



Yapay Sinir Ağları Kullanılarak (EKG) Verilerinden Kalp Hastalığı Teşhisi

Yazılım Mühendisliği Ana Bilim Dalı

Dönem Projesi

Murat Kaan Çam

Y220234141

Proje Danışmanı :Doc.Dr.Vahide Bulut

Subat 2024

Özet

Kalp krizi günümüzde en sık ölüm nedenlerinden biri olmaktadır. Ve bu hastalığın erken teşhisi önemlidir. Kalp krizi teşhisinde yapay sinir ağları tıpkı diğer alanlarda kullanıldığı gibi kullanılabilir. Doğru teşhisi yapabilmek için ağın topolojisinin iyi seçilmesi gerekmektedir. Çalışmada Python programlama dili kullanıldı. Günümüzde popülerliği gittikçe artan yapay sinir ağı ile model eğitildi. Kalp krizi önemli bir sağlık sorunu olduğundan dolayı yapay zekanın da bu duruma dahil olması daha fazla insanı kurtaracaktır. İleri beslemeli sinir ağı kullanarak model inşa edildi.

Anahtar Sözcükler: Kalp krizi, yapay sinir ağları, derin öğrenme, ileri beslemeli sinir ağları, ah_kalbim dataset.

Abstract

Heart attack is one of the leading causes of death nowadays. Early diagnosis of this disease is crucial. Artificial neural networks (ANNs) can be used in heart attack diagnosis, similar to their applications in other fields. The network topology must be carefully chosen to achieve accurate diagnosis. This study used the Python programming language and trained a model using a popular deep learning framework. Since heart attack is a significant health problem, incorporating artificial intelligence can potentially save more lives. A feedforward neural network was constructed and trained using the ah_kalbim dataset obtained from Kaggle. The dataset was split into training and testing sets for model training.

Keywords: Heart attack, diagnosis, artificial neural networks, deep learning, feedforward neural network, ah_kalbim dataset.

İÇİNDEKİLER

İç Kapak Sayfası	Sayfa
Özet	1
Abstract	2
Bölüm 1	5
Genel Bilgiler	5
1.Kalp ve Damar Hastalıkları	5
1.1 Akut Kroner Sendrom	5
1.2 Kalp krizi	6
1.2.1 Kalp Krizi Tanısı	7
1.2.2 Göğüs Ağrısı	8
1.2.3 Fizik Muayne	8
1.2.4 Laboratuvar Bulguları- Testleri	8
1.2.4.1 Kreatinin kinaz	8
1.2.4.2 Troponinler	8
1.2.4.3 Miyoglobin	8
1.2.4.4 Elektrokardiyografi(EKG)	8
1.2.5 Kalp Damar Hastalıklarını Tetikleyen Faktörler	9
1.2.5.1 Obezite	9
1.2.5.2 Hipertansiyon	9
1.2.5.3 Diyabet	10
1.2.5.4 Yüksek Kan Kolesterolü	10
1.2.5.5 Cinsiyet	10
1.2.5.6 Yaş	10
1.2.5.7 Tütün Kullanımı	10
1.2.5.8 Alkol Kullanımı	10

1.2.5.9 Aile Öyküsü	10
1.3 Yapay Sinir Ağları	11
1.3.1 Biyolojik Sinir Ağları	11
1.3.2 YSA'nın tarihçesi	11
1.3.3 Yapay Sinir Hücrelerinin Yapısı	13
1.3.4 YSA'nın Özellikleri	16
1.3.5 Ağ Yapıları	17
1.3.5.1 İleri Beslemeli Sinir Ağları(Feedforward Neural Network)	17
1.3.5.2 Tek Katmanlı İleri Beslemeli Ağlar	17
1.3.5.3 Çok Katmanlı İleri Beslemeli Ağlar	18
1.3.5.4 Geri Dönüşümlü Sinir Ağları (Recurrent Neural Networks)	20
1.3.6 Öğrenme Stratejileri	21
1.3.6.1 Danışmanlı Öğrenme (Supervised Learning)	21
1.3.6.2 Danışmansız Öğrenme	21
1.3.6.3 Tavsiyeli Öğrenme(Reinforcement Learning)	22
1.3.6.4 Öğrenme Kuralları	22
1.3.6.5 Çevrimiçi (On-line) Öğrenme	22
1.3.6.6 Çevrimdışı (off-line) Öğrenme	22
1.3.7 Yapay Sinir Ağı Modelleri Ve Öğrenme Algoritmaları	22
1.3.7.1 Tek Katmanlı Algılayıcılar	22
1.3.7.2 Basit Algılayıcı (Perceptron) Modeli	22
1.3.7.3 Adaline Modeli	23
1.3.7.4 Çok Katmanlı Algılayıcılar	23
1.3.7.5 Geri Yayılım (Backpropagation)	24
1.3.8 Yapay Sinir Ağlarında Geri Yayılım Algoritması	24
1.3.8.1 İleri Yayılım	24
1.3.8.2 Geri Yayılım	24
Bölüm 2	24
2.1 Verilerin İncelenmesi	24

Bölüm 3

2.3. Sonuç	29
Kaynaklar	30
Ekler	31
EK 1	31

Ekler

Tablolar Listesi	Sayfa
Şekil 1. Türkiye istatistik kurumu 2013- 2014 yılı ölüm verileri	6
Şekil 2. Akut kroner sendrom	7
Şekil 3. Kalp krizi oluşum süreci	8
Şekil 4. EKG dalga gösterimi	10
Şekil 5. Doğrusal olmayan nöron modeli	14
Şekil 6. Doğrusal fonksiyon	16
Şekil 9. Sigmoid Fonksiyonu	17
Şekil 11. Hiperbolik tanjant Fonksiyonu	17
Şekil 15 tek katmanlı ileri beslemeli ağ yapısı	20
Şekil 16. Çok katmanlı İleri beslemeli sinir ağı	21
Şekil 17. Geri dönüşümlü sinir ağı	22
Şekil 23 corelasyon grafiği	29
Şekil 26 Model Kayıp Grafiği	30

Bölüm 1

Genel

1.Kalp Ve Damar Hastalıkları

Kalp ve damar hastalıkları; koroner kalp hastalıkları, serebrovasküler hastalıklar, hipertansiyon, periferik arter hastalığı, romatizmal kalp hastalıkları, konjenital kalp hastalıkları, kalp yetmezliği ve kardiyomyopatileri kapsamaktadır. Kalp ve damar hastalıklarının gelişiminde; tütün kullanımı, fiziksel hareketsizlik, obeziteye yol açabilen sağlıksız beslenme gibi olumsuz davranış tarzları yanında diyabet, hipertansiyon, dislipidemi gibi hastalıklar yer almaktadır. 2012 yılında tüm dünyada bulaşıcı hastalıklara bağlı olmayan ölümlerin yüzde 46,2' si (17,5 milyon) kalp ve damar hastalıkları nedeniyledir. Türki İstatistik Kurumunun (TÜİK) ölüm verileri toplam ölümlerin içinde kalp hastalıklarının payının gittikçe artma eğiliminde olduğunu göstermektedir.

	2013 ^(*)		2014	
	Sayı	(%)	Sayı	(%)
Dolaşım sistemi hastalıkları	143.084	100,0	151.696	100,0
İskemik kalp hastalığı	55.753	39,0	60.040	39,6
Serebro-vasküler hastalık	35.977	25,1	37.403	24,7
Diğer kalp hastalığı	25.293	17,7	28.445	18,8
Hipertansif hastalıklar	18.337	12,8	17.572	11,6
Diğer	7.724	5,4	8.236	5,4

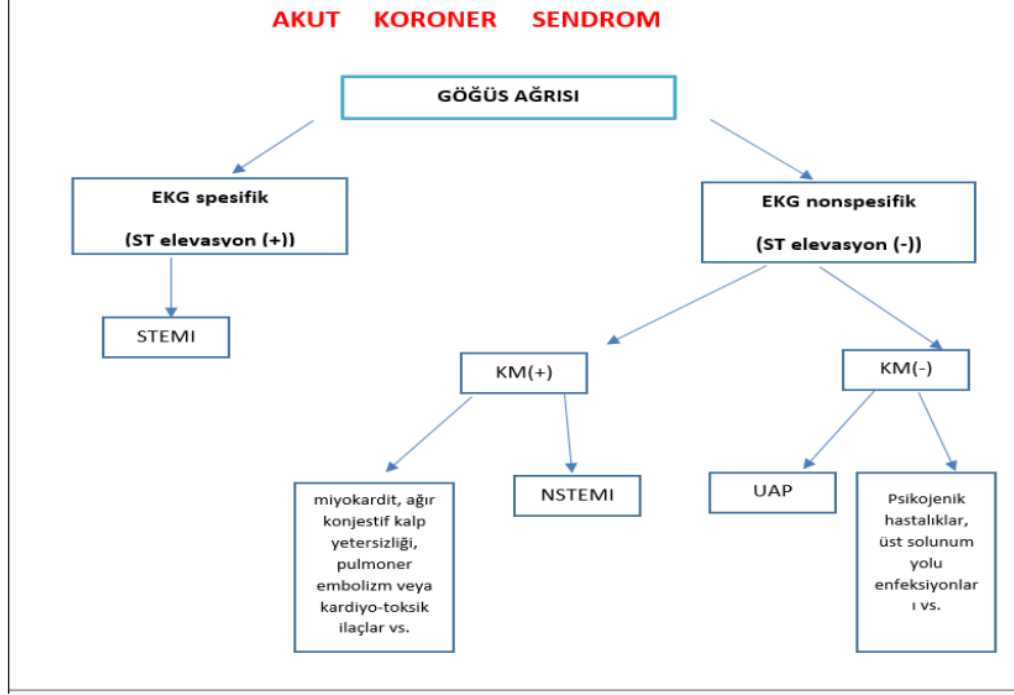
Şekil 1. Türkiye istatistik kurumu 2013- 2014 yılı ölüm verileri

TÜİK verilerine bakıldığında dolaşım sistemi rahatsızlıkları ölüm nedeni olarak ilk sırada yer almaktadır ve bunlar arasında istemik kalp hastalığı en büyük öneme sahiptir. İstemik kalp hastalığı koroner arterlerden geçen kan miktarının kalbin oksijen gereksinimini karşılayamayacak durumda olması sonucu ve çoğu kez arterlerin ateroskleroz ile daralması veya tıkanması sonucu ortaya çıkmaktadır. Bunu takiben oksijen yetersizliğinin derecesine göre angina pektoris ve kalp krizi görülmektedir.

1.1 Akut Kroner Sendrom

Acil servise göğüs ağrısı şikayeti ile başvuran hastaların önemli bir kısmı Akut Kroner Sendrom tanısı almaktadır. Bu tanının olabildiğince erken konulması ve trombolitik tedavinin veya girişimsel işlemlerin zamanında yapılmasıyla mortalite(ölüm) ve morbidite(sağkalım) olumlu yönde etkilenmekte olup hastaların hastanede kalış süresi azalıp hastalığın prognozunda iyileşme sağlamaktadır. Yapılan çalışmalar, acil servislere başvuran akut koroner sendrom tanısı alan hastaların %4-6' sının doğru teşhis konulamaması sonucu acil servislerden yanlışlıkla taburcu edildiğini göstermiştir.

Günümüzde, akut koroner sendromlar, başvuru elektrokardiyografileri (EKG) ve biyokimyasal belirteçlere dayanarak 3 guruba ayrılmıştır. Bunlar, EKG' sinde ST segment yükselmeli kalp krizi (STEMI) olan, EKG' sinde yükselmesi olmayan, ancak hasar belirteçlerinde yükselme ile ispat edilmiş kalp hasarı bulunanalar (NSTEMI) ve kararsız anjinalı(unstabil angina; UA) hastalardır.



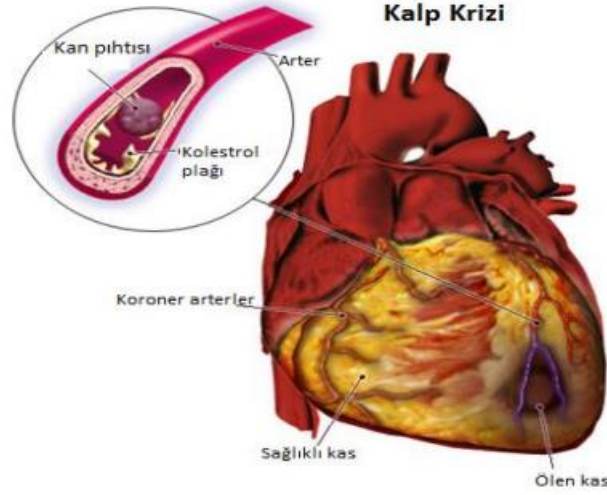
Şekil 2. Akut kroner sendrom

NSTEMI sıklığı STEMI tanısı alan hastaların görülme sıklığından daha fazladır. NSTEMI tanısı koymak da zordur ve bu nedenle prevalansı kestirmek kolay değildir. Geçen yıllar içinde STEMI sıklığı azalırken NSTEMI sıklığı bir artış söz konusu olduğu gözlemlenmektedir. STEMI hastane mortalitesi %7 iken NSTEMI hastane mortalitesi %5 tir.

Kalp krizi kaynaklı ölümlerin % 50'si ilk bir saat içinde olmaktadır. Bu oran ilk 24 saat içinde % 80'e ulaşılmaktadır. Erken dönemde tromboliz veya primer anjiyoplasti ile sağlanacak damar açıklığı, kalp krizi geçirmekte olan hastaların hızlı bir şekilde değerlendirilip tedavi sürecinin erken başlatılmasına yönelik stratejilerin geliştirilmesi önem taşımaktadır. Günümüzde açıkça bilinmektedir ki hastanede ilk müdahalesi yapılan hastaların %90'ı için çok erken dönemde tedaviye başlanması, önceki yıllarda düşünüldüğünden çok daha fazla önem taşımaktadır. Bu durumda MI'nün hastaneye gelmeden önceki ilk müdahalesinin önemi de artmaktadır.

1.2 Kalp Krizi

Miyokard infarktüsü (MI), genellikle kalp krizi olarak adlandırılan bu tıbbi sorunun nedeni kalbin bir bölümünün kanlanması/oksijenlenmesinin bozulmasıdır. Yani kalbi besleyen damarların tıkanması sonucu kalbe yeterli kanın gidememesi durumudur.



Şekil 3. Kalp krizi oluşum süreci

Kanlanamayan ya da diğer bir deyişle kan gitmediği için oksijen de gitmeyen kalp kası hücrelerinde hasar, kalp kası uzun süre oksijensiz kaldığında ise ölüm meydana gelir. Hem kadında hem de erkekte ölüm ile sonuçlanabilen bu sorun, hemen müdahale edilmesi gereken bir tıbbi acildir. MI'da semptomların başlangıcını izleyen ilk 6 saat içerisinde aspirin ve heparin ile birlikte kullanılan trombolitik ajanların, hastanedeki mortaliteyi %50'nin üzerinde azalttığı ve uzun süre sağ kalma oranını da önemli ölçüde arttırdığı bilinmektedir. Bu nedenle AKS tanısı alan hastaların uygun triajının ve MI'nün erken belirlenmesinin önemi daha da artmaktadır. MI hastalarının yaklaşık üçte birinde göğüs ağrısı atipik olduğundan ve hastaların yarıya yakınının EKG'si de nondiagnostik olduğundan bu hastalarda kardiyak belirteçlerin takibinin önemi artmaktadır. MI'ne bağlı ölümlerde hastaneye taşınma ve hastanın tanı alıp tedaviye başlama süresi büyük rol oynamaktadır.

1.2.1 Kalp Krizi Tanısı

Dünya Sağlık Örgütü (WHO)'ne göre MI teşhisi, göğüs ağrısı, EKG değişikliği ve kardiyak belirteçlerin yüksekliği kriterlerinden en az ikisinin varlığı ile konulmaktadır. MI'lı hastalar bazen farklı varyasyonlar ile başvurabilirler. Bu sebeple hekim göğüs ağrısı ile gelen hastaların kardiyak belirteçlerine hem MI'yı dışlamak hem de teşhis için mutlaka bakmalıdır.

1.2.2 Göğüs Ağrısı

Genellikle sol göğüs kemiği altında şiddetli ezici karakterde, sol kola yayılan göğüs ağrısı ve birlikte ölüm korkusu, göğüste rahatsızlık hissi ile ortaya çıkan göğüs ağrısıdır. Göğüsteki rahatsızlık hissi boyun, çene, sırt, omuz, sağ kol ve epigastrik (mide çukuru) bölgeye yansıyabilir. Göğüs ağrısı olmaksızın bu bölgelerden birinde ağrı olması muhtemeldir. MI özellikle ameliyat sonrası dönemdeki hastalarda, yaşlılarda, hipotansiyon, diyabet ve semptomlu kalp yetersizliği olan hastalarda göğüs ağrısı olamadan da görülebilir. Nitratlar ile geçmez ve hafiflemez. Göğüs ağrısı sıklıkla terleme, bulantı, halsizlik, korku ve ölüm hissi gibi belirtiler ile birlikte gelir.

1.2.3 Fizik Muayene

Genelde fizik muayene MI tanısına ek katkı sağlamaz. Çünkü bazı vakalarda fizik muayene tamamen normal olabilir. Ancak MI'nü taklit edebilecek diğer hastalıkları ekarte etmek, risk sınıflaması yapmak, gelişen kalp yetersizliği tanısını koymak gibi farklı amaçlar için fizik muayene yapılması önemlidir.

1.2.4 Laboratuvar Bulguları- Testleri

1.2.4.1 Kreatinin kinaz

CK kas hücrelerinde sentez edilen bir enzimdir. İzoenzimleri M ve B subünitelerinin birleşmesi ile meydana gelmektedir. CK-MM, iskelet kasında; CK-BB, beyinde; CK-MB, kalp kasında bulunur. Kalpte büyük konsantrasyonda ayrıca küçük miktarlarda iskelet kasında, dilde, ince bağırsakta ve diyafragmada bulunmaktadır. CKMB markerleri MI başlamasından 3 saat içerisinde serumda görülür. 12-24 saatte tepe düzeyine ulaşır. Serumda aktivitesi 1-3 gün devam etmektedir. Spesifitesi oldukça yüksektir. Bu yüzden son yıllarda CK-MB ölçümü oldukça fazla önem taşımaktadır. CK-MB'yi yükselten MI dışındaki sebepler: Prostat veya uterus cerrahisi, ince bağırsak, dil, diyafram travması, ağır egzersiz, kardiyak cerrahi, miyokardit, kronik renal yetmezlik.

1.2.4.2 Troponinler

Troponin T ve troponin I testleri, yüksek hassasiyetleri, yatak başı hızlı uygulanabilme ve yorumlanabilme özellikleri ve neredeyse tüm dünyada yaygın kullanımı olması nedeniyle kararsız anjina ve NSTEMI tanı ve tedavi yönteminde oldukça yararlıdır. Kan serumunda tespit edilebilir konsantrasyona ulaşma zamanı yaklaşık 3-6 saattir. CK'nın aksine ilk saatlerde kullanımları sınırlıdır. Bunun yanı sıra sensitivite ve spesifiteleri yüksek olması nedeniyle günümüzde göğüs ağrısıyla bir kliniğe başvuran hastalara rutin bakılan ilk ve önemli enzimlerdendir.


1.2.4.3 Miyogloblin

Hasarlanan kas hücreleri hızla bu proteini salmaktadır ve tepe düzeyi 1-4 saatte meydana gelmektedir. MI'nin teşhis edilmesine yardımcı olmaktadır. Ancak kardiyak spesifitesi düşüktür, dolayısıyla klinikte kullanımı sınırlıdır. Miyogloblin 2-6 saatlik zaman aralığında ölçüldüğünde sonuç negatif ise MI'yi kolaylıkla dışlayabilmektedir.

1.2.4.4 Elektrokardiyografi(EKG)

EKG (elektrokardiyografi) yani kalbin elektriksel aktivitesi olup genellikle göğüs ağrısı şikâyeti ile gelen hastalarda kalp krizi tanısını koyabilme, düzenli veya düzensiz kalp ritim bozukluklarını (aritmiler) ortaya çıkarmada önemli bir rol oynayan ilk 12 parametredir. MI teşhisinde uygulanması basit ve kullanışlı olan tek yöntemdir. Bundan dolayı MI sınıflandırması EKG bulgularına göre yapılmaktadır. ST elevasyonlu (STEMI) ve Non ST elevasyonlu (NSTEMI) olmak üzere iki guruba ayrılırlar. Akut miyokard infarktüsü ve iskeminin teşhis edilmesinde erken dönemde

seri çekilen 12 derivasyonlu-EKG 'nin tanısal değeri yüksektir. MCPS'de (çok merkezli göğüs ağrısı çalışması) MI olgularının %2'sinde EKG normal bulunmuştur. MI teşhisi için iki veya daha fazla komşu derivasyonda ≥ 1 mm ST elevasyonu görülmesi gerekmektedir ve sıklıkla bunların karşı tarafındaki derivasyonlarda ise ST depresyonu görülmektedir.



Şekil 4. EKG dalga gösterimi

1.2.5 Kalp Damar Hastalıklarını Tetikleyen Faktörler

1.2.5.1 Obezite

Obezite gelişmiş ülkelerin ve gelişmekte olan ülkelerin giderek artan önemli bir sağlık problemidir. Fazla kilolu olma ve obezite her yıl yaklaşık 3,4 milyon ölüme sebep olmaktadır. Prospektif yapılan çalışmalar kilolu olma hali ve obezite ile kalp ve damar hastalıklarına bağlı morbidite ve mortalite arasında ilişki olduğunu göstermiştir. Obezitenin yüksek kan basıncı, glukoz intoleransı, tip 2 diyabet ve dislipidemi gibi kalp 13 ve damar hastalıkları risk faktörleri ile kuvvetli ilişkisi vardır. Koroner kalp hastalığı, iskemik inme, tip 2 diyabet riski artan beden kütle indeksi ile arttığı bilinmektedir.

1.2.5.2 Hipertansiyon

2010 yılında dünya genelinde yıllık 9,4 milyon ölüm ve hastalık yükünün yüzde 7'sinden HT sorumlu tutulmaktadır. Yüksek kan basıncı, koroner kalp hastalığı ve serebrovasküler (beyin damarları) hastalık için büyük risk faktörüdür. Kan basıncı seviyesinin, inme ve koroner kalp hastalığı ile anlamlı ve ilerleyici ilişkisi olduğu kabul edilmektedir. Aynı yaş grubunda 115/75 mmHg'dan itibaren kan basıncındaki her 20/10 mmHg'lık artış kalp ve damar hastalıkları riskini iki katına çıkarmaktadır. Koroner kalp hastalığı ve serebrovasküler hastalığa ek olarak yüksek kan basıncı kalp

yetmezliđi, renal yetmezlik, periferik damar hastalığı, retinal kan damarlarında bozulma ve görme kaybına yol açtığı bilinmektedir.

1.2.5.3 Diyabet

Diyabetli kişilerde ölümün yüzde 60'nın nedeni kalp ve damar hastalıklarıdır. Tip 1 veya tip 2 diyabetli kişilerde kalp ve damar hastalıkları görülme sıklığı 2-3 kat daha artmaktadır. Kadınlarda risk daha yüksektir. Diyabetli kişilerde kalp ve damar hastalıklarından sonra hastalığın ilerleme süreci diyabetli olmayanlara göre daha kötüdür. Kalp ve damar hastalıkları riski yüksek glukoz değerleri ile artar. Ayrıca anormal glukoz regülasyonu santral obezite, yüksek kan basıncı, düşük HDL kolesterol, yüksek trigliserid seviyeleri gibi bilinen kalp ve damar hastalıkları risk faktörleri ile birlikte olma eğiliminde olduğu düşünülmektedir.

1.2.5.4 Yüksek Kan Kolesterolü

Yüksek kan kolesterolü kalp krizi riskini artırır. Genel olarak iskemik kalp hastalıklarının 1/3'ü yüksek kolesterolle ilişkilidir. Yüksek serum kolesterolünü düşürmenin kalp hastalığı riskini azaltmasının yanı sıra yapılan çalışmalarda 40 yaşındaki bir erkekte kan kolesterolündeki yüzde 10'luk azalmanın 5 yıl içinde kalp hastalığı riskini yüzde 50 azalttığı tespit edilmiştir.

1.2.5.5 Cinsiyet

Kadınlarda kalp ve damar hastalıkları hakkında birçok yanlış bilinen kanı vardır. Kadınlar da erkekler kadar kalp ve damar hastalıklarına yakalanmaktadır. Kadınlarda 14 erkeklere göre kalp damar hastalığı 7-10 yıl daha geç gelişmektedir. Her yıl 3.3 milyon kadın kalp krizinden ölmektedir. MI sonrası ölüm oranı kadınlarda erkeklere göre daha yüksektir.

1.2.5.6 Yaş

Yaş güçlü bir kalp ve damar hastalıkları risk faktörüdür. Düşük ve orta gelir düzeyindeki ülkelerde artan kalp ve damar hastalıkları yükü nüfusun yaşlanması ile ilişkili olduğu düşünülmektedir.

1.2.5.7 Tütün Kullanımı

Tütün kullanımının kalp ve damar hastalıklarının %10'nuna neden olduğu tahmin edilmektedir. Yapılan çalışmalarla sigarayı bırakmanın koroner kalp hastalığına bağlı ölümleri azaltıcı etkisi gösterilmiştir.

1.2.5.8 Alkol Kullanımı

Alkol tüketimi ile kalp ve damar hastalıkları riski arasında ilişki olduğu bilinmektedir. Ayrıca alkol kullanımı kalp kasında hasara yol açabilme, kardiyak aritmiye sebep olma ve inme riskini artırma gibi durumlara sebep olabilir.

1.2.5.9 Aile Öyküsü

Eđer baba ya da erkek kardeş 55 yaşından önce; anne ya da kız kardeş 65 yaşından önce kalp krizi geçirmiş, koroner kalp hastalığı tanısı almış ya da aniden ölmüş ise

ailede kalp damar hastalığı öyküsü var demektir. Aile öyküsünün varlığı risk faktörlerinden biri olarak görülmektedir.

1.3 Yapay Sinir Ağları

Yapay Sinir Ağları(YSA) üzerinde yapılan çalışmalar beynin çalışma mantığı ile geleneksel bilgisayarın çalışma mantığının tamamen farklı olduğunun anlaşılmasıyla başlamıştır. Beyin, karmaşıklığı oldukça yüksek, doğrusal olmayan ve paralel yapıda çalışan bilgi işleme sistemidir. Nöron olarak bilinen yapısal bileşenlerini düzenleyerek belirli hesaplamaları günümüz bilgisayarlarından daha hızlı yapabilme yeteneğine sahiptir. YSA beynin bu çalışma prensibinin modellenmesi için tasarlanmış bir makinedir.

İnsanoğlu yaşamı boyunca edindiği tecrübeler neticesinde öğrenme kabiliyeti kazanmaktadır. Yaşanılan deneyimler ile sinir sistemindeki sinaptik bağlantılar sürekli gelişim ve değişim geçirir. İnsanlar ne kadar bilgi edinilirse edinsin sinir hücreleri arasındaki bağlantıları geliştirmişse düşünme, muhakeme etme ve akıl yürütme becerileri gelişmemektedir, bu yüzde de eğitilmiş sayılmamaktadırlar. Tıpkı insanlardaki gibi YSA'larda nöronları arasındaki bağlantı ağırlıklarını edindiği deneyimler ile ayarlanarak öğrenme gerçekleştirir. Bu sayede ağ eğitilmiş olur. Eğitilen ağ yeni veya daha önce hiç karşılaşmadığı örneklere, önceki tecrübelerine dayanarak mantıklı cevap vererek genellenme yapabilmektedir.

YSA'lar sinirbilim, matematik, istatistik, fizik, bilgisayar bilimleri ve mühendisliği gibi birçok farklı disipline ait problemlerin çözümünde kullanılmaktadır. YSA öğrenme kabiliyetine sahip olması nedeniyle sinyal işleme, desen tanıma, tahmin, zaman serisi analizi ve kontrolü gibi farklı uygulamalarda yer bulmuştur.

1.3.1 Biyolojik Sinir Ağları

Biyolojik sinir ağları beynin çalışmasına olanak sağlayan en temel yapı taşlarıdır ve insanların çevresindekileri anlamlandırıp algılamasını sağlar. Milyonlarca sinir hücresi bir araya gelerek bir sinir ağını oluştururlar. Bir sinir hücresi hücre gövdesi(soma), akson, dentrit ve sinapslardan oluşmaktadır. Sinir hücreleri arasındaki sinyal geçişleri, sinapslar tarafından sağlanmaktadır. Elektrik sinyalleri, hücre gövdesi ve dentrit'lere iletilir. Dentritler aldıkları bu sinyalleri sinaps'lara göndererek diğer sinir hücrelerine aktarılmasını sağlarlar.

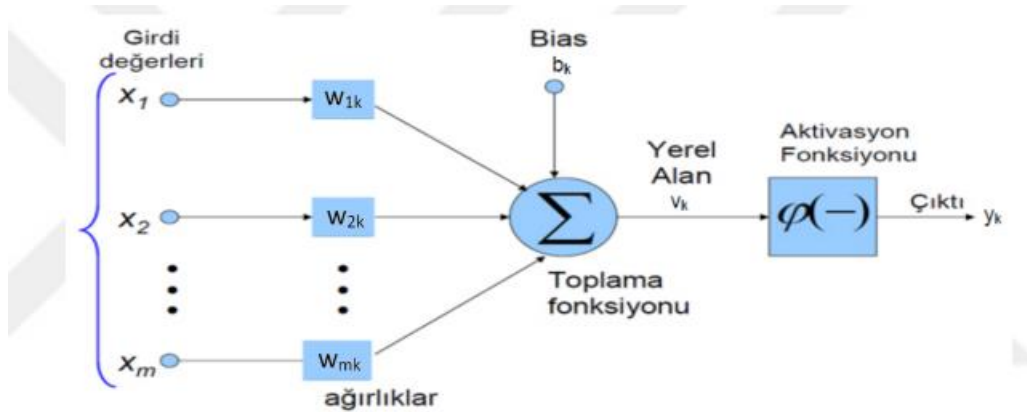
1.3.2 YSA' nın Tarihçesi

- 1943 yılında, matematikçi Walter Pitts ve nörofizyolog Warren McCulloch, nöronların nasıl çalışabileceği üzerine bir makale yayınlamışlardır. Beyindeki nöronların nasıl çalıştığını tanımlamak için insan beyninin çalışma tekniğinden esinlenip elektrik devreleri kullanarak bir sinir ağı oluşturmuşlardır.
- 1949'da Donald Hebb, "Organization of Behavior" adlı kitabında "Hebbian öğrenme" adlı temel teoriyi ele almıştır. Hebb kuralı sayesinde öğrenebilme ve uyum sağlayabilmenin sinir ağının bağlantı sayısı ile ilişkili olduğu saptanmıştır.

- 1951’de, ilk nöro bilgisayar üretilmiştir.
- 1954’te, IBM arařtırmacıları olan Farley ve Clark YSA’lar için simülasyon çalıřması yapmıřlar ancak modellerini çalıřtıramamıřlardır.
- 1958’de Frank Rosenblatt, perceptron modelini geliřtirmiřtir. Bu model iki katmanlı, basit ekleme ve çıkarma iřlemine kullanan bir desen tanıma algoritmasıdır. 13
- 1959 yılında Stanford’ta Bernard Widrow ve lisansüstü öđrencisi olan Marcian Hoff ”ADALINE” ve ”MADALINE” adlı modelleri geliřtirmiřlerdir. Ayrıca, en küçük kareler algoritması olarak bilinen bir öđrenme algoritması da geliřtirmiřlerdir.
- 1965 yılında Nilssons, ilk makine öđrenme kitabı olan “Öđrenen Makineler” isimli kitabı yazmıřtır. Bu kitapta yapay sinir ađı üzerine yapılan tüm çalıřmalar bir araya getirilmiřtir..
- 1969 ’da Minsky ve Papert yaptıkları incelemeler sonucunda Perceptron’un çok sınırlı alanda kullanılabileceđini, bir çok problemin çözümlünde yetersiz kaldıđını yayınladıkları ”Perceptrons” kitabıyla duyurmuřlardır. XOR probleminin çözümlünü yapamadıđını ispatlamıřlardır. XOR probleminin çözümlü için iki katmanlı ađların kullanılabilmesi düşünmüřler ancak ađlıklarının deđiřtirilmesi konusunda izleyebilecekleri bir yöntem önerememiřlerdir.
- 1970 yılında Fukushima, görüntü iřleme ve tanıma için Neocognitron modeli tanıtmıřtır.
- 1972’de Kohonen ve Anderson, birbirinden bađımsız bir řekilde “çađrıřımlı bellek” konusu üzerinde benzer bir ađ geliřtirmiřlerdir.
- 1982 yılına gelindiđinde Kohonen, ”Kendi kendine Öđrenme Nitelik Haritaları (Self Organizing Feature Maps SOM)” isimli çalıřma yayınlamıřtır.
- 1982-1984 yılları arasında Hopfield, ađların matematiksel modellerini ortaya koymuřtur. Yayınladıđı çalıřmalar ile YSA’ların genelleřtirilebilme yeteneđinin varlıđını ve çözümlü olduđu zor problemler için çözümlü üretebildiklerini kanıtlamıřtır. Bunun en büyük kanıtı ise gezgin satıcı probleminin çözümlüsidir.
- 1984 yılında Kohonen, danıřmansız öđrenme stratejisini geliřtirmiřtir.
- 1986 yılında Rumelhart ve McClelland, ÇKA(Çok Katmanlı Algılayıcı)’lar için geriye yayılım öđrenme algoritmasını geliřtirmiřlerdir. Bu algoritma 14 günümüzde olduđu yaygın bir řekilde kullanılmaktadır.
- 1987’de, Amerikan Elektrik Elektronik Mühendisliđi Enstitüsü tarafından uluslar arası ilk YSA konferansı 1800 den fazla katılımcı ile gerçekleřtirilmiřtir.

1.3.3 Yapay Sinir Hücresinin Yapısı

YSA insan beyninin kaba bir modeline dayanmaktadır. Nöron, bir YSA’da temel olan bilgi işleme birimidir. Nöronlar birbirlerine paralel yapıda ayarlamalı ağırlıklarla bağlanmaktadır.



Şekil 5. Doğrusal olmayan nöron modeli.

Şekil 5’teki blok diyagram bir nöron modelini göstermektedir. Nöron modelinin beş temel elemanı vardır:

1. Girdiler: Dış dünyadan yapay sinir hücresine iletilen bilgilere denir. Bilgiler dış sistemden gelen veriler olabileceği gibi başka yapay sinir ağı hücrelerinin çıktı değeri de olabilir. Bazen işlem elemanları geri besleme yöntemi ile kendileri de girdi oluşturabilir.
2. Ağırlıklar: Bir sinir hücresine genellikle bir çok girdi verisi ulaşır. Her girdinin kendi bağlı ağırlık değeri vardır. Her bir ağırlığın farklı sabit değeri vardır. Ağırlıkların başlangıç değerleri genellikle rastgele seçilmekte ve pozitif veya negatif değer alabilmektedir. Hücreye gelen bilginin etki ve önem derecesi ağırlıklar ile belirlenir. Bu sayede bazı girdi değerleri diğerlerinden daha önemli olabilir ve böylece sinir hücresi üzerinde daha fazla etkili olabilir. Ağırlığın topolojik yapısına veya öğrenme algoritmasına göre ağırlıkların değiştirilmesi yöntemleri farklılık göstermektedir.
3. Toplama Fonksiyonu: Bir hücreye gelen net girdiyi hesaplayan fonksiyondur. En yaygın kullanılan toplam fonksiyonu girdilerin ilgili ağırlıkları ile çarpılıp toplandığı ağırlıklı toplam fonksiyonudur ve 5’deki gibi formülüne edilir.

$$net_k = \sum_{i=1}^n w_i x_i$$

Şekil 6. Ağırlıklı toplam fonksiyonu

Hangi problemlere hangi toplama fonksiyonunun kullanılacağına dair bir formül yoktur. Tüm işlem elemanları aynı toplama fonksiyonunu kullanabilecekleri gibi her bir işlem elemanları bağımsız olarak farklı bir toplama fonksiyonunu da kullanabilmektedir.


4. Aktivasyon Fonksiyonu: Her bir işlem elemanına gelen net girdinin işlenip girdiye karşılık gele çıktı değerinin üretilmesini sağlayan fonksiyondur. Aktivasyon fonksiyonları ağı kullanıldığı probleme, ağın topolojisine veya kullanılan öğrenme algoritmasına uygulanacak ağlar için, aktivasyon fonksiyonu türevlenebilir bir fonksiyon olmalıdır.

Nöron modelin doğrusal olmama özelliği, doğrusal olmayan aktivasyon fonksiyonunun kullanılması ile ilişkilidir. Bu sayede girdi ve çıktı değerleri arasında daha kuvvetli nonlinear (doğrusal olmayan) ilişki kurulmuş olur.

Doğrusal olmayan fonksiyonlar hem pozitif hem de negatif değerler üretmektedirler ve sadece pozitif veya negatif değerler üretmektedirler ve sadece pozitif veya negatif değer üreten fonksiyonlara kıyasla ağı daha hızlı öğrenmesini sağlamaktadırlar. Yapay nöronlarda doğrusal olmayan aktivasyon fonksiyonu kullanılmazsa temsil edilen sistem doğrusal özellik gösterecektir. Bu tip yapay nöronlar doğrusal olmayan sistemlerde kullanılamazlar. Doğrusal aktivasyon fonksiyonu kullanılan sinir modeli, Widrow- Hoff modeli olarak ta bilinmektedir.

Bazı aktivasyon fonksiyonu türleri şunlardır.

- Doğrusal Fonksiyon : Doğrusal fonksiyon, doğrusal problemlerin çözümünde aktivasyon fonksiyonu olarak seçilebilir. Denklem 7’de gösterildiği gibi doğrusal fonksiyonun çıktısı girdisine eşittir. Şekil 6 doğrusal fonksiyonu ve türevini göstermektedir.




Şekil 7. Doğrusal fonksiyon

Doğrusal fonksiyonun denklemi:

$$f(net) = net$$

Şekil 8. Girdisi Çıktısına eşit doğrusal fonksiyon denklem.

- Sigmoid Fonksiyonu : Türevlenebilir, sürekli ve doğrusal olmayan bir fonksiyondur. Bu sebeplerden dolayı, en çok tercih edilen aktivasyon fonksiyonudur. Bu fonksiyon her girdi değerine karşılık [0,1] aralığında bir değer vermektedir. Şekil 8’de fonksiyon ve türevi gösterilmiştir.




Şekil 9. Sigmoid Fonksiyonu

Sigmoid fonksiyonunun denklemi :

$$f(net) = \frac{1}{1 + e^{-net}}$$

Şekil 10. Sigmoid fonksiyonun denklemi

- Hiperbolik Tanjant Fonksiyonu : Sigmoid fonksiyonunun farklı bir biçimidir. Bu fonksiyonda üretilen çıktı -1 ile +1 değerleri arasında bir değere karşılık gelir. Fonksiyonun türevi ve kendisi Şekil 11'd e gösterilmiştir.



Şekil 11. Hiperbolik tanjant fonksiyonu

Hiperbolik Tanjant Fonksiyonunun denklemi;

$$f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}}$$

Şekil 12. Hiperbolik tanjant fonksiyonunun denklemi

5. Hücre çıktısı : Aktivasyon fonksiyonun ürettiği sonuç hücre çıktısı olarak kabul edilir. Bu çıktı hücrenin ağıdaki konumuna göre bağlı olduğu diğer hücrelere girdi olarak iletilir veya ağı ürettiği sonuç olarak değerlendirilir.

Bir yapay sinir hücresinin çalışmasını özetleyecek olursak;

Şekil 6'de gösterilen model dışardan ayrıca bir girdiye sahiptir. Aktivasyon fonksiyonunun net girdi değeri b_k ile gösterilen sapma (bias) değeri pozitif olduğunda yükselmekte, negatif olduğunda ise düşmektedir.

Aşağıdaki iki eşitlik k nöronunun matematiksel ifadesidir.

$$u_k = \sum_{j=1}^m w_{jk} x_j$$

Şekil 13. Girdi işaretlerinden gelen ağırlıklı toplam değer denklemini

$$y_k = \phi(v_k)$$

Şekil 14. Nöronun çıktısının denklemini

Burada x_1, x_2, \dots, x_m girdi işaretlerini, $w_{1k}, w_{2k}, \dots, w_{mk}$, k nöronunun sinaptik ağırlıklarını, u_k girdi işaretlerinden gelen ağırlıklı toplam değerini, b_k bias (sapma) terimini, $\phi(\cdot)$ aktivasyon fonksiyonunu ve u_k nöronun çıktısını belirtir. 11'de görülen v_k , aktivasyon fonksiyonunun net girdisidir. Bias kullanılması halinde $u_k = u_k + b_k$, kullanılmadığında ise $u_k = u_k$ olarak hesaplanır.

1.3.4 YSA'nın Özellikleri

YSA'nın paralel dağıtılmış yapısı ve genelleme yeteneği sayesinde hesaplama ve bilgi işleme yeteneği oldukça gelişmiştir. Genelleme, ağı öğrenme esnasında hiç karşılaşmadığı örneklere uygun çıktılar üretebilmek olarak tanımlanabilir. YSA bu üstün özellikleri ile karmaşık problemlerin çözebilmesini mümkün kılmaktadır.

YSA'nın başlıca özellikleri şöyle sıralanabilir.

1. Doğrusal Olmama: YSA'ların en küçük işlem elemanı olan hücre doğrusal bir yapıya sahip değildir. Bu nedenle bu hücrelerin birleşiminden oluşan YSA'lar da doğrusal değildir ve bu özellik tüm ağı yayılmıştır. YSA'nın bu özelliğinin karmaşık ve doğrusal olmayan problemlere çözüm üretmesindeki önemi büyüktür.
2. Öğrenme: Öğrenme ile kastedilen ilgili problemin girdi-çıkıtı ilişkisini en iyi verebilecek optimum ağırlık değerlerine ulaşılmasıdır. Karmaşık yapısı nedeniyle bağlantı ve ağırlık değerleri önceden ayarlanmış bir şekilde YSA'lara verilememektedir. Bu nedenle YSA, üzerinde çalıştığı problemde aldığı eğitim verilerini kullanarak istenilen davranışı gösterecek şekilde problemi öğrenmelidir.
3. Genelleme: Güçlü paralel dağıtım yapısı ve öğrenme yeteneği sayesinde sinir ağı, öğrenme sürecine katılmayan girdiler için makul çıktılar üretebilir. Kusurlu veya

eksik verileri işleyebilir ve hataya dayanıklı olma potansiyeline sahiptir. Pratik gürültülü verileri analiz ederken bu çok yararlıdır.

4. Adaptasyon: YSA üzerinde çalışılan sorunun değişimlerine göre ağırlık değerlerini günceller. Belirli bir çevrede çalışmak üzere eğitilmiş olan YSA çalışma ortamı koşullarında olabilecek küçük değişikliklere karşı tekrar eğitim alabilir. Eğer değişiklikler sürekli ise eğitim gerçek zamanlı olarak devam edebilir. Uyarlama özelliği nedeniyle YSA sinyal işleme, örnek tanıma ve denetim gibi alanlarda etkin bir şekilde kullanılır.

5. Hata toleransı: YSA'lar çeşitli şekillerde bağlanmış çok sayıda hücreden oluştuğundan, paralel dağılmış yapıya sahiptir ve ağda bulunan bilgi tek bir yerde toplanmak yerine ağdaki tüm bağlantılara dağılmış durumdadır. Dolayısıyla eğitimi tamamlanmış bir YSA'nın bağlantılarının bazılarında hatta bazı hücrelerinde hasar oluşması, ağın doğru çıktıyı üretmesini büyük ölçüde etkilemeyecektir. Bilginin tek bir yerde saklanmaktan ziyade tüm sisteme dağılmış olması YSA'nın hatayı tolere etme becerisinin, geleneksel yöntemler ile karşılaştırıldığında daha yüksek olduğunu göstermektedir.

6. Paralel İşlem Yapma: YSA paralel yapısı sayesinde büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik YSA'nın bilgi işleme yeteneğini hızlandırır ve işaret işleme, örnek tanıma, denetim, sistem kimliklendirme gibi gerçek zamanlı uygulamalar tarafından tercih edilir.

7. Analiz ve Tasarım Kolaylığı: YSA modeli ve işleme elemanının yapısı tüm problemler için neredeyse aynıdır. YSA'nın bu standart yapısı farklı uygulama alanlarında kullanılacaktır. Bu nedenle farklı uygulama alanlarında kullanılan YSA'lar benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bütün 20 YSA uygulamalarında hep aynı gösterimin kullanılması problemlerin YSA ile çözümünde önemli bir kolaylık getirmektedir.

1.3.5 Ağ Yapıları


1.3.5.1 İleri Beslemeli Sinir Ağları(Feedforward Neural Network)

İleri beslemeli YSA, akış yönünün sadece girişten çıkışa doğru tek yönlü olduğu ağlardır. Bu YSA modelinde bir katmana ancak önceki katmandan giriş olabilir. Yani bir nöronun çıktısı bir sonraki nöronun girdisi olarak kullanılabilir. YSA işlem elemanlarının oluşturduğu her bir gruba katman adı verilir. İşlem elemanları birbirlerine bağlanıp katmanları, bu katmanlar da ağ yapısını oluşturur. İleri beslemeli YSA tek ve çok katmanlı olmak üzere ikiye ayrılır.

1.3.5.2 Tek Katmanlı İleri Beslemeli Ağlar

En basit ağ yapısı olarak bilinirler. Tek bir girdi katmanı vardır ve bu da doğrudan çıktı katmanına bağlıdır. Çıktı katmanında bulunan her bir nöron, girdi katmanında bulunan tüm nöronlarla bağlantılıdır. Girdi katmanında hiçbir hesaplama yapılmadığı için sadece çıktı katmanı hesaba katılarak bu türdeki ağlara tek katmanlı ağ denir.


Şekil 15' de tek katmanlı ileri beslemeli ağ yapısı görülmektedir.



Şekil 15. Tek katmanlı ileri beslemeli ağ yapısı.

1.3.5.3 Çok Katmanlı İleri Beslemeli Ağlar


Bir önceki modelden farklı olarak bu tür ağlarda bir veya birden fazla gizli katman bulunur. Sinir ağı katmanlar halinde düzenlenir; ilk katman girdileri alır, son katman çıktılarının üretildiği katmandır. Orta katmanların dış dünyayla hiçbir bağlantısı yoktur ve gizli katmanlar denir. Bir katmandaki her bir nöronun hiçbir bağlantısı yoktur ve gizli katmanlar denir. Bir katmandaki her bir nöronun bir sonraki katmandaki her nörona bağlandığı ağlara tümüyle bağlı ağ, bazı nöronlar arası bağlantıların eksik olduğu ağlara ise kısmen bağlı ağ denilmektedir. Çok katmanlı ileri beslemeli ve tümüyle bağlı ağ şekil 16’ de gösterilmiştir.



Şekil 16. Çok katmanlı ileri beslemeli sinir ağı

1.3.5.4 Geri Dönüşümlü Sinir Ağları(Recurrent Neural Networks)

Bu tür ağları ileri beslemeli ağlardan ayıran özellik, en az bir tane geri besleme döngüsüne sahip olmasıdır. Örneğin bir geri dönüşümlü ağ tek bir katmandan oluşabilir ve bu katmandaki her sinir hücresinin çıktısı diğer hücelere girdi olarak aktarılabilir. Bir sinir hücresi kendi çıktısını yine kendisine girdi olarak gönderebilir. Geri besleme döngülerinin olması ağın öğrenme yeteneklerini artırır ve daha performanslı çalışmasını sağlar. Şekil 13’ de örnek bir geri dönüşümlü ağ gösterilmiştir.



Şekil 17. Geri dönüşümlü sinir ağı

1.3.6 Öğrenme Stratejileri

Bir sinir ağı için birincil önemli olan özellik çevresinden öğrenmek ve öğrenme yoluyla performansını geliştirmektir. Genel olarak öğrenme deneyimle ortaya çıkan davranış değişiklikleridir. Sinir ağında öğrenme ağın problem için en doğru çıktıları üretmesini sağlayacak ağırlık değerlerinin bulunması olarak tanımlanabilir. YSA' da öğrenmeyi gerçekleştirecek sistem ve kullanılacak öğrenme algoritmasına göre genel olarak üç öğrenme stratejisi kullanılmaktadır. Bunlar, danışmanlı, danışmansız ve takviyeli öğrenmedir.

1.3.6.1 Danışmanlı Öğrenme (Supervised Learning)

Danışmanlı öğrenmede YSA' ya gerçek çıktı değerleri verilir. Ağın çıktısı ve gerçek çıktı arasındaki fark hata olarak ele alınır. Elde edilen hata değerine göre nöronlar arası bağlantı ağırlıkları düzenlenerek en uygun çıktıyı elde etmek amaçlanmaktadır.

1.3.6.2 Danışmansız Öğrenme

Ağa sadece giriş bilgileri verildiği öğrenme stratejisidir. Ulaşılacak istenen hedef çıktılar ağa tanıtılmaz. Sistemin kendisine sunulan girdilerden elde edilen çıktı bilgisine göre ağın kuralları kendisine öğrenmesi beklenir. Genellikle sınıflandırma problemlerinde kullanılan öğrenme stratejisidir. Sistemin öğrenme işlemi tamamlandıktan sonra YSA çıktıları belli parametrelere göre sınıflandırılmıştır, ancak bu sınıfların ne anlama geldiğini bilmemektedir. Hangi kategorinin neyi gösterdiği kullanıcı tarafından belirlenmelidir. Bu işleme etiketlendirme ismi verilmektedir.

1.3.6.3 Tavsiyeli Öğrenme(Reinforcement Learning)

Takviyeli öğrenme algoritmasında istenilen çıktının bilinmesine gerek yoktur. Hedeflenen çıktı ağa verilmez fakat elde edilen çıktının girdiye göre iyiliğini değerlendiren bir kriter kullanılmaktadır.

1.3.6.4 Öğrenme Kuralları

YSA gibi sistemlerde öğrenme işlemi bazı kurallara göre gerçekleşmektedir. Bu kuralların bir kısmı (on-line) çalışırken, bir kısmı ise çevrimdışı (off-line) çalışmaktadır.

1.3.6.5 Çevrimiçi (On-line) Öğrenme

On-line diğer bir deyişle gerçek zamanlı öğrenmede sistemde bir öğrenme algoritması bulunmakta olup, bu yapıyla uyumlu yazılım ve donanım mevcuttur. Bu ağ çalışma modunda öğrenme süreklidir. Bu tip öğrenme daha karmaşık yapıların tasarımı için kullanılır ve maliyetleri yüksektir. Art ağının öğrenme kuralı ile Kohenen öğrenme kuralı çevrimiçi öğrenme gerçekleştirmektedirler.

1.3.6.6 Çevrimdışı (off-line) Öğrenme

Çoğunlukla ağlarda off-line öğrenme kullanılmaktadır. Bu yaklaşımda ilk olarak ağ eğitilir. Eğitim tamamlandıktan sonra elde edilen ağırlıklar on-line uygulamalarda kullanılabilir. Bu aşamada hiç bir öğrenme algoritması kullanılmaz sadece mevcut ağ 27 parametreleri kullanılarak ileri yönde bir hesaplama yapılarak çıktı hesaplanır.

1.3.7 Yapay Sinir Ağı Modelleri Ve Öğrenme Algoritmaları

1.3.7.1 Tek Katmanlı Algılayıcılar

Tek katmanlı algılayıcılarda bir girdi ve bir de çıktı katmanı bulunmaktadır. Katmanlarda bir veya daha fazla nöron yer alabilmektedir. $X = [x_1, x_2, \dots, x_n]$ girdi katmanındaki n tane girdinin vektörünü. $Y = [y_1, y_2, \dots, y_k]$ çıktı katmanındaki k tane nöronun çıktı vektörünü göstermektedir. $w = [w_{1n}, w_{2n}, \dots, w_{nk}]$ ise girdi katmanı ile çıktı katmanı arasındaki bağlantıların vektörünü göstermektedir. Burada w_{ij} ile ifade edilen girdi katmanındaki i . node ile çıktı katmanındaki j . node arasındaki bağlantının ağırlığıdır.

Çıktı katmanındaki her bir nöronun çıktısı kendine gelen tüm girdi değerleri ve eşik değerinin ağırlığının toplanarak bu toplam üzerine kendi aktivasyon fonksiyonunun uygulaması sonucu elde edilir.

1.3.7.2 Basit Algılayıcı (Perceptron) Modeli

Frank Rosenblatt, “zeki sistemlerin temel özelliklerinden bazılarını simüle etmek” için Perceptronu geliştirmiştir. Perceptron modelinde çıktı katmanında bulunan bir nöron birden fazla girdi değerini alarak çıktı üretmektedir. Ağın ürettiği çıktı oluşturulurken, girdi değerleri kendi ağırlıkları ile çarpılıp toplanır ve bu toplamdan elde edilen sonuç eşik değer ile karşılaştırılarak ağın çıktısı belirlenir. Elde edilen toplam değer eşik değerden büyük veya eşit ise ağın çıktısı 1, küçük ise 0 seçilmektedir. Rosenblatt desen tanıma problemleri için de öğrenme kuralı geliştirmiştir Rosenblatt (1958). Çalışmasında kuralın çözümü verecek olan doğru ağırlık değerlerine yakınsayacağını kanıtlamıştır. Rosenblatt ayrıca, dijital bilgisayarlarda yapay sinir ağlarının simülasyonunu gerçekleştirmiştir Rosenblatt 30 (1961). Yaptıkları detaylı matematiksel incelemeler sonucunda Marvin Minsky ve Seymour Papert algılayıcıların belli alanlarda kullanılabileceğini ve çözemeyeceği çok fazla problem sınıfının

bulduğunu yayınlamış oldukları "Perceptrons" adlı kitapları ile kamuya göstermişlerdir Minsky ve Papert (1969). XOR problemi algılayıcılar tarafından çözülemeyecek örneklerden birisidir. Bu sorun 1980'lerde ÇKA'nın geliştirilmesi ile giderilmiştir.

1.3.7.3 Adaline Modeli

Frank Rosenblatt'ın Perceptronu geliştirdiği esnada YSA üzerine çalışmaya başlayan Bernard Widrow ve lisansüstü öğrencisi Marcian Hoff 1960 yılında ADALINE ağı ile En Küçük Kareler (EKK) algoritması olarak bilinen öğrenme kuralını geliştirdiler. Adaline ağının algılayıcılardan farkı aktivasyon fonksiyonu olarak eşik fonksiyonu yerine doğrusal fonksiyon kullanmasıdır. Her iki model de yalnızca doğrusal olarak ayrılabilen problemlere çözüm üretebilmektedir.

EKK algoritması gürültüye duyarlı olan Perceptron'dan daha güçlüdür. Ortalama karesel hatayı minimize eden EKK algoritmasının Perceptrona göre gürültüye duyarlılığı daha azdır. EKK algoritması kendisine Perceptrondan çok daha pratik kullanımlar bulmuştur. Özellikle dijital sinyal işleme alanında sıklıkla kullanılmıştır.

1.3.7.4 Çok Katmanlı Algılayıcılar

ÇKA modelinde bir girdi, bir veya birden fazla gizli katman ve bir adet te çıktı katmanı bulunmaktadır. Çok katmanlı bir sinir ağındaki her katman kendi özel işlevine sahiptir. Girdi katmanı dış dünyadan gelen sinyalleri alır ve bunlar üzerinde hiç bir işlem yapmadan bir sonraki gizli katmandaki tüm nöronlara yeniden dağıtır. Gizli katmandaki nöronlar özellikleri tespit eder, nöronların ağırlığı girdi kalıplarında gizli olan özellikleri temsil eder. Çıktı katmanı gizli katmanın çıkış sinyallerini işleyip tüm ağın çıktılarını belirler.

Gizli katmanlar kendi çıktısını gizler. Gizli katmandaki nöronlar, ağı giriş / çıkış davranışıyla gözlenemez. Gizli katmanın istenen çıktısının ne olması gerektiğinin kesin bir yolu yoktur. Başka bir deyişle gizli katmanın istenen çıktısı katmanın kendisi tarafından belirlenir. Ticari YSA'lar üç ve bazen de dört katman içerir, bunlardan biri ya da ikisi gizli katmandır. Her katman 10 ila 1000 nöron içerebilir. Deneysel sinir ağları beş ya da altı katmana sahip olabilir, bunlar üç ya da dört gizli katmandan oluşur ve milyonlarca nöron kullanır.

ÇKA'lar için yüzden fazla farklı öğrenme algoritması mevcuttur ancak en yaygın yöntem geri yayılımdır.

Tek katmanlı algılayıcılarda her girdi için yalnızca bir ağırlık ve bir çıktı değeri bulunur. Ancak çok katmanlı algılayıcılarda çok fazla ağırlık vardır ve her biri birden fazla çıktıya katkıda bulunur.

1.3.7.5 Geri Yayılım (Backpropagation) Algoritması

Geri yayılım algoritması, yapay sinir ağlarında(YSA) çok katmanlı perceptronları eğitmek için kullanılan bir algoritmadır. Algoritma, sinir ağının ağırlıklarını ve

önyargılarını iteratif olarak ayarlayarak, ağı tahmin ettiği değerler ile gerçek değerler arasındaki hatayı en aza indirmeyi amaçlar.

1.3.8 Yapay Sinir Ağlarında Geri Yayılım Algoritması

Geri yayılım algoritması, yapay sinir ağlarında (YSA) çok katmanlı perceptronları eğitmek için kullanılan bir algoritmadır. Algoritma, sinir ağının ağırlıklarını ve önyargılarını iteratif olarak ayarlayarak, ağı tahmin ettiği değerler ile gerçek değerler arasındaki hatayı en aza indirmeyi amaçlar. Geri yayılım algoritması ileri yayılım ve geri yayılım olmak üzere iki aşamadan oluşmaktadır.

1.3.8.1 İleri Yayılım

Bu aşamada, girdi verileri sinir ağının katmanları boyunca ilerler ve her katmandaki nöronlar, aktivasyon fonksiyonları aracılığıyla bir çıktı üretir. Bu işlem, son katmana kadar devam eder ve son katmandaki nöronlar, problemin tahmini değerini üretir.

1.3.8.2 Geri Yayılım

Bu aşamada, ileri yayılım sırasında üretilen hata değeri, sinir ağı üzerinde çıktı katmanından girdi katmanına doğru geriye doğru yayılır. Bu işlem sırasında, her katmandaki nöronların ağırlık ve önyargılarında, hatayı en aza indirecek şekilde bir güncelleme yapılır.

Bölüm 2

2.1 Verilerin İncelenmesi

Proje çalışmasında kullanılmak üzere Python programlama dili kullanılmıştır. Projede pandas ,numpy ve tensorflow kütüphanesi kullanılmıştır. Proje yapay sinir ağı kullanarak eğitilmiştir. İleri beslemeli sinir ağı kullanılmıştır. Bir tane girdi katmanı iki tane ara katman ve 1 tane çıktı katmanı vardır. Girdi katmanında 13 nöron ara katmanlarda 13' er nöron be çıktı katmanında 1 nöron vardı. Activation fonksiyonu olarak ilk üç katmanda relu son katmanda ise sigmoid kullanılmıştır. Sigmoid fonksiyonu S harfine benzer ve girdi değerindeki küçük değişiklikler çıktı değerinde gözlemlenebilir.

In [24]: dataframe

Out[24]:

	yas	cinsiyet	gogus_agri_tipi	dinlenme_kan_basinci	Kolesterol	Acilik_Kan_Sekeri	Elektrokardiyografik_Ölçümü	Ulasilan_maks_kalp_hizi	egzersize_bagli_di
0	63	1	3	145	233	1	0	150	
1	37	1	2	130	250	0	1	187	
2	41	0	1	130	204	0	0	172	
3	56	1	1	120	236	0	1	178	
4	57	0	0	120	354	0	1	163	
...	
298	57	0	0	140	241	0	1	123	
299	45	1	3	110	264	0	1	132	
300	68	1	0	144	193	1	1	141	
301	57	1	0	130	131	0	1	115	
302	57	0	1	130	236	0	0	174	

303 rows x 14 columns

Şekil 18. Veri setindeki datalar.

In [24]: dataframe

Out[24]:

in_basinci	Kolesterol	Acilik_Kan_Sekeri	Elektrokardiyografik_Ölçümü	Ulasilan_maks_kalp_hizi	egzersize_bagli_durumu	depresyon_ST	egjim	ca	talasemi	amac
145	233	1	0	150	0	2.3	0	0	1	1
130	250	0	1	187	0	3.5	0	0	2	1
130	204	0	0	172	0	1.4	2	0	2	1
120	236	0	1	178	0	0.8	2	0	2	1
120	354	0	1	163	1	0.6	2	0	2	1
...
140	241	0	1	123	1	0.2	1	0	3	0
110	264	0	1	132	0	1.2	1	0	3	0
144	193	1	1	141	0	3.4	1	2	3	0
130	131	0	1	115	1	1.2	1	1	3	0
130	236	0	0	174	0	0.0	1	1	2	0

Şekil 19. Veri setindeki datalar.

Şekil 19 de görüldüğü üzere kalp krizi geçirme riski olanlar amaç kısmında 1 ile olmayanlar ise 0 ile gösterilmiştir.

```
In [25]: dataframe.isnull().sum()
Out[25]: yas                0
cinsiyet                0
gogus_agrı_tipi        0
dinlenme_kan_basıncı   0
Kolesterol              0
Aclık_Kan_Sekeri       0
Elektrokardiyografik_Ölçümü 0
Ulasılan_maks_kalp_hızı 0
egzersize_bağlı_durumu 0
depresyon_ST           0
egim                   0
ca                     0
talasemi               0
amac                   0
dtype: int64
```

Şekil 20. Boş veri ile ilgili datalar.

Şekil 20 de boş veri olup olmadığı incelendi ve boş veri olmadığı bulundu.

```
In [26]: dataframe.describe()
Out[26]:
```

	yas	cinsiyet	gogus_agrı_tipi	dinlenme_kan_basıncı	Kolesterol	Aclık_Kan_Sekeri	Elektrokardiyografik_Ölçümü	Ulasılan_maks_kalp_hızı	egze
count	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000
mean	54.366337	0.683168	0.966997	131.623762	246.264026	0.148515	0.528053	149.646865	
std	9.082101	0.466011	1.032052	17.538143	51.830751	0.356198	0.525860	22.905161	
min	29.000000	0.000000	0.000000	94.000000	126.000000	0.000000	0.000000	71.000000	
25%	47.500000	0.000000	0.000000	120.000000	211.000000	0.000000	0.000000	133.500000	
50%	55.000000	1.000000	1.000000	130.000000	240.000000	0.000000	1.000000	153.000000	
75%	61.000000	1.000000	2.000000	140.000000	274.500000	0.000000	1.000000	166.000000	
max	77.000000	1.000000	3.000000	200.000000	564.000000	1.000000	2.000000	202.000000	

Şekli 21. Verilerin miktarı, ortalaması, standart sapması verilerine ait bilgiler.

```
In [26]: dataframe.describe()
Out[26]:
```

	Aclık_Kan_Sekeri	Elektrokardiyografik_Ölçümü	Ulasılan_maks_kalp_hızı	egzersize_bağlı_durumu	depresyon_ST	egim	ca	talasemi	amac
count	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000	303.000000
mean	0.148515	0.528053	149.646865	0.326733	1.039604	1.399340	0.729373	2.313531	0.544554
std	0.356198	0.525860	22.905161	0.469794	1.161075	0.616226	1.022606	0.612277	0.498835
min	0.000000	0.000000	71.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
25%	0.000000	0.000000	133.500000	0.000000	0.000000	1.000000	0.000000	2.000000	0.000000
50%	0.000000	1.000000	153.000000	0.000000	0.800000	1.000000	0.000000	2.000000	1.000000
75%	0.000000	1.000000	166.000000	1.000000	1.600000	2.000000	1.000000	3.000000	1.000000
max	1.000000	2.000000	202.000000	1.000000	6.200000	2.000000	4.000000	3.000000	1.000000

Şekil 22. Verilerin miktarı, ortalaması, standart sapması verilerine ait bilgiler.

Şekil 21 ve şekil 22 de yaş, cinsiyet, kolesterol gibi çeşitli verilerin standart sapması, ortalaması veri miktarı, max, min gibi değerler hesaplanmıştır. Yaş, dinlenme kan basıncı, kolesterol, ulaşılan maksimum kalp hızı gibi değerlerin standart sapması en fazladır.

```
In [27]: dataframe.corr()["amac"].sort_values()
```


```
Out[27]: egzersize_bagli_durumu    -0.436757
depresyon_ST                    -0.430696
ca                               -0.391724
talasemi                        -0.344029
cinsiyet                        -0.280937
yas                             -0.225439
dinlenme_kan_basinci           -0.144931
Kolesterol                      -0.085239
Acilik_Kan_Sekeri              -0.028046
Elektrokardiyografik_Ölcümü    0.137230
egim                            0.345877
Ulasilan_maks_kalp_hizi        0.421741
gogus_agri_tipi                0.433798
amac                           1.000000
Name: amac, dtype: float64
```

Şekil 23. Verilerin corelasyon değerine ait veriler.

Şekil 23 te corelasyon değerlerine bakılmıştır. Sonucu neyin pozitif neyin negatif etkilediği incelenmiştir. Pozitif sayılar sonucu pozitif negatif olanlar ise negatif yönde sonucu etkilemiştir.

```
In [28]: dataframe.corr()["amac"].sort_values().plot(kind="bar")
```


```
Out[28]: <AxesSubplot: >
```



Şekil 24. Corelasyon grafiği

```
In [30]: sbn.countplot(x= "amac", data = dataframe)
```


```
Out[30]: <AxesSubplot: xlabel='amac', ylabel='count'>
```



Şekil 25 te hasta ve sağlıklı hasta sayısı. Sağlıklı olanlar 1 hasta olanlar 0 ile gösterilmiştir.

```
In [43]: modelkaybi.plot()
```

```
Out[43]: <AxesSubplot: >
```



Şekil 26. Model kayıp değeri grafiği

Şekil 26 de model kayıp değeri gösterilmektedir. Amaç loss ve val_loss fonksiyonlarının birbirine yakın değerler almasını sağlamaktır. Şekilde görüldüğü üzere loss ve val_loss birbirine yakın değerler almıştır.

```
In [49]: print(classification_report(y_test, tahmin))
```

	precision	recall	f1-score	support
0	0.94	0.74	0.83	43
1	0.83	0.96	0.89	57
accuracy			0.87	100
macro avg	0.89	0.85	0.86	100
weighted avg	0.88	0.87	0.87	100

Şekil 27. Modelin doğruluğu ile ilgili veriler.

Şekil 27'e baktığımızda hasta kişiler %94 oranında doğru tahmin edilmiş sağlıklı kişilerse %83 oranında doğru tahmin edilmiştir. Yapılan çalışmada doğruluk oranı yüksektir.

Bölüm 3

2.3. Sonuç

Günümüzde yapay zeka teknolojisi büyük ilerleme göstermiştir ve bu ilerleme sayesinde birçok alanda yapılacak işlere kolaylık sağlamıştır. Tıpta teşhis ve tedavi konusunda da yapay zeka büyük katkı sağlamıştır. Bu çalışmada yapay sinir ağları kullanarak kalp krizi tahmini yapılmaya çalışılmıştır. Kalp krizi tahmini için hastanın cinsiyet, yaş, kolesterol, kan basıncı, açlık kan basıncı gibi verilerden faydalanılmıştır. Model hasta kişileri % 94 duyarlılıkla hasta olmayan kişileri ise % 84 duyarlılıkla tahmin etmiştir. Modelin kayıp değer grafiğinde lost değeri ve validasyon lost değeri birbirine yakın değer almıştır. Sonuçta model başarılı bir performans göstermiştir. Yapay sinir ağları insan nöron yapısını taklit etmektedir. Ve günümüzde popülerliği artmıştır. Bu çalışmada yapay sinir ağlarının yüksek bir duyarlılıkta tahmin yaptığı gösterilmiştir.

Kaynaklar

1. Türkiye Kalp ve Damar Hastalıkları Önleme ve Kontrol Programı Eylem Planı. (2015) T.C Sağlık Bakanlığı Türkiye Halk Sağlığı Kurumu, 988, 2015.
2. Kalp hastalıkları önlenbilir (2016) [online]. <http://webb.deu.edu.tr/halksagligi/?SID=ContentBlogger&ID=114&PID=Hal kaYo nelik&TID=G%C3%BCncel%20Konular%20%C2%BB%20Halka%20y%C3%B6 nelik>
3. Ayhan, B. (2016). Yapay sinir ağıları. 11 Eylül 2019, <https://slideplayer.biz.tr/slide/10200379/>.
4. <https://www.kaggle.com/datasets/erencanardc/kalp-hastaliklari-analizi> veri seti.
5. Doç.Dr.Özel SEBETCİ Yapay Zekayı Kodlamak .(Yapay Sinir Ağları 389-406) sayfalar

Ekler

EK 1 = Projede kullanılan Jupiter notebookta yazılan kodlar.

```
import numpy as np
import pandas as pd
dataframe= pd.read_csv(r"C:\Users\meta-\Desktop\ah_kalbim.csv")
dataframe
dataframe.describe()
dataframe.corr()["amac"].sort_values()
dataframe.corr()["amac"].sort_values().plot(kind="bar")
import matplotlib.pyplot as plt
import seaborn as sbn
sbn.countplot(x= "amac", data = dataframe)
import tensorflow as tf
from sklearn.model_selection import train_test_split
y = dataframe["amac"].values
x = dataframe.drop("amac" ,axis=1).values
x_train, x_test, y_train, y_test= train_test_split(x,y,test_size=0.33, random_state=3)
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense

model=Sequential()
x_train.shape

model.add(Dense(13, activation="relu"))
model.add(Dense(13, activation="relu"))
model.add(Dense(13, activation="relu"))
model.add(Dense(1,activation="sigmoid"))
model.compile(loss="binary_crossentropy", optimizer="adam")
```



```
model.fit(x=x_train, y=y_train, validation_data=(x_test,y_test), epochs=500,
verbose=1)

modelkaybi=pd.DataFrame(model.history.history)

modelkaybi.plot()

tahmin = (model.predict(x_test)>0.5).astype("int32")

tahmin

from sklearn.metrics import classification_report, confusion_matrix
print(classification_report(y_test, tahmin))
```