişki varsa yönünü ve gücünü incelemektedir. Regresyon analizi, değişkenlerden birisi belirli bir birim değiştiğinde diğerinin nasıl bir değişim gösterdiğini incelemektedir. Yapay sinir ağlarının performansını ölçmek için bu yöntemler yaygın olarak kullanılmaktadır.

Korelasyon katsayısı (r) iki değişken arasındaki ilişkinin ölçüsüdür, -1 ve +1 arasında değişim gösterir. Korelasyon katsayısı 0,5-1,0 arasında ise değişkenler arasında ilişki kuvvetlidir, negatif yönde elde edilen değerler değişkenler arasında ters yönde ilişki olduğunu ifade eder.

Regresyon analizi, bilinen bulgulardan, bilinmeyen gelecekteki olaylarla ilgili tahminler yapılmasına izin verir. Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi ve doğrusal eğri kavramını kullanarak, bir tahmin eşitliği geliştirir. Değişkenler arasındaki ilişki belirlendikten sonra, bağımsız değişkenlerin katsayıları bulunursa bağımlı değişkenin değeri tahmin edilebilir [52].

Bağımlı değişken (y) ile bağımsız değişken (x) arasındaki doğrusal ilişkiyi açıklayan tek değişkenli regresyon modeli “Eş. 2.24” deki gibidir.

$$y = a + bx \quad (2.24)$$

“Eş. 2.24” de kullanılan a parametresi bağımsız değişken sıfır iken bağımlı değişkenin alacağı değeri, b parametresi ise bağımsız değişken bir birim artarken bağımlı değişkendeki değişim miktarını yani doğrunun eğimini ifade etmektedir.

2.1.4. Lojistik Regresyon

LR analizi, en az değişkeni kullanarak en iyi uyuma sahip olacak şekilde bağımlı ile bağımsız değişkenler arasındaki ilişkiyi tanımlayabilen ve biyolojik olarak kabul edilebilir matematiksel model kurma yöntemidir.

Kümeleme, diskriminant ve LR analizleri, gözlemlerin gruplara atanmasında kullanılan yöntemlerdir. Kümeleme analizinde gözlemlerin atanacağı küme sayısı tam bilinmez. Diskriminant analizi ise bağımlı ve bağımsız değişkenlerin sürekli olmalarını ister. LR analizinde bağımsız değişkenler sürekli ya da kesikli olabilirler. Bağımsız değişken kesikli, mantıksal bir ifade ise lojistik regresyon analizi özellikle tercih edilir. Doğrusal regresyon analizinde bağımlı değişkenin değeri kestirilirken, LR analizinde bağımlı değişkenin alacağı değerlerden birinin gerçekleşme olasılığı kestirilir. Bunun için “Eş. 2.25 “ kullanılır.

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} \quad (2.25)$$

Lojistik regresyondaki bağımsız değişkenlere ait katsayılar kestirildikten sonra, olasılık fonksiyonları kullanılarak gözlenen değerlerle kestirilen değerler karşılaştırılır ve yorumlanır.

Lojistik regresyon analizi, özellikle tıp biliminde bağımlı değişken iki ya da daha çok düzey içerdiğinde, bağımsız değişkenlerin ise hem kesikli hem de sürekli olabildiği durumlarda verileri ait oldukları gruplara en doğru şekilde atayacak ve hastalıklara ilişkin risk faktörlerini belirleyebilecek modeli kurmayı amaçlar [52-54].

2.1.5. Receiver Operating Characteristics (ROC)

ROC eğrisi, tanı testlerinin performanslarının değerlendirilmesi ve kıyaslanması için yaygın olarak kullanılan bir yöntemdir. ROC eğrisi yöntemi, tanı testinin sınıflandırma performansının 2 boyutlu grafiksel gösterimidir. Tıbbi testlerde sonuçlar pozitif ya da negatif olarak gruplandırılır. Bu gruplar oluşturulurken örnek pozitif ise Doğru Pozitif (DP), örnek pozitif ancak negatif bulunmuşsa Yanlış Negatif (YN), örnek negatif ve negatif sınıflandırılmışsa Doğru Negatif (DN), örnek negatif ancak pozitif sınıflandırılmış ise Yanlış Pozitif (YP) olarak gruplandırılarak sınıflama tabloları oluşturulur (Çizelge 2.3).

Çizelge 2.3. Tıbbi testlerin analizinde kullanılan sınıflama tablosu

		Gerçek Durum	
		Pozitif	Negatif
Tahmin Edilen Durum	Pozitif	DP	YP
	Negatif	YN	DN

Tanı testlerinin değerlendirilmesinde bu tablolardan elde edilen belirlilik (specificity), duyarlılık (sensitivity), doğruluk oranı (accuracy) değerleri çok önemlidir. Belirlilik oranı, bir testin gerçekten hasta olmayanları ayırabilme yeteneğini belirten orandır (Eşitlik 2.26).

$$\text{Belirlilik} = P(B) = \frac{DN}{DN+YP} \quad (2.26)$$

Duyarlılık oranı, gerçekten hasta olanların test tarafından hangi oranda saptanabildiğini belirten orandır (Eşitlik 2.27).

$$\text{Duyarlılık} = P(D) = \frac{DP}{DP+YN} \quad (2.27)$$

Doğruluk oranı bir testin hasta kişileri hasta, hasta olmayanları hasta değil olarak sınıflandırma oranıdır ve testin tanı amaçlı ne kadar güvenle kullanılabileceğini ifade eder (Eşitlik 2.28).

$$\text{Doğruluk} = P(DO) = \frac{DP+DN}{N} \quad (2.28)$$

ROC eğrileri, uygun kesim noktalarının oluşturulan sınıflandırma tablolarındaki belirlilik ve duyarlılık değerlerine bakılarak oluşturulurlar. ROC eğrisi altında kalan alan (AUC) testin başarısını ifade etmekte kullanılır. Tıp alanında tahmin ve sınıflandırma amaçlı YSA kullanımında sadece doğruluk değerlendirmesi yapmak yeterli olmayacaktır. YSA'nın başarısı ROC eğrileri, duyarlılık, belirlilik ve doğruluk sonuçlarına bakılarak da değerlendirilmelidir [55-58].

3. MATERYAL VE YÖNTEM

Bu çalışmada Ankara Numune Eğitim ve Araştırma Hastanesi, Ankara Onkoloji Eğitim ve Araştırma Hastanesi'ne başvuran 270 hastanın bilgilerini içeren veri seti kullanılmıştır. Veri setinin yapay sinir ağı ve lojistik regresyon ile analizi yapılmıştır.

3.1. Materyal

Çalışmada kullanılan veri seti meme kanseri hastalarının bilgilerini içermektedir. Hastaların koltuk altı lenf nodu durumları SLNB cerrahi işlemleri uygulandığı için bilinmemektedir. Uzman doktor tarafından YSA ve LR analizleri için veri setinden dokuz özellik seçilmiştir. Veri seti düzenlenerek eksik ve aynı olan veriler veri setinden çıkarılmıştır. Bu eleme işlemi sonrasında 270 meme kanseri hastasının verileri %80'i eğitim ve %20'si test veri seti olarak ikiye ayrılmıştır. Analizler için seçilen giriş bilgileri, hastanın T evresi bilgisi (TE), tümörün çapı (TÇ), tümörün derecesi (TD), hastanın menopoz durumu (MD), lenf yollarındaki yayılım (LY), tümörün tipi (TT), hastanın yaşı (Y), hastanın yaşının elliden büyük olup olmadığı (E) bilgisidir. Çıkış ise hastanın koltuk altı lenf nod durumudur (Çizelge 3.1).

Yapay sinir ağı ile koltuk altı lenf nodu belirleme işlemi, Matlab Neural Network Toolbox™ 6.0 fonksiyonları aracılığıyla, Lojistik Regresyon analizi SPSS 13.0 programı ile gerçekleştirilmiştir.

3.2. Metot

YSA mimarisi için çok katmanlı ileri yayımlı yapay sinir ağı tercih edilmiştir. YSA eğitim ve test işlemleri, Matlab Gui üzerinde gerçekleştirilen program aracılığı ile yapılmıştır.

216 kişiye ait giriş ve çıkış verileri YSA içinde sonlu sayılarla ifade edebilmek için 0 ile 1 arasına normalize edilmiştir.

Çizelge 3.1. Veri setinin özellikleri

Değişken	Tanım	Özellikler	Sayı	%	Ort.	S.S	Min	Max
LND	Koltuk Altı Lenf Nod Yayılım Durumu	0-yok	160	59,3	-	-	-	-
		1-var	110	40,7				
TE	T Evre Bilgisi	1-T1	70	25,9	-	-	-	-
		2-T2	169	62,6				
		3-T3	31	11,5				
TÇ	Tümör Çapı	Sayısal	270	100	3,43	1,67	0,8	10
TD	Tümör Histolojik Derecesi	1-G1	71	26,3	-	-	-	-
		2-G2	138	51,1				
		3-G3	61	22,6				
EL	Yaş(<50,>=50)	1, <50	144	53,3	-	-	-	-
		2, >=50	126	46,7				
MD	Menopoz Durumu	1-premenepoz	119	44,1	-	-	-	-
		2-postmenepoz	151	55,9				
LY	Lenfatik Yayılım Durumu	0-yok	190	70,4	-	-	-	-
		1-var	80	29,4				
TT	Tümör Tipi	1-ductal	232	85,9	-	-	-	-
		2-lobüler	2	0,7				
		3-mixed	9	3,3				
		4-otipik medullar	1	4				
		5- özel tip	25	9,3				
		6-dcis	1	4				
TY	Tümör Yerleşim	1-sağ/sol UDK	156	57,8	-	-	-	-
		2-sağ/sol ADK	24	8,9				
		3-sağ/sol UIK	65	24,1				
		4-sağ/sol AIK	15	5,6				
		5-areola	10	3,7				
Y	Yaş	Sayısal	270	100	48,3	9,57	25	75

Ağın eğitimi için esnek geriye yayılım algoritması (Resilient Backpropagation-trainrp), öğrenme katsayısı değişen geriye yayılım algoritması (Variable Learning Rate Backpropagation-trainrlda), eşlenik gradyan öğrenme algoritmaları (Conjugate Gradient Algorithms-traincgf-traincgb-traincgp-trainscg), Quasi-Newton öğrenme algoritmaları (Quasi-Newton Algorithms-trainbfg-trainoss), Levenberg-Marquardt öğrenme algoritması (Levenberg-Marquardt-trainlm) seçilmiştir. Algoritmaların sahip oldukları düzenlenebilir parametreler program üzerinden değiştirilmektedir (Şekil 3.1).

Eğitim seti içindeki her giriş değerinin ağa sunumu rasgele yapılmıştır. Ağın başlangıç ağırlık ve bias değerleri 0–1 arasında rasgele belirlenmiştir. Ağın eğitimde en önemli işlem gizli katman sayısının, katmanlardaki hücre sayısının ve hücre

aktivasyon fonksiyonlarının belirlenmesi işlemidir. Gizli katman ve hücre sayıları deneme yanılma işlemi ile belirlenmektedir. Katman sayısı problemin güçlüğüne göre artırılır, ancak sayının fazla olması işlem süresini uzatmaktadır ve ağıın ezberlemesine sebep olabilmektedir. Eğitim işleminde amaç minimum hataya az sayıda gizli katman ve nöronlar ile ulaşılmasıdır. ÇKA için transfer fonksiyonu olarak hiperbolik tanjant (tansig) kullanılmıştır.



Şekil 3.1. Eğitim algoritmasının özellik değişim penceresi

Ağıın performans fonksiyonu olarak hataların kareleri ortalaması (mean squared error-mse) seçilmiştir. Yeni ağırlıkların hesaplanması işleminde kullanılan η öğrenme katsayısı 0,01 olarak seçilmiştir. Sıralı eğitim modu, algoritma kolaylığı, zor ve güç problemleri çözme başarısından dolayı tercih edilmiştir.

YSA'nın eğitimi esnasında ağıın ezberlemesi ya da öğrendiklerini unutması problemleri oluşabilmektedir. Bunu engellemek için durdurma kriterleri kullanılmaktadır. YSA'da eğitim esnasında, ağıın iterasyon sayısı belli bir değere ulaşınca, eğitim süresi belli bir değeri aşınca, ağı minimum hataya ulaşınca ya da

minimum performans gradyan değeri elde edildiğinde durdurulabilir. Diğer bir yöntem çapraz-geçerleme yöntemidir. Bu yöntem ile ağ eğitilirken geçerleme veri kümesi ile bağımsız olarak eş zamanlı test edilir ve eğitim hataları azalırken geçerleme hataları artıyor ise eğitim durdurulur, ancak bu yöntem küçük veri setleri için çok önerilmemektedir. Durdurma kriteri olarak minimum hata değeri 0,001, minimum performans gradyan değeri 10^{-10} alınmıştır [59-62].

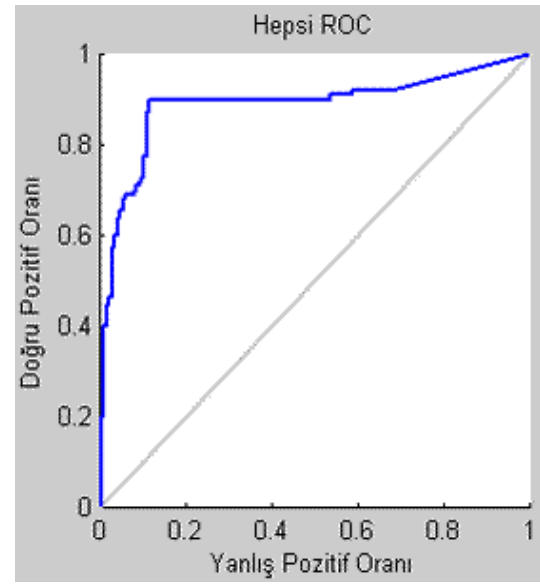
Oluşturulan ağın performansı ağın hiç görmediği test verilerine karşı oluşturduğu sonuçlarının değerlendirilmesi ile belirlenmektedir. Eğitim ve test veri sonuçlarının doğruluğu Regresyon ve ROC eğrisi istatistik analiz yöntemleri ile değerlendirilmiştir. Performans ölçmek için korelasyon katsayısı r değeri ve ROC eğrilerini oluşturulan sınıflandırma tabloları kullanılmıştır (Şekil 3.2).

Aynı özelliklere sahip YSA modelleri tekrar çalıştırıldığında çok farklı sonuçlar oluşmaktadır. Bunun için her yapı en az 100 kez çalıştırılmış, oluşan ağ yapılarından en yüksek korelasyon ve doğruluk değerlerine sahip olan belirlenmiştir.

Yapay sinir ağı ile karşılaştırma yapabilmek amacıyla LR istatistiksel analiz yöntemi kullanılmıştır. Eğitim için ayrılan veri setindeki bağımlı ve bağımsız değişkenler arasındaki ilişkiyi belirleyecek katsayıları bulmak için SPSS ile adım adım ve ileriye doğru seçim yöntemleri kullanılarak modeller oluşturulmuştur. Wald testleri ile modellerdeki katsayıların doğrulukları ve Hosmer-Lemeshow yöntemi ile modellerin geçerliliği değerlendirilmiştir. Modellerin karşılaştırılması için “Cox ve Snell R^2 ” ve “Nagelkerke R^2 ” yöntemleri kullanılmıştır. Oluşturulan modeller test verileri ile test edilmiştir. Bağımlı değişkenlerin anlamlılık düzeylerini belirleyen Pearson katsayısı 0,15 olarak alınmış ve anlamlı bulunan giriş verileri ile tekrar LR analizi yapılmış, model test verileri ile test edilmiştir.

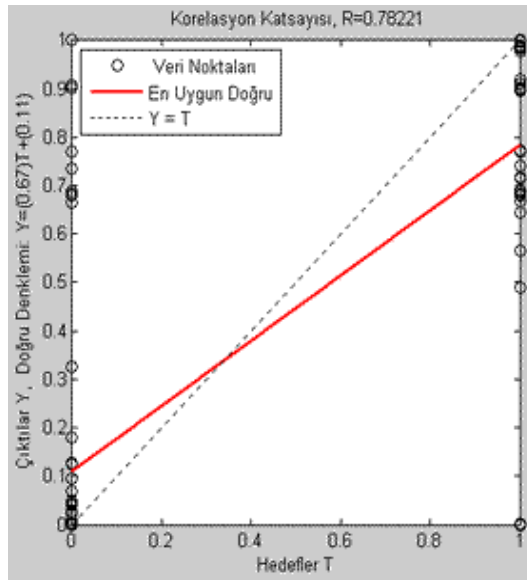
Eđitim Hata Matrisi

Çıktı Sınıfı	1	83 38.4%	17 7.9%	83.0% 17.0%
	2	9 4.2%	107 49.5%	92.2% 7.8%
		90.2% 9.8%	86.3% 13.7%	88.0% 12.0%
		1	2	
		Hedef Sınıfı		



a)

b)



c)

Şekil 3.2. a) Sınıflandırma tablosu, b) ROC eğrisi, c) Regresyon doğrusu

4. BULGULAR VE TARTIŞMA

Yapılan çalışmada öncelikle meme kanseri hastalarına ait eğitim veri seti ile LR analizi yapılmış ve hangi verilerin daha anlamlı olduğu belirlenmiştir. Aynı zamanda uzman doktor tarafından belirlenen özellikler ile çok katmanlı geri yayımlı yapay sinir ağları oluşturulmuş, ağların performansları ROC eğrileri ve korelasyon katsayıları ile karşılaştırılarak doğru yapay sinir ağı yapısının belirlenmesi sağlanmıştır. LR analizi ile belirlenen anlamlı verilerle tekrar yapay sinir ağları oluşturulmuş ve test verileri ile test edilmişlerdir. Belirlenen yapay sinir ağı modeli farklı bir veritabanı ile denenerek modelin geçerliliği belirlenmiştir.

4.1. Meme Kanseri Verileri ile Lojistik Regresyon Analizi

Uzman doktor tarafından belirlenen verilerle oluşturulan eğitim seti, SPSS programı aracılığıyla LR analizi için kullanılmış ve karşılaştırma yapabilmek amacı ile iki model oluşturulmuştur. İlk model, adım adım hangi bağımlı değişkenlerin bağımsız değişkenler üzerinde etkili olduğunu belirlemek için oluşturulmuştur. Modelde denkleme giren değişkenler Çizelge 4.1’de belirlenmiş katsayıların doğruluk testleri Wald testi ile belirlenmiş, Wald testi için anlamlılık düzeyi 0,15 alınmıştır.

Çizelge 4.1. I.Model için denkleme giren ve girmeyen değişkenler

	Denklem Katsayısı (B)	Wald	s.d	Önem Düzeyi p<0.15	Exp(B)	95,0% Exp(B) için Güven Sınırı	
						En düşük	En yüksek
TE	0,760	1,184	1	0,277	2,139	0,544	8,410
TÇ	-0,209	0,735	1	0,391	0,811	0,503	1,309
TD	-0,487	4,286	1	0,038*	0,615	0,388	0,974
EL	1,218	2,897	1	0,089*	3,381	0,831	13,751
MD	-2,224	11,546	1	0,001*	0,108	0,030	0,390
LY	1,864	24,198	1	0,000*	6,451	3,069	13,557
TT	-0,161	1,436	1	0,231	0,851	0,654	1,108
TY	-0,043	0,103	1	0,748	0,958	0,735	1,247
Y	-0,007	0,079	1	0,779	0,993	0,945	1,043
Sabit	1,629	1,571	1	0,210	5,100		

*Oluşturulan I. model denklemine giren değişkenleri ifade etmektedir.

Birinci modelde hastaların tümör derece (TD), yaş elli bilgisi (EL), menopoz durumu (MD), lenf yollarındaki yayılım (LY) verileri koltuk altı lenf nodunu belirlemek için anlamlı bulunmuştur. Oluşturulan model denklemi “Eş. 4.1“ de verilmiştir.

$$\hat{Y} = 1,629 - 0,487*TD + 1,218*EL - 2,224*MD + 1,864*LY \quad (4.1)$$

İkinci modelde ileriye doğru seçim yöntemi ile adım adım gereksiz olan değişkenlerin modelden çıkarılması ile uygun katsayıları içeren doğru denklem elde edilmeye çalışılmıştır (Çizelge 4.2).

Çizelge 4.2. II. Model için denkleme giren değişkenler

	Denklem Katsayısı (B)	Wald	s.d.	Önem Düzeyi p<0.15	Exp(B)	95,0% Exp(B) için Güven Sınırı	
						En düşük	En yüksek
TD	-0,429	3,552	1	0,059	0,651	0,417	1,017
EL	1,053	2,782	1	0,095	2,865	0,832	9,869
MD	-2,252	12,534	1	0,000	0,105	0,030	0,366
LY	1,885	28,545	1	0,000	6,589	3,299	13,157
Sabit	1,813	7,102	1	0,008	6,129		

Çizelge 4.2'ye göre oluşturulan denklem “Eş 4.2“ de verilmiştir.

$$\hat{Y} = 1,813 - 0,429*TD + 1,053*EL - 2,252*MD + 1,885*LY \quad (4.2)$$

Oluşturulan modeller Hosmer ve Lemeshow anlamlılık testinde anlamlılık düzeyleri 0,05 büyük olduğu için anlamlı bulunmuştur (Çizelge 4.3).

Çizelge 4.3 Modellerin Hosmer ve Lemeshow testi sonuçları

Adım	Ki-kare	s.d	Sig.
I. Model	6,875	8	0,550
II. Model	3,173	7	0,869

Oluşturulan iki model de tam veri setine uygulanmış ve test veri setleri ile analiz edilmiştir. Anlamlı bulunan verilerle oluşturulan sınırlı eğitim ve test veri setlerine


uygulanan modellerin duyarlılık, belirlilik ve doğruluk sonuçları Çizelge 4.4'te verilmiştir. I. modelin meme kanseri hastalarının koltuk altı lenf nod durumunu belirleme belirlilik ve doğruluk oranı %82,3, %73,1 iken ikinci modelin belirlilik ve doğruluk oranı %75,8, %69,0 olarak elde edilmiştir. Tanı testlerinde belirlilik değeri %50 oranını kesinlikle aşmalıdır, tanı ile yüksek ilişki kurulabilmesi içinde %75 - %100 arasında olmalıdır [52, 57-58]. İlk modelde tanı ile değişkenler arasında yüksek ilişki değerinin sağlandığı söylenebilir. Önceki çalışmalarda yapay sinir ağları ile ya da farklı istatistiksel analizler ile koltuk altı nod durumunu belirlemek için oluşturulan modellerin doğruluk sonuçları, oluşturulan modellerin doğruluklarından yüksek çıkmıştır. Bunun sebebi bu çalışmada kullanılan verilerin içerisinde hastaların gen bilgilerinin olmamasıdır.

Çizelge 4.4 İki modelin tam ve sınırlı veri setleri analiz sonuçları

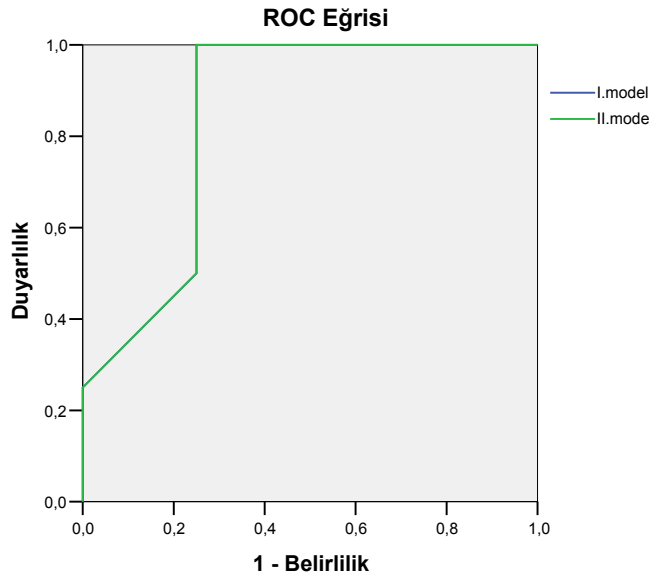
		Duyarlılık	Belirlilik	Doğruluk	AUC
I. Model	Tam Eğitim Seti	60.9	82.3	73.1	0,783
	Tam Test Seti	50.0	86.1	74.1	0,758
	Sınırlı Eğitim Seti	61.5	76.9	69.2	0,692
	Sınırlı Test Seti	75.0	75.0	75.0	0,844
II. Model	Tam Eğitim Seti	59.8	75.8	69.0	0,771
	Tam Test Seti	50.0	83.3	72.2	0,799
	Sınırlı Eğitim Seti	61.5	76.9	69.2	0,692
	Sınırlı Test Seti	75.0	75.0	75.0	0,844

Oluşturulan modellerin tam test seti ve sınırlı test veri seti ile elde edilen sonuçlarını gösteren ROC eğrileri Şekil 4.1 ve Şekil 4.2'de gösterilmektedir. ROC eğri altında kalan alan AUC değerinin 0,75-1,0 arasında olması yapılan analizin yüksek oranda başarılı olduğunu göstermektedir. Şekil 4.1'de I. model için tam test seti AUC değeri, 0,758, II. model için 0,79 bulunmuştur. Şekil 4.2'de I. model için sınırlı test seti AUC değeri, 0,75, II. model için 0,75 bulunmuştur.

Oluşturulan modellerin doğruluk sonuçları birbirine çok yakın elde edildiği için, modellerin kıyaslanması Cox-Snell R^2 ve Nagelkerke R^2 ile yapılmıştır. I. model olan adım adım seçim yönteminin R^2 sonuçları daha iyi elde edildiğinden, I. model geçerli sayılmıştır (Çizelge 4.5).



Şekil 4.1. Modellerin tam test seti ROC eğrileri



Şekil 4.2. Modellerin sınırlı test seti ROC eğrileri

Çizelge 4.5. Modellerin kıyaslanması

Modeller	-2 Log olabilirlik	Cox & Snell R Kare	Nagelkerke R Kare
I. Model	238,287	0,230	0,309
II. Model	241,632	0,218	0,293

4.2. Meme Kanseri Verileri ile Yapay Sinir Ağı Analizi


Yapay sinir ağı için 9 giriş değerinin girildiği giriş katmanı, bir gizli katman ve çıktı katmanı oluşturulmuştur. Giriş ve çıkış değerleri 0–1 arasında normalize edilmiştir. Gizli ve çıktı katmanındaki nöronlar için aktivasyon fonksiyonu olarak hiperbolik tanjant seçilmiştir. İleri yayımlı, hatayı geriye yayan çok katmanlı yapay sinir ağı modeli için 9 hızlı eğitim algoritması seçilmiştir.

Levenberg–Marquardt eğitim algoritması için Matlab trainlm fonksiyonu kullanılmıştır. Doğru yapının tayini için farklı nöron sayılarından oluşan ağlar oluşturulmuştur ve test verileri ile test edilmişlerdir. Performans analizi için kullanılan korelasyon katsayıları, duyarlılık, belirlilik, doğruluk ve ROC eğrisi alan sonuçları Çizelge 4.6’da verilmiştir. Korelasyon katsayısı (r) değerinin 0,7-1,0 arasında olması bağımsız değişkenlerle bağımlı değişken arasındaki ilişkinin yüksek olduğunu ifade etmektedir. Çizelge 4.6’da eğitim seti için r değeri gizli katmandaki nöron sayısı arttıkça yükselmektedir. Ancak oluşturulan ağlar test seti ile test edildiklerinde gizli katmanda 5, 6, 7, 8, 9, 10 nöron içeren ağlarda r değeri düşmektedir. Bu durum bu ağların ezberlediğini ya da öğrendiğini unuttuğunu göstermektedir. 4 nöronlu gizli katman eğitim ve test sonuçlarının r değeri eğitim seti için 0,784, test seti için 0,872 olarak elde edilmiştir. Korelasyon katsayısının 0,75 değerinden yüksek olması, belirlilik, doğruluk ve alan değerlerinin %97,22, %94,44, 0,954 olması bu ağın performansının yüksek olduğunu göstermektedir.

Levenberg–Marquardt eğitim algoritması ile oluşturulan ağların test veri ROC eğrileri Şekil 4.3’te verilmiştir. ROC eğrileri altında kalan alanlar kıyaslandığında gizli katmanda 4 nöron içeren ÇKA’nın 0,954 olan AUC değerinin diğerlerinden daha yüksek olduğu gözükmemektedir (Çizelge 4.6).

Çizelge 4.6. Levenberg–Marquardt algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R	0,665	0,720	0,784	0,877	0,874	0,934	0,886	0,953	0,972
	Duyarlılık (%)	82,609	86,957	84,848	93,478	96,739	94,565	93,478	96,739	98,913
	Belirlilik (%)	81,452	83,871	87,970	94,355	89,516	98,387	91,935	98,387	98,387
	Doğruluk (%)	0,822	0,874	0,894	0,925	0,953	0,957	0,954	0,965	0,984
	AUC	0,819	0,851	0,866	0,939	0,926	0,967	0,926	0,977	0,986
Test Seti	R	0,746	0,748	0,872	0,742	0,710	0,624	0,656	0,628	0,614
	Duyarlılık (%)	77,78	72,22	88,89	77,78	83,33	72,22	83,33	77,78	66,67
	Belirlilik (%)	94,44	97,22	97,22	94,44	91,67	88,89	83,33	86,11	91,67
	Doğruluk (%)	88,89	88,89	94,44	88,89	88,89	83,33	83,33	83,33	83,33
	AUC	0,85	0,868	0,954	0,907	0,883	0,826	0,86	0,86	0,829
	Ort(zaman)	11,737	11,799	12,110	12,138	14,756	7,511	14,432	22,987	1,993
SS(zaman)	6,626	6,633	6,823	6,799	8,095	4,172	8,227	11,14	0,977	
Ort(hata)	0,138	0,119	0,099	0,063	0,063	0,0399	0,057	0,041	0,041	
SS(hata)	0,010	0,012	0,014	0,013	0,018	0,026	0,017	0,040	0,053	




Şekil 4.3. Levenberg-Marquardt eğitim algoritması test seti ROC eğrileri

Öğrenme katsayısının değiştirilmesine dayanan eğitim algoritması için Matlab traingda fonksiyonu kullanılmış ve gizli katmanda farklı sayıda nöron içeren ağlar oluşturulmuştur (Çizelge 4.7). Oluşturulan ağ yapılarının test veri r değerleri 0,75-1,0 arasında değildir. Gizli katmanda 6, 7, 8, 9 ve 10 nöron olan yapılarda test seti r değerleri, eğitim seti r değerlerine göre düşüktür. Ağların ROC analiz sonuçları bütün ağlarda yüksek bulunmuştur. Öğrenme katsayısı değişen algoritma ile elde edilen ağların test veri ROC eğrileri altında kalan alan değerleri Şekil 4.4'te

incelendiğinde gizli katmanda 4 nöron olan ÇKA'nın AUC değerinin yüksek olduğu gözükmemektedir. Bu değer 0,904 olarak elde edilmiştir (Çizelge 4.7).

Çizelge 4.7. Öğrenme katsayısı değişen algoritma ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R		0,568	0,583	0,577	0,631	0,651	0,655	0,641	0,629
Duyarlılık (%)		81,522	76,087	79,348	68,478	73,913	70,652	77,174	68,478	66,304
Belirlilik (%)		73,387	77,419	81,452	87,903	84,677	87,097	81,452	87,903	88,710
Doğruluk (%)		76,852	76,852	80,556	79,630	80,093	80,093	79,630	79,630	79,167
AUC		0,828	0,833	0,832	0,862	0,865	0,876	0,872	0,867	0,861
R		0,663	0,722	0,664	0,688	0,649	0,668	0,654	0,648	0,646
Duyarlılık (%)		83,33	83,33	77,78	61,11	61,11	61,11	55,56	50,00	44,44
Belirlilik (%)		88,89	91,67	91,67	97,22	94,44	94,44	91,67	94,44	97,22
Doğruluk (%)		87,04	88,89	87,04	85,19	83,33	83,33	79,63	79,63	79,63
AUC		0,89	0,912	0,904	0,887	0,892	0,877	0,88	0,88	0,88
Ort(hata)		0,1922	0,1902	0,1899	0,1817	0,1860	0,1888	0,1784	0,1828	0,1815
SS(hata)		0,0423	0,0399	0,0199	0,0384	0,0611	0,0369	0,0265	0,0355	0,0192
Ort(zaman)		86,045	79,108	79,088	80,045	80,517	76,464	90,464	80,089	98,527
SS(zaman)		49,148	43,762	43,895	44,331	44,748	42,260	49,566	44,787	54,068




Şekil 4.4. Öğrenme katsayısı değişen algoritma test seti ROC eğrileri

Esnek geriye yayılım algoritması için Matlab trainrp fonksiyonu kullanılmıştır. Çizelge 4.8'de görüldüğü gibi gizli katmanda 7, 8, 9 ve 10 nöron kullanılan ağlar da test seri r değeri, eğitim seti r değerinden düşüktür. Gizli katmanda 4 nöron bulunan ağın test r değeri 0,82 olarak elde edilmiştir. Bu yapının test seti için belirlilik, doğruluk ve AUC değeri %97,22, %90,74, 0,961 olarak bulunmuştur. Şekil 4.5'te

test setlerinin ROC eğrileri arasında 4 nöronlu ÇKA'nın alan değerinin daha yüksek olduğu görülmektedir.

Çizelge 4.8. Esnek geriye yayılım algoritması ÇKA sonuçları

	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
		R	0,586	0,613	0,704	0,715	0,760	0,849	0,811	0,871
Eğitim Seti	Duyarlılık (%)	76,087	76,087	86,957	84,783	83,696	90,217	89,130	93,478	95,652
	Belirlilik (%)	81,452	81,452	81,452	82,258	90,323	92,742	93,548	93,548	95,968
	Doğruluk (%)	79,167	79,167	83,796	83,333	87,500	91,667	91,667	93,519	95,833
	AUC	0,831	0,854	0,895	0,903	0,909	0,964	0,92	0,974	0,98
	R	0,711	0,751	0,820	0,820	0,782	0,703	0,706	0,727	0,735
Test Seti	Duyarlılık (%)	72,22	83,33	77,78	83,33	83,33	72,22	72,22	72,22	77,78
	Belirlilik (%)	88,89	88,89	97,22	94,44	91,67	86,11	88,89	94,44	91,67
	Doğruluk (%)	83,33	87,04	90,74	90,74	88,89	81,48	83,33	87,04	87,04
	AUC	0,907	0,935	0,961	0,966	0,94	0,907	0,923	0,917	0,904
	Ort(hata)	0,1663	0,1614	0,1365	0,1322	0,1187	0,0987	0,1041	0,0895	0,0786
SS(hata)	0,0125	0,0097	0,0175	0,0150	0,0207	0,0304	0,0260	0,0345	0,0338	
Ort(zaman)	8,849	8,0997	9,6931	9,1037	8,7033	8,6992	8,199	8,2954	8,3381	
SS(zaman)	5,412	4,5266	5,7478	5,25	4,874	4,8521	4,5741	4,608	4,6561	



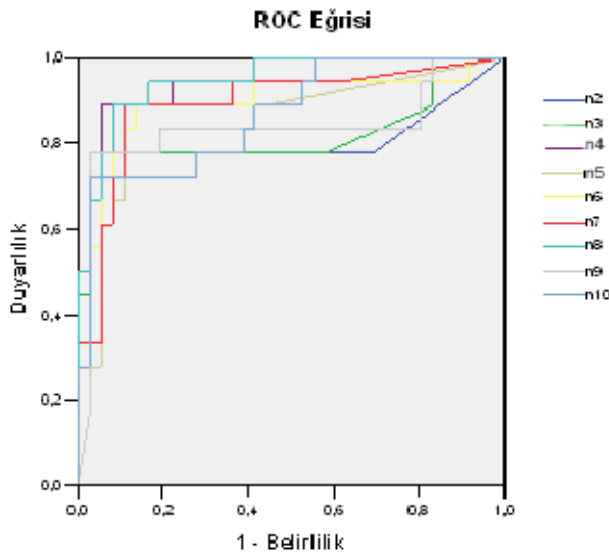
Şekil 4.5. Esnek geriye yayılım algoritması test seti ROC eğrileri

Fletcher ve Reeves eşlenik gradyan yöntemi için Matlab traincgf fonksiyonu kullanılmıştır. Çizelge 4.9'da görüldüğü gibi eğitim seti r değeri gizli katmanda bulunan nöron sayısı arttıkça 1'e daha çok yaklaşmıştır. Ancak oluşturulan yapılar test veri setlerinin r değeri, gizli katman nöron sayısı 5, 6, 7, 8, 9, 10 olan ÇKA'larda

düşmüştür. Gizli katmanda 4 nöron bulunan yapı test seti r değeri 0,81, belirlilik, doğruluk ve AUC değeri %94,4, %90,74, 0,941 olarak bulunmuştur. Şekil 4.6'da oluşturulan ÇKA'ların ROC eğrileri incelendiğinde de 4 nöronlu yapının eğri alanının daha iyi olduğu görülmektedir.

Çizelge 4.9. Fletcher-Reeves eşlenik gradyan yöntemi ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R	0,647	0,678	0,785	0,781	0,816	0,805	0,827	0,940	0,867
	Duyarlılık (%)	80,44	81,522	92,391	89,130	84,783	84,783	83,696	96,739	90,217
	Belirlilik (%)	80,65	83,871	85,484	83,065	95,161	88,710	92,742	96,774	95,968
	Doğruluk (%)	80,56	82,870	88,426	85,648	90,741	87,037	88,889	96,759	93,519
AUC	0,817	0,842	0,913	0,904	0,934	0,928	0,937	0,977	0,941	
Test Seti	R	0,747	0,743	0,814	0,725	0,718	0,713	0,788	0,742	0,738
	Duyarlılık (%)	77,78	72,22	83,33	83,33	77,78	72,22	88,89	77,78	72,22
	Belirlilik (%)	94,44	97,22	94,44	88,89	91,67	88,89	88,89	91,67	97,22
	Doğruluk (%)	88,89	88,89	90,74	87,04	87,04	83,33	88,89	87,04	88,89
	AUC	0,799	0,818	0,941	0,872	0,897	0,892	0,948	0,834	0,867
	Ort(hata)	0,150	0,147	0,1115	0,1169	0,0951	0,101	0,107	0,0596	0,0868
	SS(hata)	0,013	0,019	0,0280	0,027	0,0212	0,0266	0,027	0,0413	0,0325
	Ort(zaman)	15,84	16,351	16,759	15,108	15,580	16,864	15,63	18,2567	22,569
	SS(zaman)	8,949	9,184	9,4203	8,5417	8,9654	9,415	8,698	10,3938	13,244




Şekil 4.6. Fletcher ve Reeves eşlenik gradyan yöntemi test seti ROC eğrileri

Powell-Beale eşlenik gradyan yöntemi için Matlab traincgb fonksiyonu kullanılmıştır. Çizelge 4.10'da görüldüğü gibi gizli katmanlardaki nöron sayısı 5, 6, 7, 8, 9, 10 olan ağlarda arttık test seti r değerleri, eğitim seti r değerlerine göre

düşüktür. Gizli katmanda 4 nöron bulunan ağın test seti r değeri 0,706, belirlilik, doğruluk, AUC değeri %91,67, %87,04, 0,864 olarak belirlenmiştir. Şekil 4.7’de bulunan ROC eğrilerine bakıldığında gizli katmanda 3 nöron bulunan ağ yapısının eğri alan değeri diğerlerine göre daha büyüktür. Ancak bu ağın eğitim r değeri 0,7 altındadır (Çizelge 4.10).

Çizelge 4.10. Powell-Beale eşlenik gradyan yöntemi ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R		0,657	0,682	0,702	0,813	0,879	0,879	0,837	0,879
Duyarlılık (%)		82,609	92,391	84,783	94,565	94,565	90,217	88,043	84,783	92,39
Belirlilik (%)		80,645	71,774	83,065	86,290	94,355	97,581	89,516	97,581	97,58
Doğruluk (%)		81,481	80,556	83,796	89,815	94,444	94,444	88,889	92,130	95,37
AUC		0,829	0,87	0,861	0,929	0,919	0,922	0,938	0,947	0,964
Test Seti	R	0,746	0,814	0,706	0,806	0,729	0,738	0,689	0,770	0,63
	Duyarlılık (%)	77,78	83,33	77,78	94,44	72,22	72,22	72,22	83,33	77,78
	Belirlilik (%)	94,44	88,89	91,67	91,67	88,89	97,22	80,56	94,44	86,11
	Doğruluk (%)	88,89	87,04	87,04	92,59	83,33	88,89	77,78	90,74	83,33
	AUC	0,87	0,957	0,864	0,934	0,938	0,887	0,906	0,941	0,877
	Ort(zaman)	6,599	22,596	13,797	24,481	23,579	19,677	23,496	30,212	23,873
	SS(zaman)	3,554	12,774	7,892	13,820	13,217	10,992	13,441	17,294	13,273
	Ort(hata)	0,154	0,136	0,138	0,098	0,0785	0,0780	0,0902	0,0801	0,0647
	SS(hata)	0,024	0,0123	0,029	0,025	0,0343	0,0330	0,0318	0,0312	0,0328




Şekil 4.7. Powell-Beale eşlenik gradyan yöntemi test seti ROC eğrileri

Polak-Ribiere eşlenik gradyan yöntemi için Matlab traincgp fonksiyonu kullanılmıştır. Çizelge 4.11’de görüldüğü gibi gizli katmanda 5, 6, 7, 8, 9, 10 nöron

bulunan ağların test seti r değerleri, eğitim seti r değerlerine göre küçüktür. Gizli katmanda 4 nöron bulunan ağın test r değeri 0,823, belirlilik, doğruluk, AUC değerleri %94,4, %87,04 ve 0,96 olarak belirlenmiştir. Şekil 4.8’de test seti ROC eğrileri incelendiğinde gizli katmanda 4 nöron bulunan ağın alanının daha iyi olduğu görülmektedir.

Çizelge 4.11. Polak-Ribiere eşlenik gradyan yöntemi için ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R		0,562	0,692	0,756	0,799	0,841	0,854	0,849	0,873
Duyarlılık (%)		77,174	83,696	90,217	89,130	93,478	88,043	95,652	93,478	93,47
Belirlilik (%)		78,226	82,258	81,452	91,935	93,548	95,161	83,871	91,129	95,16
Doğruluk (%)		77,778	82,870	85,185	90,741	93,519	92,130	88,889	92,130	94,44
AUC		0,776	0,847	0,909	0,877	0,909	0,934	0,948	0,956	0,931
Test Seti	R	0,720	0,739	0,823	0,724	0,696	0,763	0,689	0,687	0,636
	Duyarlılık (%)	77,78	72,22	72,22	72,22	66,67	72,22	77,78	66,67	72,2
	Belirlilik (%)	94,44	97,22	94,44	94,44	97,22	97,22	88,89	94,44	88,8
	Doğruluk (%)	88,89	88,89	87,04	87,04	87,04	88,89	85,19	85,19	83,3
	AUC	0,805	0,847	0,96	0,877	0,852	0,924	0,904	0,892	0,92
	Ort(hata)	0,174	0,140	0,116	0,108	0,094	0,088	0,095	0,105	0,0742
	SS(hata)	0,0150	0,018	0,021	0,021	0,032	0,0285	0,031	0,039	0,0313
	Ort(zaman)	9,412	23,741	20,929	22,925	24,558	23,416	24,308	30,526	23,356
	SS(zaman)	5,442	13,444	11,858	12,916	13,797	13,291	13,949	17,305	13,275




Şekil 4.8. Polak-Ribiere eşlenik gradyan yöntemi test seti ROC eğrileri

Ölçekli eşlenik gradyan yöntemi için Matlab trainsecg fonksiyonu kullanılmıştır. Çizelge 4.12’de görüldüğü gibi gizli katmanda 4 ve 5 nöron bulunduran ÇKA ağları

test r değerleri 0,763 ve 0,775 olarak bulunmuştur. Gizli katmanda 6, 7, 8, 9 ve 10 nöron bulunan ağların test r değerleri, eğitim r değerinden düşük elde edilmiştir. 4 nöronlu ağın belirlilik, doğruluk ve AUC değerleri %97,2, %90,74, 0,937'dir. Bu sonuçlar 5 nöronlu ağın ROC değerlerine göre daha iyidir. Şekil 4.9'da oluşturulan ağların ROC eğrileri değerlendirildiğinde eğri altında kalan alan bakımından 4 nöronlu ağ diğerlerine göre daha başarılıdır.

Çizelge 4.12. Ölçekli eşlenik gradyan yöntemi için ÇKA sonuçları

Eğitim Seti	Ağ Sayısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1	
	R		0,652	0,666	0,726	0,761	0,844	0,849	0,878	0,933	0,906
Duyarlılık (%)		80,435	84,783	78,261	86,957	86,96	92,391	92,391	95,652	94,565	
Belirlilik (%)		80,645	80,645	92,742	86,290	97,58	93,548	96,774	96,774	95,161	
Doğruluk (%)		80,556	82,407	86,574	86,574	93,06	93,056	94,907	96,296	94,907	
AUC		0,816	0,845	0,868	0,903	0,908	0,9	0,922	0,957	0,946	
Test Seti	R		0,748	0,748	0,763	0,775	0,717	0,774	0,647	0,690	
	Duyarlılık (%)		77,78	77,78	77,78	77,78	61,11	77,78	66,67	66,67	72,22
	Belirlilik (%)		94,44	94,44	97,22	94,44	100,0	94,44	94,44	97,22	94,44
	Doğruluk (%)		88,89	88,89	90,74	88,89	87,04	88,89	85,19	87,04	87,04
	AUC		0,821	0,861	0,937	0,898	0,89	0,909	0,887	0,831	0,923
	Ort(hata)		0,151	0,15	0,1300	0,116	0,094	0,089	0,077	0,056	0,073
	SS(hata)		0,023	0,0218	0,0165	0,0200	0,031	0,0268	0,0295	0,0549	0,0335
	Ort(zaman)		19,783	19,943	19,987	21,231	25,306	24,112	20,102	21,234	20,408
	SS(zaman)		11,422	11,379	11,396	12,11	14,671	13,878	11,451	12,139	11,611

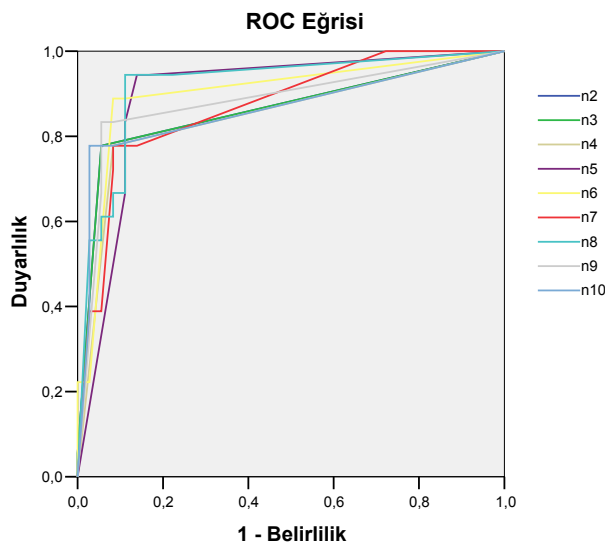


Şekil 4.9. Ölçekli eşlenik gradyan yöntemi test seti ROC eğrileri

Quasi-Newton eğitim algoritması için Matlab trainbfg fonksiyonu kullanılmıştır. Çizelge 4.13'te görüldüğü gibi gizli katmanda 4, 5, 6 nöron bulunduran ÇKA ağlarının test seti r değerleri sonuçları 0,70, 0,74 ve 0,76'dır. Bu ağların belirlilik, doğruluk ve AUC değerleri birbirine çok yakındır. Gizli katmandaki nöron sayısı 7, 8, 9, 10 olan ağlarda test seti r değerleri, eğitim seti r değerlerine göre düşüktür. Şekil 4.10'da ağların ROC eğrileri değerlendirildiğinde 8 nöronlu ağın eğri alanı daha yüksektir, 4, 5, 6 nöronlu ağların alan değerleri birbirine yakındır.

Çizelge 4.13. Quasi-Newton eğitim algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R		0,577	0,554	0,699	0,694	0,743	0,770	0,833	0,798
Duyarlılık (%)		77,174	73,913	83,696	91,304	96,739	88,043	92,391	95,652	93,478
Belirlilik (%)		79,032	79,839	75,806	75,000	75,000	86,290	86,290	82,258	82,258
Doğruluk (%)		78,241	77,315	79,167	81,944	84,259	87,037	88,889	87,963	87,037
Alan		0,784	0,782	0,804	0,872	0,884	0,911	0,93	0,917	0,928
Test Seti	R	0,741	0,741	0,705	0,740	0,763	0,706	0,745	0,749	0,707
Duyarlılık (%)		77,78	77,78	77,78	94,44	88,89	77,78	94,44	77,78	77,78
Belirlilik (%)		94,44	94,44	91,67	83,33	88,89	91,67	88,89	94,44	94,44
Doğruluk (%)		88,89	88,89	87,04	87,04	88,89	87,04	90,74	88,89	88,89
AUC		0,863	0,863	0,847	0,898	0,901	0,871	0,92	0,882	0,863
Ort(hata)		0,1671	0,175	0,1742	0,1399	0,1252	0,1199	0,0855	0,1004	0,1009
SS(hata)		0,0113	0,013	0,0202	0,0186	0,0356	0,0340	0,0228	0,0211	0,0325
Ort(zaman)		29,872	3,83	2,7265	11,324	9,147	6,8832	24,88	28,077	15,260
SS(zaman)		18,28	1,854	1,4721	7,1088	5,401	4,2835	14,6	17,275	9,3062




Şekil 4.10. Quasi-Newton algoritması test seti ROC eğrileri

Tek adım sekant algoritması için Matlab trainoss fonksiyonu kullanılmıştır. Çizelge 4.14'te görüldüğü gibi gizli katmanda 4 ve 5 nöron bulunduran test seti r değerleri 0,84 ve 0,81'dir. Gizli katmandaki nöron sayıları 6, 7, 8, 9, 10 olan ağların test r değerleri, eğitim r değerlerinden düşüktür. 4 nöronlu ağın belirlilik, doğruluk ve AUC değerleri %94,4, %88,9 ve 0,96'dır. Şekil 4.11'de gösterildiği gibi ağların ROC eğri alanları incelendiğinde 4 nöronlu ağın eğri altında kalan alan değerinin daha iyi olduğu gözükmemektedir.

Çizelge 4.14. Tek adım sekant algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1	9/6/1	9/7/1	9/8/1	9/9/1	9/10/1
	R		0,602	0,686	0,760	0,794	0,807	0,857	0,893	0,841
Duyarlılık (%)		81,522	83,696	88,043	90,217	94,565	93,478	89,130	94,565	92,391
Belirlilik (%)		77,419	83,065	82,258	85,484	85,484	92,742	97,581	91,129	98,387
Doğruluk (%)		79,167	83,333	84,722	87,500	89,352	93,056	93,981	92,593	95,833
AUC		0,797	0,83	0,914	0,921	0,916	0,907	0,964	0,902	0,935
Test Seti	R	0,739	0,714	0,841	0,818	0,728	0,726	0,717	0,643	0,696
	Duyarlılık (%)	77,78	72,22	77,78	83,33	94,44	88,89	72,22	72,22	61,11
	Belirlilik (%)	94,44	94,44	94,44	94,44	86,11	86,11	91,67	91,67	100,00
	Doğruluk (%)	88,89	87,04	88,89	90,74	88,89	87,04	85,19	85,19	87,04
	AUC	0,802	0,81	0,96	0,949	0,918	0,914	0,9	0,929	0,827
	Ort(hata)	0,1619	0,1427	0,1186	0,1183	0,0960	0,0919	0,0712	0,1017	0,0597
	SS(hata)	0,0092	0,0163	0,0249	0,0284	0,0215	0,0263	0,0316	0,0288	0,0346
	Ort(zaman)	23,566	24,103	23,474	23,977	23,323	17,299	16,936	24,287	22,915
	SS(zaman)	13,335	13,619	13,107	13,717	13,327	9,6726	9,4502	13,858	13,269

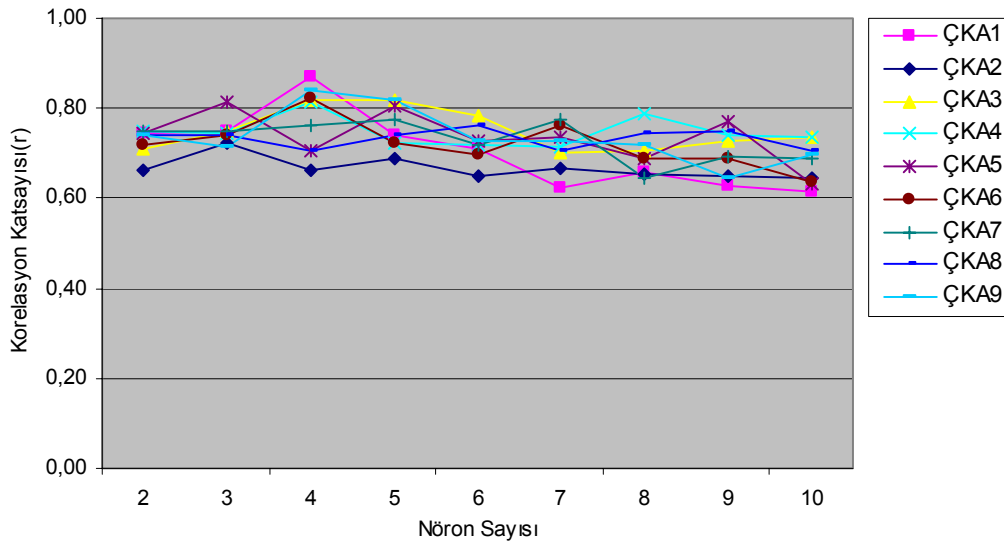


Şekil 4.11. Tek adım sekant algoritması test seti ROC eğrileri

Farklı eğitim algoritmaları ile oluşturulan ÇKA'lar için test seti korelasyon katsayısı r değerleri, Çizelge 4.15'te ve Şekil 4.12'de incelendiğinde en iyi sonuçlar gizli katmanda 4 nöron olan ağlarda 0,7-1,0 arasında elde edilmiştir. Bu durum ağ çıktıları ile tanı arasında yüksek ilişki olduğunu ifade etmektedir. Öğrenme katsayısı değişen algoritma, Powell-Beale, ölçekli eşlenik gradyan ve Quasi-Newton eğitim algoritmaları kullanılarak oluşturulan gizli katmanda 4 nöron bulunan ağların test seti korelasyon değerleri düşüktür. Bu eğitim algoritmalarıyla oluşturulan farklı sayıda nöron içeren diğer ağların test seti r değerleri, eğitim seti r değerinden düşüktür ya da eğitim seti r değerleri 0,7 sınırını aşamamıştır.

Çizelge 4.15. Eğitim algoritmalarının gizli katmandaki nöron sayılarına göre r değerleri

Eğitim Algoritmaları	2	3	4	5	6	7	8	9	10
Levenberg-Marquardt Algoritması-ÇKA1	0,75	0,75	0,87	0,74	0,71	0,62	0,66	0,63	0,61
Öğrenme Katsayısı Değişen Algoritma-ÇKA2	0,66	0,72	0,66	0,69	0,65	0,67	0,65	0,65	0,65
Esnek Geriye Yayılım Algoritması-ÇKA3	0,71	0,75	0,82	0,82	0,78	0,70	0,71	0,73	0,74
Fletcher ve Reeves Algoritması-ÇKA4	0,75	0,74	0,81	0,73	0,72	0,71	0,79	0,74	0,74
Powell-Beale Algoritması-ÇKA5	0,75	0,81	0,71	0,81	0,73	0,74	0,69	0,77	0,63
Polak-Ribiere Algoritması-ÇKA6	0,72	0,74	0,82	0,72	0,70	0,76	0,69	0,69	0,64
Ölçekli Eşlenik Gradyan Algoritması-ÇKA7	0,75	0,75	0,76	0,78	0,72	0,77	0,65	0,69	0,69
Quasi-Newton Algoritması -ÇKA8	0,74	0,74	0,71	0,74	0,76	0,71	0,75	0,75	0,71
Tek Adım Sekant Algoritması-ÇKA9	0,74	0,71	0,84	0,82	0,73	0,73	0,72	0,64	0,70



Şekil 4.12. Eğitim algoritmalarının gizli katmandaki nöron sayılarına göre r değerleri


4.2.1. Meme kanseri sınırlı veri seti YSA analiz sonuçları

Uygulamanın ikinci aşamasında meme kanseri verileri ile yapılan LR analizi sonucu koltuk altı lenf nod durumunu belirlemede anlamlı bulunan tümör evre, tümör derece, yaş elli, lenfatik yayılım bilgileri ile tekrar yapay sinir ağları oluşturulmuştur. 4 veri ile oluşturulan sınırlı eğitim seti örnek sayısı 26, test veri sayısı 8 olmuştur. Sınırlı eğitim seti ile oluşturulan geri yayımlı ÇKA'ların korelasyon katsayıları ve ROC analiz sonuçları, örnek sayısının yetersizliği sebebiyle yüksek değerlere ulaşamamıştır. Ağların ROC analiz sonuçları, korelasyon katsayılarına göre daha iyi sonuç vermiştir. Aşağıda hızlı eğitim algoritmaları ile oluşturulan ağların performans sonuçları verilmektedir.

Levenberg –Marquardt eğitim algoritması ile farklı nöron sayıları içeren tek gizli katmanlı ÇKA'lar oluşturulmuştur. Elde edilen ağların performans analizleri değerlendirildiğinde korelasyon katsayılarının test verileri için düşük elde edildiği Çizelge 4.16'da görülmektedir. Şekil 4.13'te oluşturulan ağların test seti ROC eğrileri incelendiğinde gizli katmanda 3 nöron bulunan ağın alan değeri en yüksektir, ancak bu ağın korelasyon katsayısı 2 nöronlu yapıya göre daha düşük elde edilmiştir.

Çizelge 4.16. Levenberg- Marquardt algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,609	0,527	0,692	0,694
Duyarlılık (%)	77	46	77	85	
Belirlilik (%)	77	100	77	69	
Doğruluk (%)	77	73	77	77	
AUC	0,837	0,713	0,879	0,885	
Test Seti	R	0,596	0,500	0,250	0,163
	Duyarlılık (%)	75,00	25,00	75,00	75,00
	Belirlilik (%)	100	100,00	50,00	25,00
	Doğruluk (%)	87,5	62,50	62,50	50,00
	AUC	0,875	1	0,688	0,5
	Ort(hata)	0,1598	0,2574	0,1458	0,0698
	SS(hata)	0,0115	0,0102	0,0194	0,0168
	Ort(zaman)	8,367	8,951	83,392	13,2978
	SS(zaman)	4,7142	4,9992	46,820	7,5235




Şekil 4.13. Levenberg-Marquardt algoritması test veri ROC eğrileri

Öğrenme katsayısının değiştirilmesine dayanan algoritma ile farklı nöron sayıları içeren ÇKA'lar oluşturulmuştur. Çizelge 4.17'de ağların performans sonuçları değerlendirildiğinde hiçbirinde korelasyon katsayısı yüksek elde edilememiştir. Gizli katmanda 2 nöron bulunan ağın, diğer ağlarına göre daha iyi sonuçlar vermiştir. Ağın test seti r değeri 0,736, belirlilik, doğruluk ve AUC değerleri %100, %87,5, 0,93 olarak bulunmuştur. Şekil 4.14'te algoritma ile geliştirilen ağların test veri seti ROC eğrileri altında kalan alanlar incelendiğinde 2 nöronlu yapının diğerlerine göre daha yüksek alana sahip olduğu gözükmemektedir.

Çizelge 4.17. Öğrenme katsayısı değişen algoritma ile ÇKA sonuçları

	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
		R	0,420	0,602	0,586
Eğitim Seti	Duyarlılık (%)	61,538	76,923	69,231	84,615
	Belirlilik (%)	69,231	76,923	69,231	69,231
	Doğruluk (%)	65,385	76,923	69,231	76,923
	AUC	0,713	0,825	0,825	0,837
	R	0,736	0,589	0,561	0,431
Test Seti	Duyarlılık (%)	75,00	75,00	75,00	75,00
	Belirlilik (%)	100,00	50,00	75,00	25,00
	Doğruluk (%)	87,50	62,50	75,00	50,00
	AUC	0,938	0,813	0,813	0,75
	Ort(hata)	0,2272	0,1947	0,1986	0,1898
SS(hata)	0,0277	0,0275	0,0501	0,0540	
Ort(zaman)	5,2602	5,4897	5,1643	5,0829	
SS(zaman)	2,8461	2,9893	2,8119	2,642	

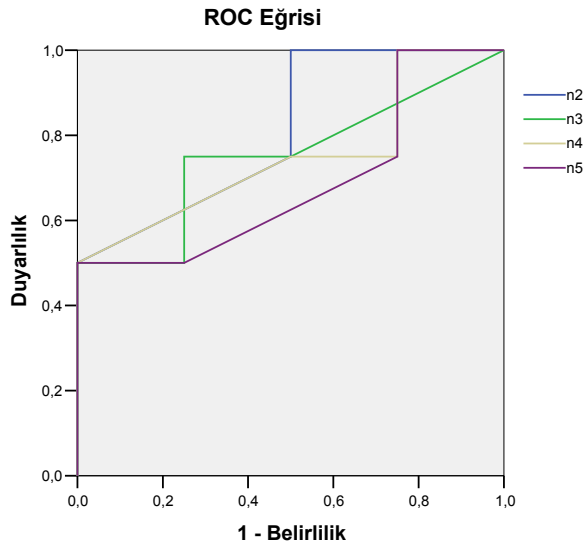


Şekil 4.14. Öğrenme katsayısı değişen algoritma ile test veri ROC eğrileri

Esnek geriye yayılım algoritması ile sınırlı eğitim seti için ÇKA ağları oluşturulmuş ancak hiçbirinde yüksek korelasyon değerleri elde edilememiştir. Çizelge 4.18’de 2 nöronlu gizli katmanla oluşturulan ağın test veri seti sonuçları diğer yapılara göre daha iyidir. Ağın test seti r değeri 0,539, belirlilik, doğruluk ve AUC değerleri %50, %62,5, 0,813 olarak elde edilmiştir. Şekil 4.15’te test veri seti ROC eğrileri altında kalan alanlar kıyaslandığında 2 nöronlu yapının diğerlerinden daha yüksek alana sahip olduğu gözükmemektedir.

Çizelge 4.18. Esnek geriye yayılım algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,506	0,613	0,645	0,588
Duyarlılık (%)	76,923	61,538	76,923	46,154	
Belirlilik (%)	69,231	84,615	76,923	92,308	
Doğruluk (%)	73,077	73,077	76,923	69,231	
AUC	0,754	0,825	0,849	0,778	
Test Seti	R	0,539	0,523	0,450	0,409
	Duyarlılık (%)	75,00	50,00	75,00	50,00
	Belirlilik (%)	50,00	75,00	50,00	100,00
	Doğruluk (%)	62,50	62,50	62,50	75,00
	AUC	0,813	0,75	0,75	0,688
	Ort(hata)	0,1915	0,1592	0,1542	0,1672
	SS(hata)	0,0085	0,0059	0,0120	0,0154
	Ort(zaman)	7,2806	7,2857	7,5276	7,1814
	SS(zaman)	4,053	4,0602	4,1889	3,9963




Şekil 4.15. Esnek geriye yayılım algoritması test veri ROC eğrileri

Fletcher ve Reeves eşlenik gradyan algoritması ile sınırlı eğitim seti için ÇKA'lar oluşturulmuştur. Çizelge 4.19'da görüldüğü gibi oluşturulan ağların hiçbirinde test seti r değerleri yüksek elde edilememiştir. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,65, belirlilik, doğruluk ve AUC değerleri %100, %87,5, 0,938 olarak bulunmuştur. Şekil 4.16'da test veri seti ROC eğrileri incelendiğinde 2 nöronlu ağın eğri alan değerinin daha yüksek olduğu görülmektedir.

Çizelge 4.19. Fletcher-Reeves eşlenik gradyan algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,562	0,621	0,627	0,157
	Duyarlılık (%)	61,538	61,538	53,846	23,077
	Belirlilik (%)	76,923	84,615	92,308	92,308
	Doğruluk (%)	69,231	73,077	73,077	57,692
	AUC	0,79	0,837	0,796	0,459
Test Seti	R	0,655	0,500	0,447	0,378
	Duyarlılık (%)	75,00	50,00	50,00	0,00
	Belirlilik (%)	100,00	75,00	100,00	100,00
	Doğruluk (%)	87,50	62,50	75,00	50,00
	AUC	0,938	0,688	0,875	0,438
	Ort(hata)	0,1817	0,1689	0,1644	0,1369
	SS(hata)	0,0241	0,0212	0,0267	0,0444
	Ort(zaman)	5,1102	5,3410	3,0907	0,302
	SS(zaman)	2,7742	2,8481	1,6118	0,0239




Şekil 4.16. Fletcher-Reeves eşlenik gradyan algoritması test veri ROC eğrileri

Powell-Beale eşlenik gradyan algoritması ile sınırlı veri seti için oluşturulan ÇKA'ların performans sonuçları Çizelge 4.20'de verilmiştir. Ağların test seti r değerleri yüksek elde edilememiştir. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,696, belirlilik, doğruluk, AUC değerleri %100, %87,5, 0,938 olarak bulunmuştur. Şekil 4.17'de ağların test seti ROC eğrileri altında kalan alanlar incelendiğinde 2 nöronlu ağın alan değerinin daha yüksek olduğu gözükmemektedir.

Çizelge 4.20. Powell-Beale eşlenik gradyan algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,412	0,398	0,398	0,407
	Duyarlılık (%)	61,538	84,615	84,615	84,615
	Belirlilik (%)	69,231	46,154	46,154	38,462
	Doğruluk (%)	65,385	65,385	65,385	61,538
Test Seti	AUC	0,707	0,713	0,689	0,648
	R	0,696	0,651	0,651	0,608
	Duyarlılık (%)	75,00	100,00	100,00	100,00
	Belirlilik (%)	100,00	50,00	50,00	50,00
	Doğruluk (%)	87,50	75,00	75,00	75,00
	AUC	0,938	0,813	0,938	0,813
	Ort(zaman)	0,2199	0,2647	0,2629	0,2737
	SS(zaman)	0,0269	0,0744	0,0379	0,0908
	Ort(hata)	0,5251	0,4128	0,3325	0,5833
	SS(hata)	0,1631	0,0871	0,0465	0,195




Şekil 4.17. Powell-Beale eşlenik gradyan algoritması

Polak-Ribiere eşlenik gradyan algoritması ile sınırlı veri seti için oluşturulan ÇKA'ların performans sonuçları Çizelge 4.21'de verilmiştir, hiçbir ağda test seti r değeri yüksek değildir. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,615, belirlilik, doğruluk, AUC değerleri %100, %50, 0,938 olarak elde edilmiştir. Şekil 4.18'de oluşturulan ağların test seti ROC eğrileri altında kalan alanlar incelendiğinde 2 nöronlu ağın alan değerinin daha yüksek olduğu gözükmemektedir.

Çizelge 4.21. Polak-Ribiere eşlenik gradyan algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,498	0,622	0,648	0,483
	Duyarlılık (%)	38,462	61,538	76,923	38,462
	Belirlilik (%)	100,000	84,615	76,923	100,000
	Doğruluk (%)	69,231	73,077	76,923	69,231
	AUC	0,728	0,837	0,855	0,636
Test Seti	R	0,615	0,498	0,411	0,539
	Duyarlılık (%)	0,00	50,00	75,00	25,00
	Belirlilik (%)	100,00	75,00	50,00	100,00
	Doğruluk (%)	50,00	62,50	62,50	62,50
	AUC	0,938	0,688	0,688	0,813
		Ort(hata)	0,1980	0,1709	0,1552
	SS(hata)	0,0318	0,0257	0,0281	0,0308
	Ort(zaman)	1,7406	6,0032	3,5157	1,4016
	SS(zaman)	0,8335	3,3059	1,8272	0,6675

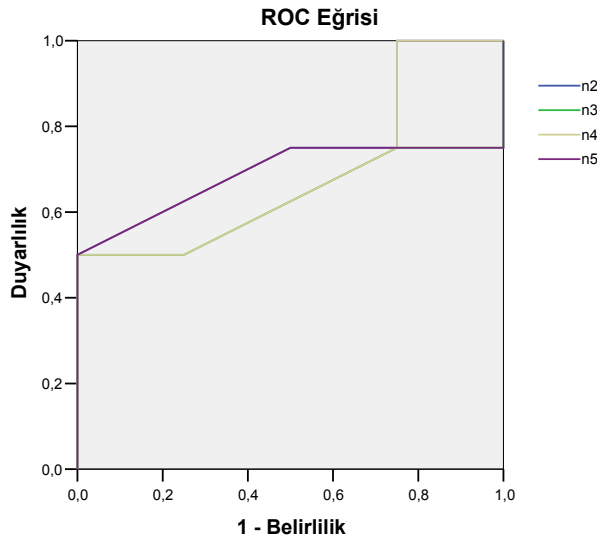


Şekil 4.18. Polak-Ribiere eşlenik gradyan algoritması test veri ROC eğrileri

Ölçekli eşlenik gradyan algoritması ile sınırlı veri seti için oluşturulan ÇKA'ların performans sonuçları Çizelge 4.22'de verilmiştir. Ağların hiçbirinde test seti r değeri yüksek değildir. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,543, belirlilik, doğruluk, AUC değerleri %25, %62,5, 0,75 olarak elde edilmiştir. Şekil 4.19'da ağ test veri ROC eğrileri incelendiğinde 2 nöronlu ağın alan değerinin daha iyi olduğu gözükmemektedir.

Çizelge 4.22. Ölçekli eşlenik gradyan algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R	0,480	0,632	0,557	0,693
	Duyarlılık (%)	92,308	53,846	53,846	84,615
	Belirlilik (%)	38,462	92,308	84,615	69,231
	Doğruluk (%)	65,385	73,077	69,231	76,923
AUC	0,701	0,873	0,802	0,879	
Test Seti	R	0,543	0,440	0,409	0,236
	Duyarlılık (%)	100,00	50,00	50,00	75,00
	Belirlilik (%)	25,00	100,00	100,00	25,00
	Doğruluk (%)	62,50	75,00	75,00	50,00
	AUC	0,75	0,625	0,688	0,688
	Ort(hata)	0,1950	0,1549	0,1748	0,1344
	SS(hata)	0,0099	0,0143	0,0150	0,0218
	Ort(zaman)	11,4771	11,212	11,2839	11,3022
	SS(zaman)	6,4985	6,3506	6,3686	6,3928




Şekil 4.19. Ölçekli eşlenik gradyan algoritması test veri ROC eğrileri

Quasi-Newton eğitim algoritması ile sınırlı veri seti için oluşturulan ÇKA'ların performans sonuçları Çizelge 4.23'te verilmiştir. Ağların hiçbirinde test seti r değeri yüksek değildir. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,577, belirlilik, doğruluk ve AUC değerleri %0, %50, 0,75 olarak bulunmuştur. Şekil 4.20'de ağların test seti ROC eğri alanları incelendiğinde 3, 4, 5 nöronlu ağların alan değerlerinin yüksek olduğu görülmektedir ancak bu ağlarında r değerleri düşüktür.

Çizelge 4.23. Quasi-Newton eğitim algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R		0,521	0,560	0,562
Duyarlılık (%)		100,000	69,231	76,923	46,154
Belirlilik (%)		30,769	76,923	69,231	100,000
Doğruluk (%)		65,385	73,077	73,077	73,077
AUC		0,74	0,814	0,793	0,814
Test Seti	R	0,577	0,555	0,471	0,430
	Duyarlılık (%)	100,00	75,00	75,00	25,00
	Belirlilik (%)	0,00	50,00	50,00	100,00
	Doğruluk (%)	50,00	62,50	62,50	62,50
	AUC	0,75	0,813	0,813	0,813
	Ort(zaman)	0,2023	0,1725	0,1903	0,1686
	SS(zaman)	0,0361	0,0075	0,0270	0,0319
	Ort(hata)	1,1169	9,4809	1,0699	1,3868
	SS(hata)	0,4797	4,8369	0,4638	0,6568




Şekil 4.20. Quasi-Newton eğitim algoritması test veri ROC eğrileri

Tek adım sekant algoritması ile sınırlı veri seti için oluşturulan ÇKA'ların performans sonuçları Çizelge 4.24'te verilmiştir, ağların test seti r değerleri oldukça düşüktür. Gizli katmanda 2 nöron bulunan ağın test seti r değeri 0,649, belirlilik, doğruluk ve AUC değerleri %75,0, %100, 0,938 olarak elde edilmiştir. Şekil 4.21'de ağların test seti ROC eğri alanları kıyaslandığında 2 nöronlu yapının alan değerinin daha büyük olduğu görülmektedir.

Çizelge 4.24. Tek adım sekant algoritması ÇKA sonuçları

Eğitim Seti	Ağ Yapısı	9/2/1	9/3/1	9/4/1	9/5/1
	R		0,563	0,609	0,648
Duyarlılık (%)		61,538	76,923	84,615	84,615
Belirlilik (%)		76,923	76,923	69,231	69,231
Doğruluk (%)		69,231	76,923	76,923	76,923
AUC		0,79	0,814	0,855	0,879
Test Seti	R	0,649	0,487	0,411	0,246
	Duyarlılık (%)	75,00	75,00	75,00	75,00
	Belirlilik (%)	100,00	50,00	25,00	25,00
	Doğruluk (%)	87,50	62,50	50,00	50,00
	AUC	0,938	0,813	0,688	0,688
	Ort(zaman)	0,1767	0,1616	0,1523	0,1333
	SS(zaman)	0,0153	0,0165	0,0178	0,0123
	Ort(hata)	14,3630	13,9063	7,6756	14,206
	SS(hata)	8,0313	7,9600	4,3814	8,2881

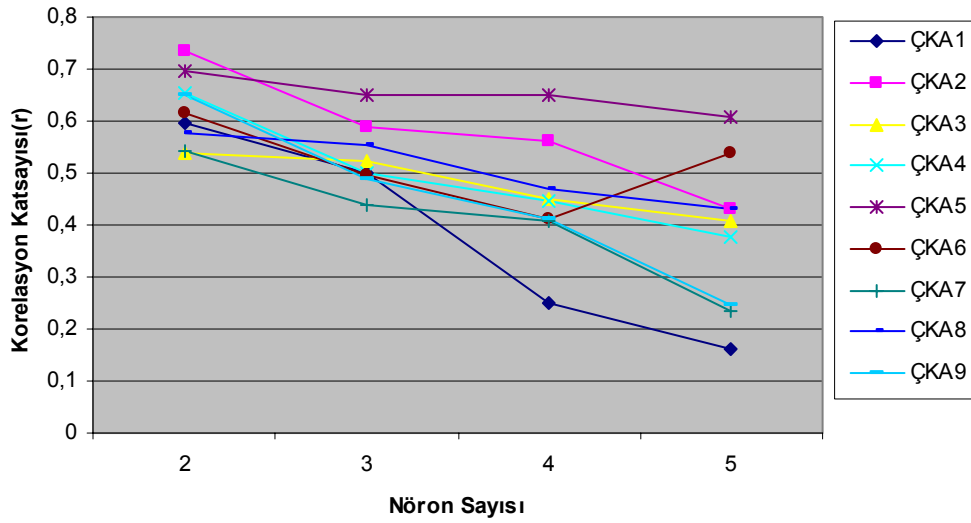


Şekil 4.21. Tek adım sekant algoritması test veri ROC eğrileri

Sınırlı veri seti ile farklı eğitim algoritmalarıyla oluşturulan ÇKA'ların korelasyon katsayıları ve ROC analiz değerleri incelendiğinde oluşturulan ağlar iyi sonuçlar vermemiştir. Ağların korelasyon katsayıları 0,7–1,0 değerlerini aşamamıştır. Belirlilik, doğruluk, duyarlılık, AUC değerleri genellikle yüksek bulunmuştur. Çizelge 4.25'te ve Şekil 4.22'de gizli katmanda farklı nöron sayıları kullanılarak farklı eğitim algoritmalarıyla oluşturulan ağların test seti r değerleri verilmiştir. 2 nöronlu yapıların regresyon sonuçları diğer ağlara göre daha yüksek elde edilmiştir. Ancak bu sonuçlar düşük korelasyon sebebiyle yeterli değildir.

Çizelge 4.25. Sınırlı eğitim seti ile oluşturulan ÇKA'ların farklı nöron sayılarına göre r değerleri

Eğitim Algoritmaları	2	3	4	5
Levenberg-Marquardt Algoritması-ÇKA1	0,596	0,5	0,25	0,163
Öğrenme Katsayısı Değişen Algoritma-ÇKA2	0,736	0,589	0,561	0,431
Esnek Geriye Yayılım Algoritması-ÇKA3	0,539	0,523	0,45	0,409
Fletcher ve Reeves Algoritması-ÇKA4	0,655	0,5	0,447	0,378
Powell-Beale Algoritması-ÇKA5	0,696	0,651	0,651	0,608
Polak-Ribiere Algoritması-ÇKA6	0,615	0,498	0,411	0,539
Ölçekli Eşlenik Gradyan Algoritması-ÇKA7	0,543	0,44	0,409	0,236
Quasi-Newton Algoritması -ÇKA8	0,577	0,555	0,471	0,43
Tek Adım Sekant Algoritması-ÇKA9	0,649	0,487	0,411	0,246



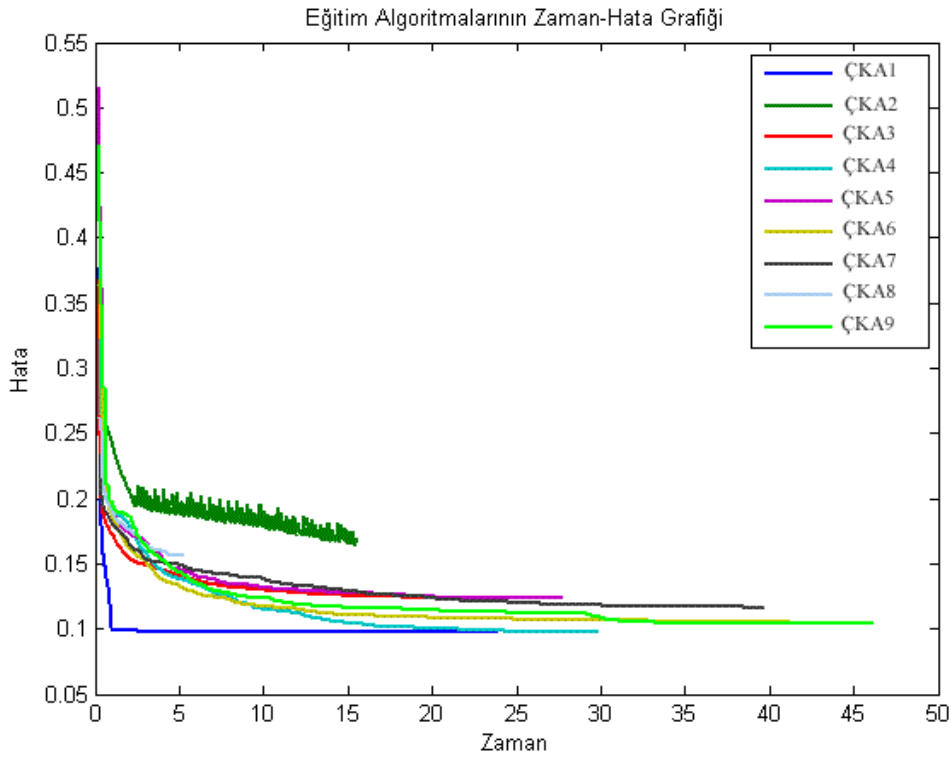
Şekil 4.22. Sınırlı eğitim seti ile oluşturulan ÇKA'ların farklı nöron sayılarına göre r değerleri

4.2.2. Tam ve sınırlı veri setleri ile oluşturulan ÇKA'ların kıyaslanması

Tam veri seti ile farklı eğitim algoritmaları, farklı yapı özellikleri ile oluşturulan ÇKA'lar arasında gizli katmanında 4 nöron bulunan ağların, test seti r değerleri sonuçları diğer ağlara göre daha yüksektir (Şekil 4.12). Sınırlı veri seti ile oluşturulan ÇKA'ların hiçbirinde yüksek korelasyon elde edilememiştir ancak 2 nöronlu ağ yapıları, diğer ağlara göre daha yüksek r değeri elde etmiştir (Şekil 4.22). Hangi eğitim algoritmasının daha başarılı olduğunu belirlemek için eğitim seti ile eğitilerek oluşturulan ağların hata ve zaman analizleri Çizelge 4.26'da gösterilmektedir. Çizelge 4.26'da Levenberg-Marquardt algoritmasının eğitim ortalama hatası, standart sapma değerleri 0,099, 0,014 olmuştur. Aynı zamanda eğitim süresi ortalama ve standart sapma değerleri kıyaslandığında Quasi-Newton eğitim algoritmasının zaman ortalama ve standart sapma değerleri 2,727, 1,472 olarak bulunmuştur. Şekil 4.23'te eğitim algoritmalarının hata-zaman eğrileri incelendiğinde Levenberg-Marquardt eğitim algoritmasının daha az hataya sahip olduğu, zaman açısından ise en hızlı 3. algoritma olduğu gözükmektedir.


Çizelge 4.26. Eğitim Algoritmaları tam veri seti hata ve zaman analizi

Geri Yayılım Eğitim Algoritması	Eğitim		Zaman(saniye)	
	Ort(hata)	SS(hata)	Ortalama	SS(zaman)
Levenberg –Marquardt –ÇKA1	0,099	0,014	12,110	6,823
Öğrenme Katsayısı Değişen–ÇKA2	0,190	0,020	79,088	43,895
Esnek Algoritma– ÇKA3	0,1365	0,0175	9,693	5,748
Fletcher-Reeves– ÇKA4	0,1169	0,0274	15,109	8,542
Powell-Beale– ÇKA5	0,1375	0,0289	13,797	7,892
Polak-Ribiere– ÇKA6	0,1162	0,0209	20,9289	11,858
Ölçekli Eşlenik Gradyan– ÇKA7	0,1300	0,0165	19,9871	11,396
Quasi-Newton – ÇKA8	0,1742	0,0202	2,727	1,472
Tek Adım Sekant – ÇKA9	0,1186	0,0249	23,474	13,1072




Şekil 4.23. Eğitim algoritmaları tam veri seti zaman-hata analizi

Eğitim algoritmalarının eğitim ve test veri ROC eğrileri Şekil 4.24 ve Şekil 4.25'te verilmektedir. Levenberg-Marquardt eğitim algoritması test seti ROC alan değeri Şekil 4.25'te görüldüğü gibi en yüksek alan değeri olan 0,954 değerini almıştır.



Şekil 4.24. Eğitim algoritmaları eğitim veri seti ROC eğrileri



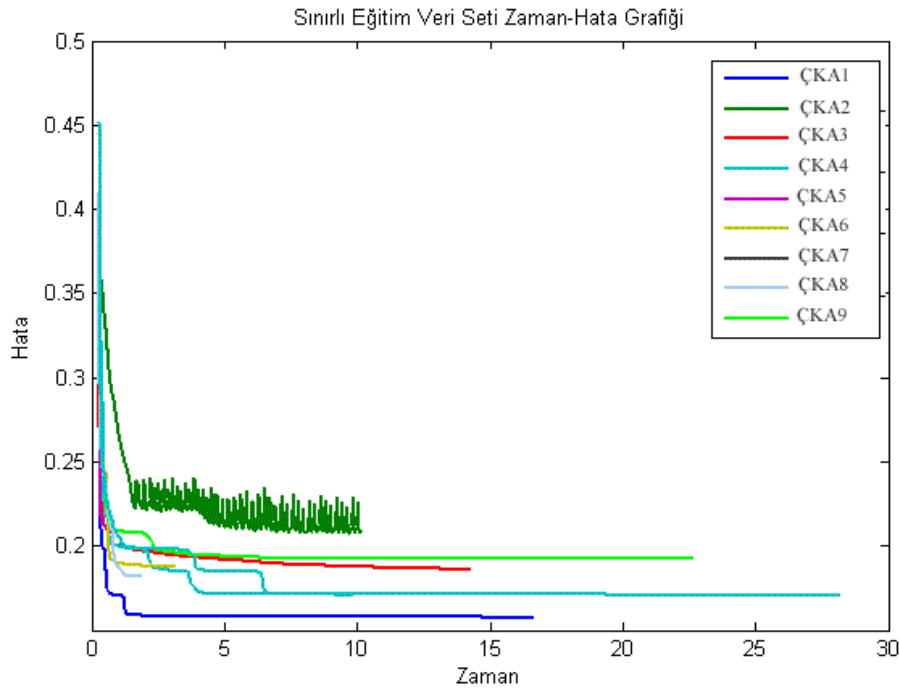
Şekil 4.25. Eğitim algoritmaları test veri seti ROC eğrileri

Sınırlı veri seti ile oluşturulan ağlarda kullanılan eğitim algoritmalarının hata ve zaman süreleri Çizelge 4.27'de kıyaslanmıştır. Levenberg-Marquardt eğitim

algoritmasının hata ortalama ve standart sapma değerleri 0,1598, 0,0115 olarak elde edilmiştir. Powell-Beale eşlenik gradyan algoritması zaman ortalama ve standart sapma değerleri 0,5251 ve 0,16131 olarak elde edilmiştir. Şekil 4.26'da eğitim algoritmaları hata-zaman analizleri incelendiğinde en düşük hataya Levenberg-Marquardt eğitim algoritması sahiptir ve en hızlı eğitim algoritmalarından biridir.


Çizelge 4.27. Eğitim algoritmaları sınırlı veri seti hata ve zaman analizi

Eğitim Algoritması	Eğitim		Zaman(saniye)	
	Ort(hata)	SS(hata)	Ortalama	SS(zaman)
Levenberg –Marquardt –ÇKA1	0,1598	0,0115	8,367	4,7142
Öğrenme Katsayısı Değişen–ÇKA2	0,2272	0,0277	5,2602	2,8461
Esnek Algoritma– ÇKA3	0,1915	0,0085	7,2806	4,053
Fletcher-Reeves– ÇKA4	0,1817	0,0241	5,1102	2,7742
Powell-Beale– ÇKA5	0,2199	0,0269	0,5251	0,1631
Polak-Ribiere– ÇKA6	0,198	0,0318	1,7406	0,8335
Ölçekli Eşlenik Gradyan– ÇKA7	0,195	0,0099	11,4771	6,4985
Quasi-Newton – ÇKA8	0,2023	0,0361	1,1169	0,4797
Tek Adım Sekant – ÇKA9	0,1767	0,0153	14,3630	8,0313



Şekil 4.26. Eğitim algoritmaları sınırlı veri seti zaman-hata analizi

Sınırlı veri seti eğitim algoritmaları ile oluşturulan eğitim ve test veri seti ROC eğrileri Şekil 4.27 ve Şekil 4.28’de verilmektedir. ROC eğrileri karşılaştırıldığında Levenberg-Marquardt ve Fletcher-Reeves eğitim algoritmalarının alan değerleri 0,938 ve 0,875 olarak elde edilmiştir. Şekil 4.28’den bu algoritmaların AUC değerlerinin daha iyi olduğu gözükmektedir.



Şekil 4.27. Eğitim algoritmalarının sınırlı eğitim seti ROC eğrileri


4.2.3. YSA'nın farklı veri seti ile test edilmesi

Meme kanseri hastalarının koltuk altı lenf nodlarını belirlemek için oluşturulan ağlar içinde 216 hastanın verileri içeren tam veri setinin eğitilmesi için kullanılan Levenberg- Marquardt eğitim algoritması ile oluşturulan 9 girişli, 4 nöronlu tek gizli katmanlı ve tek çıkışlı yapının Çizelge 4.15’te yüksek korelasyon katsayısına sahip olduğu görülmektedir. Aynı ağın Çizelge 4.26 ve Şekil 4.23’te diğer algoritmalarla yapılan hata-zaman analizleri sonucunda daha az hataya sahip olduğu ve en hızlı ağlardan biri olduğu gözükmektedir. Oluşturulan yapı Matlab içinde bulunan meme kanseri hastalarına ait verilerden oluşan farklı bir veri seti ile sınanmıştır [63].

ÇKA için seçilen girişler, 699 meme kanseri hastasının tümör hücre bilgileri, protein bilgileri, kalınlık bilgileri olmak üzere 9 farklı verisidir. Ağ için istenilen çıktı tümörün iyi ya da kötü huylu olup olmadığıdır. Çizelge 4.28'de görüldüğü gibi oluşturulan ağ, meme kanseri verilerini içeren farklı bir test veri setinde de %91,3 doğruluk sonucunu vermiştir. Bu sonuç koltuk altı lenf nodu durumunu tespit için seçilen ÇKA yapısının başarılı olduğunu göstermektedir.

Çizelge 4.28. Farklı meme kanseri veri seti performans sonuçları

Veri Setleri	R	Duyarlılık (%)	Belirlilik (%)	Doğruluk (%)
Eğitim	0,775	90,5	84,0	88,2
Test	0,83	90,6	93,8	91,3



Şekil 4.28. Eğitim algoritmalarının sınırlı test seti ROC eğrileri

4.3. YSA ve LR Analizleri Karşılaştırılması

Lojistik regresyon ve yapay sinir ağları ile meme kanseri hastalarının koltuk altı lenf nod durumunu belirlemek için yapılan analizlerde tam veri seti performans analiz

sonuçları başarılı bulunurken, sınırlı veri setindeki örnek sayısının az olması sebebi ile sınırlı set performans analiz sonuçları çok başarılı bulunmamıştır.

Lojistik regresyon ile kabul edilen adım adım seçim modeline göre duyarlılık, belirlilik, doğruluk ve ROC eğri alanı test verileri için %50, %86, %74, 0,758 bulunmuştur. Levenberg-Marquardt eğitim algoritması ile oluşturulan çok katmanlı sinir ağının test verileri için duyarlılık, belirlilik, doğruluk ve ROC eğri alanı, %88,8, %97,2, %94,4 ve 0,954 olarak bulunmuştur. Yapay sinir ağı lojistik regresyona göre çok daha başarılı sonuç vermiştir (Çizelge 4.29).

Çizelge 4.29. YSA ve LR analiz sonuçları

Modeller	Duyarlılık (%)	Belirlilik (%)	Doğruluk (%)	AUC
LR	50,0	86,1	74,1	0,758
YSA	88,8	97,2	94,4	0,954

4.4. Tartışma

Yapay sinir ağları pek çok alanda olduğu gibi tıpta tanı ve teşhis amaçlı olarak istatistiksel yöntemlere alternatif olarak kullanılmaktadır [23-39]. Bu çalışmada meme kanseri hastalarının koltuk altı lenf nod durumunu belirlemek için yapay sinir ağları ve lojistik regresyon yöntemleri kullanılmıştır.

270 meme kanseri hastasının verileri eğitim ve test setlerine ayrılmıştır. Öncelikle 9 veriden oluşan tam eğitim veri seti ile lojistik regresyon analizi yapılmıştır. Oluşturulan lojistik regresyon modelleri test seti ile test edilmiştir. Anlamli bulunan veriler ile oluşturulan eğitim ve test veri setleri tekrar modellere uygulanmış ve ROC değerleri elde edilmiştir (Çizelge 4.4). Oluşturulan modeller birbirlerini ile kıyaslanmış ve I. model seçilmiştir (Çizelge 4.5).

Koltuk altı lenf nod durumu belirlemek için uzman doktor tarafından belirlenen veriler için ÇKA'lar oluşturulmuştur. Karşılaştırma yapabilmek için 9 farklı eğitim algoritması ile oluşturulan ağlar eğitim setleri ile eğitilmiş ve test setleri ile test edilmişlerdir. Ağların performansları korelasyon katsayısı, ROC analiz yöntemleri ile karşılaştırılmış ve doğru ağ yapısı Çizelge 4.15 ve Şekil 4.12'den elde edilmeye çalışılmıştır. Gizli katmanda 4 nöron bulunan ağ yapıları regresyon ve ROC analizleri değerlendirildiğinde diğer ağlara göre başarılı bulunmuştur.

Çok katmanlı yapay sinir ağları lojistik regresyon sonucunda anlamlı bulunan 4 veri ile tekrar eğitilmiş, test verileri ile test edilmiş, ağ yapıları regresyon ve ROC analiz yöntemleri ile değerlendirilmiştir. Doğru ağ yapısı için farklı eğitim algoritmaları içeren ağların gizli katman nöron sayıları ve korelasyon katsayıları karşılaştırılmıştır. 2 nöronlu ağların daha başarılı olduğu Çizelge 4.25 ve Şekil 4.22'de görülmektedir. Sınırlı test seti veri setinin örnek sayısının çok düşük olması sebebi ile oluşturulan ağların hiçbirinde korelasyon katsayısı 0,7-1,0 değerine ulaşamamıştır.

Farklı eğitim algoritmaları kullanılarak sınırlı ve tam eğitim setleri ile oluşturulan ağların hata zaman analizleri yapılarak eğitim algoritmaları Şekil 4.23 ve Şekil 4.26 'da karşılaştırılmıştır. Sınırlı veri seti ile oluşturulan ağların veri setinin çok küçük olması sebebiyle korelasyon katsayıları oldukça düşük elde edilmiştir. Levenberg-Marquardt algoritması ile oluşturulan ağ, korelasyon katsayısının ve ROC değerlerinin yüksek olması aynı zamanda hata zaman açısından diğer algoritmalarından daha iyi olması sebebiyle tercih edilmiştir (Şekil 4.25).

Levenberg-Marquardt algoritması ile oluşturulan 9 girişli, 4 nöronlu tek gizli katmanlı, tek çıkışlı ağ farklı bir meme kanseri veri seti ile ağ yapısının geçerliliğini belirlemek için eğitilmiş ve test edilmiştir (Çizelge 4.28).

Oluşturulan yapay sinir ağı ve lojistik regresyon modelleri Çizelge 4.29'da karşılaştırılmıştır ve yapay sinir ağı daha başarılı olmuştur. Literatürde meme kanseri hastalarının koltuk altı lenf nod durumlarını belirlemek için oluşturulan yapay sinir

ađları dođruluk deđerleri daha yuĐsek elde edilmiŐtir [35, 39]. OluŐturulan yapay sinir ađlarının hepsinde hastaların gen bilgileri gibi zor elde edilebilir verileri kullanılmıŐtır ve hiĐbiri SLNB ve AD ameliyatlarının uygulanmasının onune geĐememiŐtir. Bu alıŐma ile oluŐturulan yapay sinir ađı giriŐ bilgileri her hastanede kolaylıkla elde edilebilir klinik ve patolojik verilerdir.

5. SONUÇ VE ÖNERİLER

Meme kanseri günümüzde kadınlarda en sık görülen kanser türlerinden biridir. Meme kanserinin evrelendirilmesinde ve tedavisinin belirlenmesinde kullanılan en önemli bilgilerden biri hastanın koltuk altı lenf nod durumudur. Meme kanseri tümörleri koltuk altı lenf nodlarına yayılarak hastanın yaşam süresini tehdit edebilmektedir. Hastaların koltuk altı lenf nodlarının durumunu belirlemek için cerrahi işlemler yapılmaktadır. Ancak bu cerrahi işlemler sonrasında hastalarda ciddi yan etkiler oluşmaktadır. Bu sebeplerle, tümör belirleyiciler ile koltuk altı lenf nodlarının belirlemek için araştırmalar yapılmış, tümör çapı, lenfatik yayılım gibi bazı veriler anlamlı bulunmuş ancak cerrahi işlemlerin yerini alamamışlardır.

Bu çalışmada Ankara Numune Eğitim ve Araştırma Hastanesi ve Ankara Onkoloji Eğitim ve Araştırma Hastanesi'ne başvuran 270 meme kanseri hastasının kolaylıkla elde edilebilir türde olan verileri ile yapay sinir ağı ve lojistik regresyon analizleri yapılmıştır. Lojistik regresyon analizi, tümör derecesi, yaş, menopoz durumu, lenfatik yayılım verilerinin koltuk altı lenf nod durumunu belirlemek için etkili olduğunu belirlemiştir. Uzman doktor tarafından belirlenen giriş değerleri ile oluşturulan yapay sinir ağları arasında test seti ROC analiz sonuçları, yüksek korelasyon katsayısı, en az hata ve az eğitim süresi gibi sebeplerle Levenberg-Marquardt algoritmasını kullanan ağ seçilmiştir. Seçilen ağ farklı bir meme kanseri veri seti ile tekrar eğitilip, test edilerek, modelin geçerliliği sınanmış ve başarılı sonuçlar elde edilmiştir.

Lojistik regresyon analizi sonrası anlamlı bulunan tümör derecesi, yaş, menopoz durumu, lenfatik yayılım olmak üzere 4 giriş verisi ile oluşturulan YSA modelleri tam veri seti kadar başarılı performans sonuçları verememiştir. Veri setindeki veriler kategorik olduğundan aynı olup tekrarlayan örnekler çıkarılmış ve veri setindeki örnek sayısı oldukça küçülmüştür. Bu durum yapay sinir ağının koltuk altı lenf nod durumunu sınıflandıramamasına sebep olmuştur. Daha fazla sayıda örnek içeren setlerle yapılacak analizlerle daha iyi sonuçlar elde edilebilir.

Lojistik regresyon ve seçilen yapay sinir ağı modelleri kıyaslandığında yapay sinir ağı değerleri daha başarılı olmuştur. Ağın korelasyon katsayısı 0,872, duyarlılık değeri %88,8, belirlilik değeri %97,2, doğruluk değeri %94,4 olarak elde edilmiştir. Elde edilen bu değerler literatürdeki YSA'ndan daha iyi olmamakla birlikte çalışmanın amacını yerine getirecek düzeydedir [35, 39]. Çünkü önceki çalışmalarda koltuk altı lenf nod durumunu belirleyecek veriler arasında çok farklı gen verileri içeren setler kullanılmıştır. Bu çalışmada kolay elde edilebilir meme kanseri hasta bilgilerinin koltuk altı lenf nod durumunu belirleme durumu araştırılmıştır ve test veri sonuçları yeterli bulunmuştur.

Çalışmada 270 meme kanseri hastasının verileri kullanılmıştır. Meme kanseri hastalarının farklı verilerinin, oluşturulan yapay sinir ağı ile mutlaka test edilmesi gerekmektedir. Yapay sinir ağları tıpta yıllardır tanı ve teşhis amaçlı olarak sürekli kullanılmaktadır. Ancak yapılan çoğu çalışmanın sonrası bilinmemektedir. Bu amaçla Ankara Numune Hastanesi Genel Cerrahi servisine elde edilen yapay sinir ağını içeren bir program oluşturularak kurulmuştur. Böylelikle farklı veriler elde edilerek yapay sinir ağının geliştirilmesi sağlanacaktır.

KAYNAKLAR

1. Aydiner, A., Topuz, E., "Meme Kanseri: Tanı-Tedavi-Takip", *Nobel Tıp Kitabevleri*, İstanbul, 1-10 (2006).
2. Arsene, C. T. C., Lisboa, P. J. G., "Artificial neural networks used in the Survival Analysis of Breast Cancer Patients: A Node-Negative Study", *Outcome Prediction in Cancer*, 191-239 (2007).
3. Topuzlu, C., "Meme kanserinin tarihçesi", *Nobel Tıp Kitabevleri*, İstanbul, 7-15, 145-153 (2005).
4. Baum, M., Chaplain, M. A., Anderson, A. R., Douek, M., Vaidya, J. S., "Does breast cancer exist in a state of chaos?", *Eur. J. Cancer*, 35: 886-891(1999).
5. Logan, V., "Incidence and prevalence of lymphoedema: a literature review.", *Journal of Clinical Nursing*, 4: 213-219 (1995).
6. Renwick, S. B., "Can axillary dissection in breast cancer be avoided? Introduction", *World J. Surg.*, 25: 759-760 (2001).
7. Andrew, J. Spillane, N., Sacks, P. M., "Role of axillary surgery in early breast cancer: review of the current evidence", *Australian and New Zealand Journal of Surgery*, 70 (7): 515 – 524 (2001).
8. Fraile, M., Rull, M., Julian, F. J., Fuste, F., Barnadas, A., Llatjos, M., Castella, E., Gonzalez, J. R., Vallejos, V., Alastrue, A., Broggi, M. A., "Sentinel node biopsy as a practical alternative to axillary lymph node dissection in breast cancer patients; An approach to its validity", *Annals of Oncology*, 11 (6): 701-705 (2000).
9. Veronesi, U., Paganelli, G., Viale, G., Galimberti, V., Luini, A., Zurrada, S., Robertson, C., Sacchini, V., Veronesi, P., Orvieto, E., Cicco, D., Intra, M., Tosi, G., Scarpa, D., "Sentinel lymph node biopsy and axillary dissection in breast cancer: results in a large series", *Journal of the National Cancer Institute*, 91 (4): 368-373 (1999).
10. Hiroyuki, T., Masafumi, K., Takashi, Y., Ninomiya, J., Hagiwara, Y., Kamimura, M., Hayashi, Y., Tozuka, K., Suemasu, K., Inoue K., Toshio T. T., "Current trends of sentinel lymph node biopsy for breast cancer:a surgeon's perspective", *Breast Cancer*, 14 (4): 362-370 (2007).
11. Patani, N.R., Dwek, M.V., Douek, M., "Predictors of axillary lymph node metastasis in breast cancer:A systematic review", *European Journal of Surgical Oncology*, 33: 409-419 (2007).

12. Elmas, Ç., "Yapay Sinir Ağları", *Seçkin Yayınevi*, Ankara, 21-65 (2003).
13. Greco, M., Agresti R., Cascinelli, N., Casalini, P., Giovanazzi, R., Maucione, A., Tomasic, G., Ferraris, C., Ammatuna, M., Pilotti, S., Menard, S., "Breast cancer patients treated without axillary surgery clinical implications and biologic analysis", *Annals of Surgery*, 232 (1):1-7 (2000).
14. Carter, C. L, Allen, C., Henson, D. E., "Relation of tumor size, lymph node status and survival in 24,740 breast cancer cases", *Cancer*, 63: 181-187 (1989).
15. Mussurakis, S., Buckley, D. L., Horsman, A., "Prediction of axillary lymph node status in invasive breast cancer with dynamic contrast-enhanced MR imaging", *Radiology*, 203: 317-321 (1997).
16. Clark, G. M., Osborne, C. K., McGuire, W. L., "Correlations between estrogen receptor, progesterone receptor, and patient characteristics in human breast cancer", *Journal of Clinical Oncology*, 2: 1102-09 (1984).
17. Gajdos, C., Tartter, P. I., Bleiweiss, I. J., "Lymphatic invasion, tumor size, and age are independent predictors of axillary lymph node metastases in women with t1 breast cancers", *Annals of Surgery*, 230 (5): 692-696 (1999).
18. Niu, Y., Fu, X., Lv, A., Fan, Y., Wang Y., "Potential markers predicting distant metastasis in axillary node-negative breast carcinoma", *Int. J. Cancer*, 98, 754-760 (2002).
19. Tez, S., Yoldaş, Ö., Kılıç, Y.A., Dizen, H., Tez, M., "Artificial neural networks for prediction of lymph node status in breast cancer patients", *Medical Hypotheses*, 68 (4): 922-923 (2007).
20. Haykin, S., "Neural networks: a comprehensive foundation", *Prentice Hall*, USA, 1-50, 117-156,156-256 (1999).
21. Fausett, L., "Fundamentals of neural networks: Architectures, Algorithms and Applications", *Prentice-Hall*, USA, 1-100 (1994).
22. Papik, K., Molnar, B., Schaefer, R., Dombovari, Z., Tulassay, Z., Feher, J., "Application of neural networks in medicine-a review" , *Med. Sci. Monit.* , 4 (3):538-46 (1998).
23. Lisboa, P. J., Taktak A. F. G., "The use of artificial neural networks in decision support in cancer: A systematic review", *NeuralNetworks*, 19 (4): 408-415 (2006).

24. Marchevsky, A. M., "The use of artificial neural network for the diagnosis and estimation of prognosis in cancer patients", *Outcome Prediction in Cancer*, 243-259 (2007).
25. Mangasarian, O. L., Street, W.vN., Wolberg, W. H., "Breast cancer diagnosis and prognosis via linear programming", *Operations Research*, 43 (4): 570-577 (1995).
26. Baker, J. A., Kornguth, P. J., Lo, J. Y., Williford, M.E., Floyd, Jr. C. E., "Breast cancer: prediction with artificial neural network based on BI- RADS standardized lexicon", *Radiology*, 196: 817-822 (1995).
27. Wu, Y., Giger, M. L., Doi, K., Vyborny, C. J., Doi, K., Schmidt, R. A., Metz, C. E. , "Artificial neural networks in mammography: application to decision making in the diagnosis of breast cancer", *Radiology*, 187: 81-87 (1993).
28. Übeyli, E. D., "Implementing automated diagnostic systems for breast cancer detection" , *Expert Systems with Applications*, 33 (4): 1054-1062 (2007).
29. Jerez-Aragone'sa, J. M., Go'mez-Ruiza, J. A., Ramos-Jime'neza, G., Mun-oz-Pe'reza, J., Alba-Conejo, E., "A combined neural network and decision trees model for prognosis of breast cancer relapse", *Artificial Intelligence in Medicine*, 27: 45-63 (2003).
30. Markey, M. K., Lo J. Y., Tourassi, G. D., Floyd, Jr. C. E., "Self-organizing map for cluster analysis of a breast cancer database", *Artificial Intelligence in Medicine*, 27: 113-127 (2003).
31. Ravdin, P. M., Gary, M. C. , Hilsenbeck, S. G., Owens, M. A., Vendely, P., Pandian, M. R. ve McGuire, W. L., "A demonstration that breast cancer recurrence can be predicted by Neural Network analysis", *Breast Cancer Research and Treatment*, 21 (1): 47-53 (1992).
32. Wilding, P., Morgan, M. A., Grygotis, A. E., Shoffner, M. A., Rosato, E. F. "Application of backpropagation neural networks to diagnosis of breast and ovarian cancer", *Cancer Lett.*, 77: 2-3 (1994).
33. Astion, M. L., Wilding, P. , "Application of neural networks to the interpretation of laboratory data in cancer diagnosis", *Clin Chem.*, 38 (1): 34-8 (1992).
34. Grey, S. R. , Dlay, S. S. , Leone, B. E. , Cajone, F., Sherbet, G. V. , "Prediction of nodal spread of breast cancer by using artificial neural network-based analyses of S100A4, nm23 and steroid receptor expression", *Clinical and Experimental Metastasis* , 20 (6): 507-514 (2003).

35. Lancashire, L. J., Rees, R. C., Ball, G. R., “Identification of gene transcript signatures predictive for estrogen receptor and lymph node status using a stepwise forward selection artificial neural network modelling approach”, *Artificial Intelligence in Medicine*, 43 (2): 99-111 (2008).
36. Naguib, R. N., Adams, A. E., Horne, C. H., Angus, B., Smith, A. F., Sherbet, G. V., Lennard T. W., “Prediction of nodal metastasis and prognosis in breast cancer: a neural model”, *Anticancer Res.* , 17: 2735-41 (1997).
37. Mattfeldt, T., Kestler, H. A., Sinn, H. P., “Prediction of the axillary lymph node status in mammary cancer on the basis of clinicopathological data and flow cytometry”, *Medical and Biological Engineering and Computing*, 42 (6): 733-739 (2004).
38. Naguib, R. N. G., Adams, A. E., Horne, C. H. W., Angus, B., Sherbet, G. V., Lennard T. W. J., ”The detection of nodal metastasis in breast cancer using neural network techniques”, *Physiological Measurement*, 17 (4): 297- 303 (1996).
39. Marchevsky, A. M., Shah, S., Patel, S., “Reasoning with uncertainty in pathology: Artificial neural networks and logistic regression as tools for prediction of lymph node status in breast cancer patients”, *Modern Pathology*, 12 (5): 505-513 (1999).
40. Öztemel, E., “Yapay sinir ağları”, *Papatya Yayıncılık*, İstanbul, 13-113 (2003).
41. Nabiyev, V. V., “Yapay zeka:problemler-yöntemler-algoritma”, *Seçkin Yayıncılık*, Ankara, 597-625 (2005).
42. Binici, E., “Java ile yapay zeka mekanizmasına sahip bir ağ yönetim sistemi geliştirilmesi”, Yüksek Lisans Tezi, *Ege Üniversitesi Fen Bilimleri Enstitüsü*, İzmir, 28-48 (2006).
43. Taş, E., “Yapay sinir ağlarında momentumlu dik iniş ve eşlenik gradyan eğitim algoritmalarının karşılaştırılması”, Yüksek Lisans Tezi, *Anadolu Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir, 5-61 (2005).
44. Le Cun, Y., “Efficient learning and second order methods”, *Tutorial presented at Neural Information Processing Systems 93, Denver*, 1-71 (1993).
45. Demuth, H., Beale, M., Hagan, M., “Neural Network Toolbox™ 6 User’s Guide, The MathWorks, Inc., Natick, *Massachusetts*, 156-228 (1992).
46. Kollias, S., Anastassiou, D., “An adaptive least squares algorithm for the efficient training of artificial neural Networks”, *IEEE Transactions on Circuits and Systems*, 36 (8): 1092-1101 (1989).

47. RiedMiller, M., "Rprop-description and implementation details", *University of Karlsruhe , W-76128, Technical Report, Karlsruhe,Germany*, 1-3 (1994).
48. Charalambous, C., "Conjugate gradient algorithm for efficient training of artificial neural Networks", *IEEE Proceedings-G on Circuits, Devices and Systems*, 139 (3): 301-310 (1992).
49. Setiono, R., Hui, C.K.L., "Use of a quasi-newton method in a feedforward neural network construction algorithm", *IEEE Transactions on Neural Networks*, 6 (1): 273-277 (1995).
50. Hagan, M. T., Menhaj, M. B., "Training feedforward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks*, 5 (6): 989-993 (1994).
51. Bolat, S., Kalenderli, Ö., "Levenberg-Marquardt algoritması kullanılan yapay sinir ağı ile elektrot biçim optimizasyonu", *International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN(2003)*, Çanakkale, 2-4 (2003).
52. Özdamar, K., "Spss ile Biyoistatistik", *Kaan Kitabevi*, İstanbul, 419-460 (2003).
53. Ürük, E., "İstatistiksel uygulamalarda lojistik regresyon analizi", Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 7-24, 54-72 (2007).
54. Tezcan, B., "Lojistik regresyon analizi ve sigortacılık sektöründe bir uygulama", Marmara Üniversitesi, *Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü*, İstanbul ,16-50 (2006).
55. Fawcett, T., "An introduction to ROC analysis ", *Pattern Recognition Letters*, 27: 861-874 (2006).
56. Slaby A. , "ROC analysis with Matlab", *Proceeding of the ITI 2007 29th Int. Conf. on Information Technology Interfaces, Cavtat*, Croatia, 191-196 (2007).
57. Özyılmaz, L., Yildirim, T., "Artificial neural networks for diagnosis of hepatitis disease", *Proceedings of the International Joint Conference on Neural Networks*, 1: 586- 589 (2003).
58. Tokan, F., Türker, N., Yıldırım, T., " Determination of the neural network performances in the medical prognosis by roc analysis", *2006 IEEE 14th on Signal Processing and Communications Applications*, Antalya, 1-4 (2006).

59. Verikas, A., Bacauskiene, M., "Using artificial neural networks for process and system modelling", *Chemometrics and Intelligent Laboratory Systems*, 67 (2): 187-191 (2003).
60. Schiffmann, W., Joost, M., Werner, R., "Optimization of the backpropagation algorithm for training multilayer perceptrons", *Technical report University of Koblenz: Institute of Physics, Koblenz-Germany*, 1-36 (1992).
61. Lawrence, S., Giles, C. L., Tsoi, A. C., "What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation", *Tech. Report UMIACS-TR-96-22, CS-TR-3617, Institute for Advanced Computer Studies: University of Maryland, Maryland, USA*, 1-35 (1996).
62. Mazurowski, M.A., Habas, P.A., Zurada, J.M., Lo, J.Y., Baker, J.A., Tourassi, G.D, "Training neural network classifiers for medical decision making: The effects of imbalanced datasets on classification performance", *Neural Networks*, 21 (2-3): 427-436 (2008).
63. Internet : Murphy, P.M., Aha, D.W., CA: University of California, Department of Information and Computer Science, "UCI Repository of machine learning databases", <http://www.ics.uci.edu/~mllearn/MLRepository.html> (1994)

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KARAKIŞ, Rukiye
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 21.09.1980 Sivas
 Medeni hali : Bekar
 Telefon : 0 (312) 2028580
 Faks : 0 (312) 2028580
 e-mail : rukiyekarakis@gazi.edu.tr

Eğitim

Derece	Eğitim Birimi	Mezuniyet tarihi
Yüksek lisans	Gazi Üniv. /Elek. ve Bilg. Eğt. Böl.	2008
Lisans	O.M.Ü. / Bilg. ve Öğr. Tek. Öğrt.	2006
Lise	Sivas Kongre Lisesi(YDA)	1998

İş Deneyimi

Yıl	Yer	Görev
2006–2008	Gazi Üniversitesi	Araştırma Görevlisi
2005–2006	Cumhuriyet Üniversitesi	Araştırma Görevlisi
2004–2005	Sivas Süleyman Demirel İ.Ö.O.	Öğretmen
2002–2004	Sivas Pamukpınar Y.İ.B.O.	Öğretmen

Yabancı Dil

İngilizce

Yayınlar

1. Güler I., Toprak A., Demirhan A., Karakiş R., "MR images restoration with the use of fuzzy filter having adaptive membership parameters", *J. Med. Syst.*, 32 (3): 229–234(2008).

Hobiler

Havacılık, Model Uçak, Doğa Yürüyüşü, Kitap Okumak