

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DİYABET HASTALIĞININ YAPAY SİNİR AĞLARI
KULLANILARAK SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Müh. Faruk AÇMALI

**Enstitü Anabilim Dalı : ELEKTRİK ELEKTRONİK
MÜHENDİSLİĞİ**
Enstitü Bilim Dalı : ELEKTRONİK
**Tez Danışmanı : Prof. Dr. Etem
KÖKLÜKAYA**

Ocak 2010

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

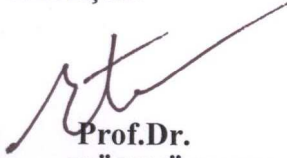
DİYABET HASTALIĞININ YAPAY SİNİR AĞLARI
KULLANILARAK SINIFLANDIRILMASI


YÜKSEK LİSANS TEZİ

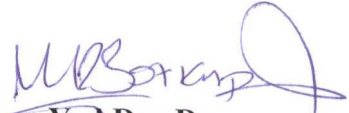
Elektrik Elektronik Müh. Faruk AÇMALI

Enstitü Anabilim Dalı : ELEKTRİK ELEKTRONİK
MÜHENDİSLİĞİ
Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 13 / 01 /2010 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.


Prof.Dr.
Etem KÖKLÜKAYA
Jüri Başkanı


Yrd.Doç.Dr.
H. İbrahim ESKİKURT
Üye


Yrd.Doç.Dr.
M. Recep BOZKURT
Üye

ÖNSÖZ

Yapay sinir ağırları günlük hayatımızda birçok uygulamada karşımıza çıkmaktadır. Kuşkusuz insan sağlığını ilgilendiren konularda da yapay sinir ağırları ile çalışmalar yapılmaktadır. Hekimlerin zaman içerisinde tecrübe ile elde ettikleri bilgilere ulaşmayı sağlayan yapay sinir ağırları, hastalıkların teşhisinden ve uygulanacak tedavilerde hekimlere yol gösterici olacaktır. Bu sayede insan kaynaklı hataların minimuma indirilmesi mümkün olabilecektir. Gelecekte yeni tedavi ve tanı yöntemlerinin ortaya çıkarılmasında hekimlerin ve doktorların beraber yapacakları çalışmalar daha da önem kazanacaktır.

Bu çalışmada beni yönlendiren bilgi ve deneyimlerini benimle paylaşan değerli hocalarım sayın Prof. Dr. Etem KÖKLÜKAYA, Yrd. Doç. Dr. Murat YILDIZ ve Yrd. Doç. Dr M. RECEP BOZKURT ile sevgili eşim Uz. Dr. Serap Betül AÇMALI' ya teşekkürü bir borç bilirim.

İÇİNDEKİLER

ÖNSÖZ.....	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ.....	vii
ÖZET.....	viii
SUMMARY.....	ix
BÖLÜM 1.	
Giriş	1
1.1. Şeker Hastalığı (Diyabetes Mellitus).....	1
1.2. DM'un Etyolojik Sınıflandırılması.....	2
1.2.1. Tip 1 DM.....	2
1.2.2. Tip 2 DM.....	3
1.2.3. Gestasyonel DM.....	3
1.2.4. Diğer bazı nadir diyabet tipleri.....	3
1.3. Risk Faktörleri.....	5
1.3.1. Tip 1 DM için risk faktörleri.....	5
1.3.2. Tip 2 DM için risk faktörleri	5
1.4. Tip 2 DM tarama kriterleri.....	7
1.5. Diyabet Semptomları.....	8
1.6. DM Tanısı	8
1.6.1. Diyabet tanı kriterleri (ADA 1997, WHO 1999).....	9
BÖLÜM 2.	
YAPAY SİNİR AĞLARI	11
2.1. Yapay Sinir Ağlarının Genel Kullanım Alanları.....	12
2.2. Yapay Sinir Ağlarının Biyolojik Sinir Ağı ile Karşılaştırılması.....	12

2.3. Yapay Sinir Ağının Yapısı.....	15
2.4. Aktivasyon Fonksiyonları.....	17
2.4.1. Doğrusal aktivasyon fonksiyonu.....	17
2.4.2. Sigmoid aktivasyon fonksiyonu.....	18
2.4.3. Tanjant hiperbolik aktivasyon fonksiyonu.....	19
2.5. Yapay Sinir Ağlarının Sınıflandırılması.....	19
2.5.1. İleri beslemeli ağlar.....	20
2.5.2. Geri beslemeli ağlar.....	21
2.6. Yapay Sinir Ağlarının Öğrenme Algoritmalarına göre Sınıflandırılması.....	22
2.6.1. Danışmanlı öğrenme.....	23
2.6.2. Danışmansız öğrenme.....	24
2.7. Çok Katmanlı PerceptronEğitim Algoritması.....	25
2.7.1 Geri yayılım algoritması.....	26
2.7.2. Delta-bar-delta algoritması.....	27
2.7.3. Genişletilmiş delta-bar-delta algoritması.....	28
BÖLÜM 3.	
3.1. Yapay Sinir Ağının Giriş Parametreleri.....	30
3.2. Yapay Sinir Ağının Matlab Uygulaması.....	32
BÖLÜM 4.	
SONUÇ VE ÖNERİLER.....	36
4.1. Sonuç.....	36
4.2. Öneriler.....	37
KAYNAKLAR.....	38
ÖZGEÇMİŞ.....	40

SİMGELER VE KISALTMALAR LİSTESİ

AKŞ:	Açlık Kan Şekeri
BKİ:	Beden Kitle İndeksi
ÇKA:	Çok Katmanlı Algılayıcı
DM:	Diabetes Mellitus
HbA1-c:	Glikolize Hemoglobin
HDL:	Yüksek Dansiteli Lipoprotein
IFG:	Bozulmuş Açlık Glikozu
IGT:	Bozulmuş Glikoz Toleransı
OGTT:	Oral Glikoz Toleransı
TURDEP:	Türkiye Diyabet Epidemiyoloji Projesi
WHO:	Dünya Sağlık Örgütü
YSA:	Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 2.1.	Biyolojik Sinir hücresi	11
Şekil 2.2.	Statik Hücre Modeli	16
Şekil 2.3.	Doğrusal Aktivasyon Fonksiyonu	18
Şekil 2.4.	Sigmoid Aktivasyon Fonksiyonu	18
Şekil 2.5.	Tanjant Hiperbolik Aktivasyon Fonksiyonu	19
Şekil 2.6.	İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı	20
Şekil 2.7.	Geri Beslemeli Ağ için Blok Diyagram	21
Şekil 2.8.	Öğrenme Yöntemleri	22
Şekil 2.9.	Danışmanlı Öğrenme Yapısı	23
Şekil 2.10.	Takviyeli Öğrenme Yapısı	24
Şekil 2.11.	Danışmansız Öğrenme Yapısı	25
Şekil 2.12.	Çok Katmanlı Sinir Ağında Hata ve Aktivasyon Yayılım	26
Şekil 3.1.	Yapay Sinir Ağı Modeli	32
Şekil 3.2.	Yapay Sinir Ağı Fonksiyon Bilgileri	33
Şekil 3.3.	Yapay Sinir Ağına Ait Eğitim Bilgileri	34
Şekil 3.4.	Yapay Sinir Ağına Ait Eğitim Parametreleri	34
Şekil 3.5.	Yapay Sinir Ağıнын transfer edilmesi	35

TABLolar LİSTESİ

Tablo 1.1.	DM ve glikoz metabolizmasının diđer bozukluklarında tanı kriterleri	10
Tablo 2.1	Biyolojik sinir ađı ile yapay sinir ađının karşılaştırılması	13
Tablo 3.1	Çalıřmada kullanılan yapay sinir ađına ait giriş parametreleri	31
Tablo 4.1	Geri yayılım algoritmasına ait yapay sinir ađının başarıımı	36

ÖZET

Anahtar kelimeler: Diyabet, Yapay Sinir Ağları

Geniş bir uygulama alanına sahip olan yapay sinir ağlarından hastalık teşhisinde de faydalanmak mümkün olmaktadır. Bu çalışmada toplam 225 kişiye ait 17 farklı parametre ve laboratuvar bilgisi kullanılarak Diyabet hastalığı teşhis edilmek istenilmiştir. Yapay sinir ağları modellerinden geri yayılım modeli seçilmiş, Matlab bilgisayar programına ait neural network toolbox grafik ara yüzü kullanılarak yapay sinir ağlarının eğitimi ve test edilmesi sağlanmıştır. Yapay sinir ağının eğitiminde kullanılan hedefler, uzman hekimler tarafından verilen diyabet hastasıdır ya da sağlıklıdır bilgisinden elde edilmiştir. Bu çalışmada test verilerinin başarıyı yapay sinir ağının sağlıklı olarak belirlediği kişilerin hekimlerin sağlıklı olarak belirlediklerine oranı, yapay sinir ağının hasta olarak belirlediği kişilerin hekimlerin hasta olarak belirlediklerine oranı ve yapay sinir ağının sağlıklı ve hasta olarak belirlediği kişilerin hekimlerin sağlıklı ve hasta olarak belirlediklerine oranı kullanılarak değerlendirilmiştir.

CLASSIFICATION OF DIABETES USING ARTIFICIAL NEURAL NETWORKS

SUMMARY

Key Words: Diabetes, Artificial Neural Network

Artificial Neural Networks, which have very large application area, also can be used in diagnosis of disease. In this study, 17 different parameters which are taken from total 225 people's used as laboratory datas to diagnose diabetes. Feed-forward backpropagation model was selected in artificial neural networks that trained and tested by using neural network toolbox graphic interface in Matlab. The targets which are used in training of artificial neural Networks, are evaluated from doctors' knowledge in regards to ill or healthy datas. In this thesis the success of test datas are determined by the ratio of artificial neural network's results which shows healthy patients to the healthy patients according to the doctors' judgements, and by the ratio of artificial neural network's results which shows diabetic patients to the diabetic patients according to doctors' judgements, and also by the ratio of all the artificial neural network's results to all the doctors' judgements about being diabetic or non-diabetic.

BÖLÜM 1. GİRİŞ

Hekimlerin hastalar ile karşı karşıya geldiklerinde en büyük amaçları doğru tedaviyi uygulamaktır. Tedavinin doğru olabilmesi için de tanının doğru konulması gereklidir. Bu nedenle uygun verinin bulunması, verinin özelliklerinin çıkarılması ve yeni verinin analizinin yapılması gerekmektedir. Hekimler, karar verme işleminde çeşitli istatistikî teknikler ve edindikleri tecrübeler ile veriyi işlemekte, verinin karmaşıklığı durumunda veri analizi için bilgisayarların kullanımına ihtiyaç duymaktadırlar. Son zamanlardaki gelişmeler incelendiğinde, tıpta bilgisayar destekli karar verme uygulamalarına yönelik çalışmalarda artış olduğu görülmektedir. Yapay sinir ağları (YSA)'nın modelleme ve karar verme işlemlerinde kullanılan en önemli araçlardan olmasının nedeni, sınırlı ve tamamlanmamış olan veri tabanlarından en iyi sonucu çıkarabilmesi ve farklı eğitim algoritmaları ile eğitilmeleri durumunda başarının artırılabilmesidir. Ayrıca yapay sinir ağları hastaların muayene bulguları, laboratuvar sonuçları, görüntüleme yöntemleri ve tanıda kullanılan diğer tetkik sonuçlarını kullanarak teşhis koyabilme imkânına sahiptir [1, 2, 3]

Bu çalışmada diyabet hastalığının tanısında, çok katmanlı perceptron sinir ağlarının geliştirilmesinde geri yayılım algoritması kullanılmıştır. Yapay sinir ağının giriş verileri ile eğitiminde ve test edilmesinde MATLAB bilgisayar programı kullanılmıştır.

1.1. Şeker Hastalığı (Diyabetes Mellitus)

Diyabetes Mellitus (DM); insülin hormonunun yokluğu, yetersizliği veya doku düzeyinde etkisizliği nedeniyle oluşan hiperglisemi (kan şekeri yüksekliği), dislipidemi (kan lipid düzeylerinin bozukluğu), glukozüri (idrara glukoz kaçıışı) ve bunlara eşlik eden birçok klinik ve biyokimyasal bulgu ile seyreden sistemik kronik bir metabolizma hastalığıdır (5, 6, 7). DM gelişiminde mutlak insülin eksikliğine yol

açan pankreas β hücre harabiyeti ve insülin direncine yol açan çeşitli patogenetik mekanizmalar rol oynar. İnsülinin hedef dokulardaki eksik etkisine bağlı karbonhidrat, yağ ve protein metabolizmasında bozukluklar meydana gelir [8,9].

Diyabet sinsi seyirli bir hastalık olması sebebiyle hastalığın görülme sıklığının saptanmasında güçlük çekilmektedir. Hastalık ilk yıllarda genellikle semptomsuz olduğundan gelişmiş ülkelerde bile diyabetiklerin bilinmeyen diyabetlilere oranı 2/1'dir. WHO (Dünya Sağlık Örgütü)'nün yaptığı çalışmalar doğrultusunda 171 milyon civarında diyabetli sayısı önümüzdeki on yılın sonunda 366 milyona ulaşması beklenmektedir (10,11). Tüm dünyada tanı koyulan diyabet vakalarının % 90-95'ni yetişkin ve şişman kişilerde görülen Tip 2 DM, % 5-10'nu da çocuklarda ve genç erişkinlerde görülen Tip 1 DM ve % 2-3'ünü diğer diyabet formları oluşturur. Gelişmiş ülkelerde toplumun %5-10'u Tip 2 diyabetlidir. Diyabetlilerin %30-50'sinin henüz tanı konulmamış vakalar olduğu sanılmaktadır [12]. Ülkemizde 2000 yılında tamamlanan WHO destekli Türkiye Diyabet Epidemiyoloji Projesinde (TURDEP) 20 yaş ve üstü Tip 2 DM prevalansın %7,2 ve 2,6 milyon diyabetli ile 1,6 milyon prediyabetli olduğu saptanmıştır. Giderek artan obezite, beslenme alışkanlığı, fiziksel inaktivite ve popülasyondaki yaş ortalamasındaki artış gibi faktörlerin tamamının hastalığın görülme sıklığındaki bu hızlı artışa katkısı vardır [13].

1.2.DM' un Etyolojik Sınıflandırılması

Diyabetli hastaların %5-10'u Tip 1 DM, %90-95'ini ise Tip 2 DM oluşturmaktadır. [8,9]

1.2.1. Tip 1 DM

Tip 1 DM herhangi bir yaşta ortaya çıkabilirken genellikle çocuklarda ve genç erişkinlerde oluşur. Pankreas β hücreleri insülin salgılayamaz ve hasta kişiler, kanlarındaki glikoz seviyesini kontrol etmek için her gün insülin enjeksiyonu

yapmak zorundadırlar. Eđer Tip 1 DM'li kişiler insülin bulamazlarsa diyabet komasına girerler. Uluslararası Diyabet Federasyonu, dünyada en az 17 milyon kişide Tip 1 DM olduğunu tespit etmiştir.

1.2.2. Tip 2 DM

Tip 2 DM' li kişilerde, insülin üretimi azdır veya onu yeterince kullanamamaktadırlar. Genellikle hastaların insülin gereksinimleri yoktur. Genellikle, diyetlerini kontrol ederek, düzenli egzersiz yaparak, ağızdan ilaç ve bazen de insülin alarak kanlarındaki glikozu kontrol edebilirler.

Tip 2 DM, 45 yaşından büyük şişman kişilerde en yaygındır. Bununla birlikte, artan obezitenin bir sonucu olarak, çocuklarda ve genç erişkinlerde de yaygın hale gelmektedir. Tip 2 DM en yaygın diyabet tipidir, tüm diyabetlilerin %90-95'ini oluştururlar. Eđer tip 2 DM'li kişilerde tanı erken konmaz ve tedavi edilmez ise, ölüme bile yol açabilen ciddi komplikasyonlar gelişebilir. Tüm dünyada milyonlarca kişi hastalığını bile bilmeden veya yeterli tıbbi bakıma ulaşmadan Tip 2 diyabetli olarak yaşamaktadırlar. Uluslararası Diyabet Federasyonu, dünyada en az 170 milyon kişide Tip 2 DM olduğunu tahmin etmektedir.

1.2.3. Gestasyonel DM

Bazen gebe kadınlarda oluşan, geçici bir diyabet formudur. "Gestasyonel Diyabet" olarak adlandırılmaktadır. Hamilelik tamamlandığında genellikle kaybolmaktadır. Bu tip diyabeti olan kadınlar, daha sonraki zamanlarda, yüksek oranda, Tip 2 DM geliştirme riskine sahiptirler (%15).

1.2.4. Diğer bazı nadir diyabet tipleri

a) hücre fonksiyonunda genetik kusurlar

- a1. MODY 1,2,3,4,5 ve 6
- a2. Mitekondriyal DNA mutasyonu
- a3. Diğerleri
- b) İnsülin etkisinde genetik kusurlar
 - b1. Tip A insülin rezistans
 - b2. Leprechaunizm
 - b3. Rabson-Mandenhall Sendromu
 - b4. Lipoatrofik diabet
 - b5. Diğerleri
- c) Ekzokrin pankreas hastalıkları
 - c1. Pankreatit
 - c2. Travma / pankreatektomi
 - c3. Neoplazi
 - c4. Kistik Fibrozis
 - c5. Hemokromatozis
 - c6. Fibrokalküloz Pankreatopati
 - c7. Diğerleri
- d) Endokrinopatiler
 - d1. Akromegali
 - d2. Cushing Sendromu
 - d3. Glukagonoma
 - d4. Feokromasitoma
 - d5. Hipertiroidizm
 - d6. Somatostatinoma
 - d7. Aldosteronoma
 - d8. Diğerleri
- e) İlaç ya da kimyasal maddeler
- f) Enfeksiyonlar
- g) İmmün kaynaklı nadir diabet formları
- h) Diabetle birlikte görülen diğer genetik sendromlar

- h1. Down Sendromu
- h2. Klinefelter Sendromu
- h3. Turner Sendromu
- h4. Wolfram Sendromu
- h5. Friedreich ataksisi
- h6. Huntington koresi

1.3. Risk Faktörleri

Birçok erişkin, semptomları tanınmadan birkaç yıl önce diyabetli olmuş olabilir. Tanı konduğu sırada, bunların birçoğunda, diyabet komplikasyonları gelişmeye başlamıştır. Görme azalması, böbrek yetmezliği, kalp hastalığı, felç ve sinir hasarı gibi. Dünyanın birçok yerinde de, hiç teşhis edilmemiş birçok diyabetli vardır. Diyabeti erken ortaya çıkarmak demek, tedavisinin daha kolay ve ciddi komplikasyon riskinin önemli ölçüde azaltılabilir olması demektir. Diyabetin gelişmesine yardımcı birçok risk faktörleri vardır.

1.3.1. Tip 1 DM için risk faktörleri:

Bunlar, çok iyi tanımlanmamışlardır. Fakat genetik ve çevresel faktörlerin bu tip diyabet gelişimi için tetikleyici rol oynayabildiği görülmektedir. Asıl etken, otoimmün mekanizmanın bozukluğudur.

1.3.2. Tip 2 DM için risk faktörleri:

Yaş: Diyabetli kişilerin %90- 95'i tip 2 diyabetlidir. Bu tip genellikle 40 yaşın üzerindeki kişilerde oluşur. Fakat zamanımızda, çocuk ve ergenlik çağındakileri de önemli ölçüde etkilemektedir. Yaşlandıkça, diyabet riski artmaktadır.

Şişmanlık: Tip 2 diyabetli kişilerin %80'inden fazlası kiloludur. Beden kitle indeksi >25 kg/m² üzerinde olan kişilerde yüksek diyabet gelişme riski vardır.

Diyabete İlişkin Aile Hikâyesi: Araştırmalar, eğer yakın aile üyelerinde bir diyabet hikâyesi var ise kişilerin daha fazla risk altında olduğunu göstermiştir. Akrabalık ne kadar yakın ise, diyabet riski de o kadar yüksektir.

Fiziksel Tembellik: Araştırmalar aktif bir hayat sürdürmeyen kişilerin, daha fazla tip 2 diyabet gelişme riskinde olduğunu göstermiştir. Ne kadar az egzersiz yaparsanız diyabet gelişme olasılığı o kadar yüksektir.

Bozulmuş Glikoz Toleransı (IGT): Sağlıklı bir kişinin kan şekeri 70–110 mg/dl (100 mililitre kanda mg olarak glikoz) arasındadır. Veya 3,9–6,0 mmol/L arasındadır. Bozulmuş glikoz toleransı, normalden daha yüksek bir kan glikoz seviyesidir. Açık diyabetin başlangıcıdır.

İrk/Etnik Özellikler: Literatürlere göre ırk ve etnik özellikler bir kişide diyabet gelişme olasılığını belirlemede önemlidir. Genel olarak diyabetli hastalara bakıldığında Afrikalı-Amerikalı, Hispanik Amerikalı, Yerli Amerikalı, Asyalı-Amerikalı ve Pasifik Adalılarda daha fazla diyabet ortaya çıkmaktadır.

Hamilelik Sırasında Diyabet: Bazı kadınlarda, hamilelikleri sırasında “gestasyonel diyabet” adıyla bilinen geçici bir diyabet tipi oluşur. Gestasyonel diyabet tüm hamileliklerin %2-5'inde gelişir. Fakat genellikle, hamilelik sonlandığında kaybolur. Bununla birlikte, gestasyonel diyabeti olan veya 4 kg veya daha büyük bebek dünyaya getiren kadınlarda, yaşamlarında daha geç bir dönemde, daha fazla Tip 2 diyabet gelişme olasılığı vardır.

Hipertansiyon varlığı: Tansiyon ölçümlerinin $>140/90$ mmHg olması insülin direnci denilen insulinin dokular tarafından kullanılmasının zorlaşmasına neden olması sonucunda risk oluşturmaktadır.

Kolesterol değerleri: Kişilerin HDL (yüksek dansiteli lipoprotein) kolesterol seviyesi ≤ 35 mg/dl ve / veya trigliserit seviyesi >250 mg/dl olması risk oluşturmaktadır.

Polikistik over sendromu: Bayanlardaki over patolojisinde yine insulın direnci nedeniyle risk oluşmaktadır.

1.4. Tip 2 DM Tarama Kriterleri

1. Obez veya kilolu yani BKİ (Beden kitle indeksi) ≥ 25 kg/m² olan, özellikle santral obezite denilen bel çevresi kadında >88 cm, erkekte >102 cm olması olarak tanımlanan kişilerde 45 yaşından itibaren 3 yılda bir, tercihen açlık kan şekeri (AKŞ) ile diyabet taraması yapılmamıştır.

2. Ayrıca BKİ ≥ 25 kg/m² olan kişilerin, aşağıdaki risk gruplarından birine mensup olmaları halinde, daha genç yaşlardan itibaren ve daha sık araştırılmaları gerekir:

- a. Birinci derece yakınlarında diyabet bulunan kişiler
- b. Diyabet prevalansı yüksek etnik gruplara mensup kişiler.
- c. İri bebek doğuran veya daha önce Gestasyonel DM tanısı almış kadınlar.
- d. Hipertansif bireyler (kan basıncı: $\geq 140/90$)
- e. Dislipidemikler (HDL-kolesterol ≤ 35 mg/dl veya trigliserid ≥ 250 mg/dl)
- f. Daha önce bozulmuş açlık glikozu (IFG) veya IGT saptanan bireyler
- g. Polikistik over sendromu olan kadınlar
- ğ. İnsülin direnci ile ilgili klinik hastalığı veya bulguları (akantozis nigricans) olanlar
- h. Koroner, periferik veya serebral damarsal hastalığı bulunanlar
- ı. Düşük doğum tartılı doğan kişiler
- i. Sedanter yaşam süren veya fizik aktivitesi düşük olan kişiler
- j. Doymuş yağlardan zengin ve posa miktarı düşük beslenme alışkanlıkları olanlar.

k. Şizofreni hastaları ve atipik antipsikotik ilaç kullanan kişiler.

3. Ayrıca Tıp 2 diabetes riski yüksek çocuk ve adolesanlarda, on yaşından itibaren iki yılda bir diabetes taraması yapılmalıdır [12].

1.5. Diabetes Semptomları

Tip 1 diabetesin başlangıcı genellikle birdenbire ve dramatiktir. Aşağıdaki semptomları içerebilir:

- Anormal susama (polidipsi) ve ağız kuruması,
- Sık idrara çıkma (poliüri), gece idrara kalkma (noktüri),
- Kol ve bacaklarda yorgunluk/Enerji azlığı,
- Sürekli açlık hissi (polifaji) veya iştahsızlık,
- Ani kilo kaybı,
- Yavaş iyileşen yaralar,
- Tekrarlayan mantar enfeksiyonları ve inatçı enfeksiyonlar,
- Bulanık görme.

Bu semptomlar tip 2 DM'li kişilerde de gözlemlenebilir. Fakat genellikle, semptomlar daha az belirgindir. Tip 2 DM başlangıcı yavaştır ve erken hiçbir belirgin semptom göstermeyebilirler.

Bu kişilerde çoğunlukla hastalık tablosu birkaç yıl sonra teşhis edilir. O zaman birçok komplikasyon gelişmiş olabilir.

1.6. DM Tanısı

Kan şekerinin teşhis amacıyla değerlendirilmesi venöz plazma ölçümlerine göre yapılır. Kan şekerini değerlendirmede kan örneği alma yeri önemlidir. Açlıkta parmak ucundan şeker ölçüm çubuğu ile alınan kan koldan alınan venöz kana göre açlıkta 5–10 mg kadar, toklukta 20 mg kadar yüksek ölçülebilir. Ayrıca parmak ucundan alınan kapiller kan veya venöz plazmada kan şekeri ölçümleri venöz tam kan örneklerinden yaklaşık 20 mg/dl (1mmol/l) daha yüksektir. Glikoz tam kandan

bakılacağı zaman alındıktan hemen sonra bakılmalıdır. Çünkü glikoz kan hücreleri tarafından kullanılır ve saatte %7 oranında azalır (9).

Açlık kan şekeri (AKŞ) 8–12 saat açlıktan sonra sabah bakılan kan şekeri. DM tanısı için ilk etapta AKŞ' ne bakılır. 1 hafta arayla AKŞ 125 mg /dl üzerinde ölçülürse DM tanısı konulur. AKŞ 100-125mg/dl ölçülürse OGTT (Oral Glikoz Tolerans Testi) yapılır. Ayrıca açlık plazma glikozu normal olan, ancak diyabet açısından yüksek risk grubunda bulunan bireylerde OGTT ile Bozulmuş glikoz toleransı (IGT) ve diyabet tanısı konulabilir (9). Günümüzde daha önce 'gizli diyabet' diye anılan IGT (Bozulmuş glikoz toleransı) ve IFG (Bozulmuş açlık glikozu) artık 'prediyabet' olarak kabul edilmektedir. Bunun nedeni, epidemiyolojik kanıtların bu düşük düzeydeki karbonhidrat intoleransının bile makrovasküler komplikasyonlarla birlikteliğini ve sıklıkla diabete ilerlediğini göstermesidir (12).

1.6.1. Diyabet tanı kriterleri (ADA 1997, WHO 1999):

1. Diyabet semptomlarıyla (poliüri, polidipsi ve açıklanamayan kilo kaybı) beraber günün herhangi bir zamanında plazma glikozu ≥ 200 mg/dl (11,1 mmol/l) veya
2. İki kez ölçülen Açlık plazma glikozu ≥ 126 mg/dl (7,0 mmol/l). (Açlık en az 8 saat kalori almamak olarak tanımlanır. 8–12. saatler arası kan alınır) veya
3. OGTT' de 2 saatlik plazma glikozu ≥ 200 mg/dl (11,1 mmol/l) (OGTT, WHO' un tanımlandığı şekilde 75 g suda çözülen glikoza eşdeğer glikoz yüklemesi ile yapılmalıdır.)

Diabetes mellitus	
Rasgele diabet(+diabet semptomları)	≥200
AKG(en az 8 saatlik açlığı takiben)	≥126
OGTT' de 2. Saat KG	≥200
Bozulmuş glukoz toleransı(IGT)	
OGTT' de 2. saat	140-199
Bozulmuş açlık glikozu(IFG)	
AK(en az 8 satlik açlığı takiben)	100-125

Tablo 1. DM ve glikoz metabolizmasının diğer bozukluklarında tanı kriterleri [12]


Hipergliseminin ve metabolik ayarsızlığın belirgin olmadığı durumlarda testler tekrar edilmelidir. OGTT'nin rutin olarak uygulanması önerilmemektedir. Diyabet için yüksek risk taşıyan bireyler, tanı amaçlı olarak OGTT ile değerlendirilmelidir. [9]

BÖLÜM 2. YAPAY SINİR AĞLARI (YSA)

Yapay sinir ağları ile ilgili yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme mekanizmalarının ortaya çıkarılmasını amaçlamaktaydı. Bugün gelinen noktada yapay sinir ağları hem teorik anlamda hem de pratik anlamda kayda değer yol alarak birçok hücrenin belli bir düzende bir araya getirilmesine, uygun öğrenme algoritmaları ile sinir ağlarının kurulabilmesine ve bu ağlar ile çok karmaşık görevleri başarıyla yerine getirebilmesine olanak sağlamıştır [14]

Yapay sinir ağlarının daha iyi anlaşılabilmesi için biyolojik sinir ağlarına sahip sinir sisteminin yapısının ve çalışma ilkelerinin bilinmesinde yarar vardır.

İnsan beyninin en temel parçası, hatırlama, düşünme, her harekette daha önceki deneyimlere başvurma yeteneğini sağlayan kendine özgü nöronlardır. Her bir biyolojik sinir hücresinin yaklaşık 10.000 kadar komşu bağlantısı vardır ve bu komşu sinirlerden uyarılar alır [15,16]. Şekil 2.1’ de biyolojik bir beyin sinir hücresi verilmiştir [25].



Şekil 2.1. Biyolojik sinir hücresi [25]

Sinir hücrelerinin birbirleri ile iletişimi Sinapslar ile kurarlar. Bu esnada hücreler aralarındaki bilgi geçişini kimyasal bir maddenin salgılanması ile birbirlerine temas

etmeden Sinaps üzerinden yaparlar. Bir veya çok girişli liflere sahip dendrit ile uzun taşıyıcılı bir lifi olan akson birbirlerine yaklaşırlar. Aksonun ucuna bilgi ulaştığı zaman, bir kimyasal madde salgılanarak tek yönlü bir veri geçişi sağlanır. Sinir hücreleri uyarıldıklarında bir aksiyon potansiyeli oluşur. Bu aksiyon potansiyel gerilimleri çok kısa süreli olup bunlara sinirsel darbeler veya darbe boşalmaları denir. Bilgi sinirsel darbeler şeklinde taşınır. Daha önce de belirtildiği gibi sinapslara geçiş tek yönlüdür. Bu nedenle haberleşme de tek yönlüdür [17, 18, 19].

Genel olarak yapay sinir ağları insan beyninin sinir ağlarını taklit eden bilgisayar programlarıdır. Bir anlamda paralel bilgi işlemi olarak da düşünülebilir. Bu bilgiler ilgili olaya ait bilgiler üzerinde eğitilerek verilir. Böylece açığa çıkarılmış özellikler üzerinde çeşitli genellemeler yapılarak daha sonra ortaya çıkacak ya da o ana kadar hiç rastlanmamış olaylara çözümler üretmektedir. Yapay sinir ağları zaman zaman bağlantıcılık paralel dağıtılmış işlem, sinirsel-işlem, doğal zeka sistemleri ve makine öğrenme algoritmaları gibi isimlerle de anılmaktadır. Öğrenmenin yanı sıra ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir. Model seçimi ve sınıflandırılması işlev tahmini, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır. En çok kullanılan yapay sinir ağı geri yayımlı yapay sinir ağı olup tahmin ve sınıflandırma işlemlerinde çok iyi sonuçlar vermektedir.

2.1. Yapay Sinir Ağlarının Genel Kullanım Alanları

Yapay sinir ağları her türlü bilgiyi işlemek ve analiz etmek amacı ile kullanılır. Yapay sinir ağlarının başlıca uygulama alanları sınıflandırma, tahmin ve modellemedir. Özet olarak denetim, ses, el yazısı, parmak izi tanıma, meteorolojik yorumlama, kalp, beyin fonksiyonlarını izleme, tanıma ve yorumlamada sık olarak kullanılmaktadır [16].

2.2. Yapay Sinir Ağlarının Biyolojik Sinir Ağı ile Karşılaştırılması

Yapay sinir ağları Tablo 2.1'de verildiği gibi biyolojik sinir hücresinin fonksiyonel özelliklerine benzer şekilde yapılandırılmıştır. İnsanlar tarafından gerçekleştirilmiş

örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyebilen bir bilgisayar sistemi olan yapay sinir ağları insan beyninin fonksiyonel özelliklerine benzer şekilde dağıtık bellek, paralellik, bilginin saklanması, hata toleransı, öğrenilebilirlik, genelleme, uyarlanabilirlik gibi konularda başarılı bir şekilde uygulanmaktadırlar.

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm(Sinir İşlem Elemanı)
Sinaps	Sinirler Arası Bağlantı Ağırlıkları
Dendrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Sinir Çıkışı

Tablo 2.1. Biyolojik sinir ağı ile yapay sinir ağının karşılaştırılması [15]

Dağıtık bellek: Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Ağın tamamı öğrendiği olayın bütünü karakterize ettiği için doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur [20,22].

Paralellik: Hız ve güvenilirlik sorunlarını beraberinde getiren alışılmış bilgi işlem yöntemlerinin çoğu seri işlemlerden oluşmaktadır. Bu seri işlemler gerçekleşirken herhangi bir birimin yavaş oluşu tüm sistemi yavaşlatırken, paralel bir sistemde yavaş bir birimin etkisi çok azdır. Nitekim seri bir bilgisayarın bir işlem elemanı beyne göre binlerce kez daha hızlı işlemesine rağmen [22], beynin toplam işlem hızı seri çalışan bir bilgisayara göre kıyaslanamayacak kadar yüksektir.

Bilginin Saklanması: Yapay sinir ağlarında bilgi, ağın bağlantılarının değerleri ile ölçülmektedir. Bilgiler ağın üzerinde saklı olup ortaya çıkarılması zordur. Yapay sinir ağlarında her bir işlem birimi, çözülecek problemin tümü ile ilgilenmek yerine, sadece problemin gerekli parçası ile ilgilenmektedir ve problemin bir parçası işlemektedir. Hücreler çok basit işlem yapmalarına rağmen, sağlanan görev paylaşımı sayesinde, çok karmaşık problemler çözülebilmektedir [20].

Hata Toleransı: Seri bilgi işlem yapan bir sistemde herhangi bir birimin hatalı çalışması, hatta bozulmuş olması tüm sistemin hatalı çalışmasına veya bozulmasına sebep olacaktır. Paralel bilgi işleme yapan bir sistemde ise, sistemin ayrı ayrı işlem elemanlarında meydana gelecek olan hatalı çalışma veya hasar, sistemin performansında keskin bir düşüşe yol açmadan, performansın sadece hata birimlerinin bir oranınca düşmesine sebep olur. Yapay sinir ağların hatayı tolere etme yetenekleri geleneksel yöntemlere göre son derece yüksektir [20,22].

Öğrenebilirlik: Yapay sinir ağları problemleri verilen örneklerle çözer. Yapay sinir ağlarının arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağlarının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle yapay sinir ağları, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir [20,22].

Genelleme: Yapay sinir ağları, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağı, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş yapay sinir ağları modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir. Görülmemiş örnekler hakkında da genelleme yaparak bilgi üretebilir. Bazı durumlarda ağa eksik bilgi içeren bir örüntü veya bir şekil verildiğinde örüntü tamamlama gerçekleştirebilirler [20,22].

Uyarlanabilirlik: Belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağları, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile yapay sinir ağları, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır [20,21].


2.3. Yapay Sinir Ağının Yapısı

Yapay sinir hücreleri bir araya gelerek yapay sinir ağını oluşturur. Yapay sinir ağlarını oluşturacak sinir hücrelerinin bir araya gelmesi üç katman halinde ve her katman içinde paralel olarak bir araya gelmesi ile olur. Proses elemanı olarak da adlandırılan yapay sinir hücresinin beş temel elemanı vardır. Ağın öğrenmesi istenen örnekler tarafından belirlenen dış dünyadan, başka hücrelerden veya kendisinden gelen bilgiler '**girdiler**' olarak adlandırılır. Gelen bilginin önemi ve hücre üzerindeki etkisini '**ağırlıklar**' gösterir. Ağırlıkların büyük, küçük, eksi, artı değerlere sahip olması önemli ya da önemsiz olduğu anlamına gelmez. Sıfır olması ise herhangi bir etkinin olmadığını gösterir. Ağa gelen net girdi; her gelen girdi değeri, kendi ağırlığı ile çarpılıp toplanması ile bulunur. '**toplama fonksiyonu**' olarak tanımlanan ve (2.3.1) numaralı bağlantıda formülize edilen bu fonksiyon her problem karşısında farklı formüller oluşturularak kullanılmaktadır. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir. Yani her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı proses elemanına da sahip olabilirler.

$$NET = \sum_i^n G_i A_i \quad (2.3.1)$$

'**Aktivasyon fonksiyonu**' olarak bilinen hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen bu fonksiyon da toplama fonksiyonunda olduğu gibi çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Mesela günümüzde en yaygın olarak kullanılan Çok Katmanlı Algılayıcı modelinde aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Aktivasyon fonksiyonu tarafından belirlenen çıktı değeri 'hücrenin çıktısı' olarak adlandırılır ve üretilen çıktı dış dünyaya, başka bir hücreye veya kendisine girdi olarak da gönderilir. Proses elemanı olarak da adlandırılan yapay sinir hücreleri **girdi katmanı** ile dış dünyadan bilgileri alır herhangi bir işleme tabi olmadan **ara katmana** iletilir. Bilgiler ara katmanda işlenir ve işlenen bilgiler çıktı katmanına girerek dış dünyaya gönderilmek üzere çıktı bilgileri üretilir. Buradan anlaşıldığı üzere yapay sinir ağlarında bir proses elemanının birden fazla çıktısı görülmesine rağmen aslında tek

bir çıktı değeri vardır; aynı değer birden fazla proses elemanın girdi olarak gitmektedir. Genel olarak yapay sinir hücre modelleri gerçekleştirdiği işleve göre hücreler statik ya da dinamik bir davranış gösterebilirler. Şekil 2' de ağırlıkların sabit olduğu ve hücrede geri besleme ya da geciktirilmiş sinyaller kullanılmadığı dikkate alınırsa bu hücre statik bir işlevi gerçekleştireceğinden statik hücre modeli olarak adlandırılabilir.



Şekil 2.2. Statik hücre modeli [14].

Statik hücrenin matematiksel modeli (2.3.2) numaralı bağlantıdaki gibi yazılabilir.

$$v = \sum_{i=0}^x w_i x_i \text{ ya da } v = \sum_{i=0}^x w_i x_i + b \quad (2.3.2)$$

Şekil 2.2'de görüldüğü üzere W hücrenin ağırlıklar matrisini, x hücrenin giriş vektörünü, v hücrenin net girişini, y hücre çıkışını ve $\varphi (/)$ hücrenin aktivasyon fonksiyonunu göstermektedir. (2.3.2) numaralı bağlantıda, x giriş vektörünün bileşenlerinin dış (geri beslemesiz) girişler olması durumunda hücrenin doğrusal olmayan statik bir işlevi gerçekleştireceği görülmektedir [14].


2.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, toplama fonksiyonundan elde edilen net girdiyi işlemde geçirerek hücre çıktısını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Hücre modellerinde, hücrenin gerçekleştireceği işleve göre sabit parametrelili yada uyarlanabilir parametrelili aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılan sigmoid ve tanjant hiperbolik fonksiyonlardır. Örneğin ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid fonksiyon, ortalamadan sapmanın öğrenilmesi isteniyorsa tanjant hiperbolik fonksiyon kullanılması önerilmektedir.

Aktivasyon fonksiyonları bir yapay sinir ağlarında nöronun çıkış genliğini genellikle $[0,1]$ veya $[-1,1]$ değerleri arasında sınırlar. Yapay sinir ağlarında da kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gereklidir. Lineer veya doğrusal olmayan transfer fonksiyonlarının kullanılması yapay sinir ağlarının karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. Aşağıda, hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları tanımlanmıştır [21,22].

2.4.1. Doğrusal aktivasyon fonksiyonu

Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve genellikle katmanlı yapay sinir ağlarının çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu matematiksel olarak $y=Av$ şeklinde tanımlanabilir. “A” sabit bir katsayıdır. yapay sinir ağlarının çıkış katmanında kullanılan doğrusal fonksiyon Şekil 2.3’ de verilmiştir.




Şekil 2.3. Doğrusal aktivasyon fonksiyonu (22)

2.4.2. Sigmoid aktivasyon fonksiyonu

Sigmoid Aktivasyon Fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle uygulamada en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyon, girdinin her değeri için sıfır ile bir arasında değer üretir. Sigmoid

fonksiyonunun denklemini; $y = \frac{1}{1+e^{-v}}$ 'dir.




Şekil 2.4. Sigmoid aktivasyon fonksiyonu [22]

2.4.3. Tanjant hiperbolik aktivasyon fonksiyonu

Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonunun biraz farklı şeklidir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır. Tanjant hiperbolik fonksiyonunun denklemini;

$$y = \frac{1 - e^{-2v}}{1 + e^{2v}}, \text{ dir.}$$



Şekil 2.5. Tanjant Hiperbolik aktivasyon fonksiyonu [22]

Literatürde geçen diğer aktivasyon fonksiyonları;

- Step Fonksiyonu
- Kutuplamalı Step Fonksiyonu
- Parçalı Doğrusal Fonksiyon
- Sinüs Fonksiyonu
- Eşik değer fonksiyonu' dur.

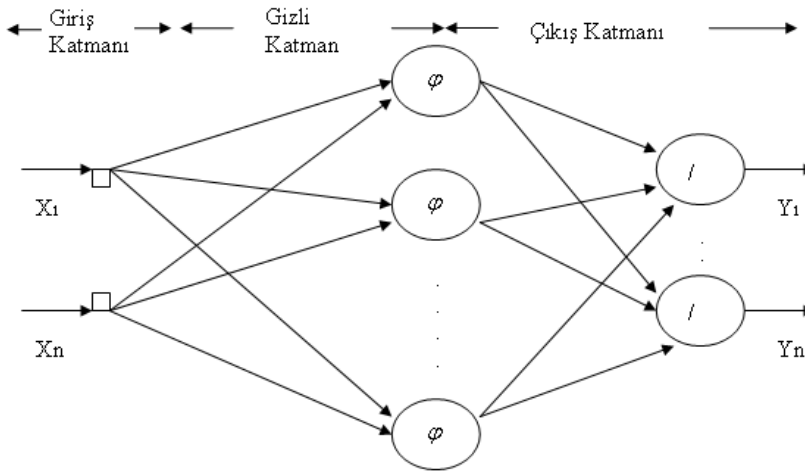
2.5. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları, yapılarına göre, ileri beslemeli ve geri beslemeli ağlar olmak üzere iki şekilde sınıflandırılırlar [22].

2.5.1. İleri beslemeli ağlar

İleri beslemeli ağları tek katmanlı ileri beslemeli ağlar ve çok katmanlı ileri beslemeli ağlar olarak ikiye ayırabiliriz. Tek katlı ağ yapısında giriş ve çıkış katmanları bulunmakla birlikte, giriş katmanında hiçbir hesaplama yapılmadığından katman olarak algılanmazlar.

Çok katmanlı ileri beslemeli ağ yapısında ise giriş ve çıkış katmanları arasında gizli katmanlar bulunmaktadır. Ağda girişler ilk gizli katmana bağlanırken gizli katmanın çıkışları kendinden sonraki gizli katmanın girişlerini oluşturur. Yapı bu şekilde ağ çıkışına kadar tekrarlanarak devam eder. Bu tekrarlanmalar her katmandaki her düğüm takip eden katmandaki tüm düğümlere bağlı ise tam bağlı ağ; izleyen katmandaki her düğüme bağlı değil ise kısmi bağlı ağdan bahsedilir.




Şekil 2.6. İleri beslemeli çok katmanlı yapay sinir ağı [14]

İleri beslemeli ağlara örnek olarak ÇKA (Multi Layer Perseptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir. Herhangi bir problemi çözmek amacıyla kullanılan YSA da, katman sayısı ve orta katmandaki hücre sayısı gibi kesin belirlenememiş bilgilere rağmen nesne tanıma ve sinyal işleme gibi alanların yanı sıra, ileri beslemeli YSA, sistemlerin tanımlanması ve denetiminde yaygın olarak kullanılmaktadır (21).

2.5.2. Geri beslemeli ağlar

Geri beslemeli sinir ağları, çıkış veya ara katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır (Şekil 2.7). Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Geri beslemeli ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, Özörgütlemeli Harita Ağı, Elman ve Jordan ağları verilebilir. Geri beslemeli yapay sinir ağlarında, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir. Geri besleme bir geciktirme elemanı üzerinden yapılırken, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir.



Şekil 2.7. Geri beslemeli ağ için blok diyagram [23]

Geriye doğru hesaplamada, ağın ürettiği çıktı değeri, ağın beklenen çıktıları ile kıyaslanır. Bunların arasındaki fark, hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Çıktı katmanında m. proses için oluşan hata, $E_m = B_m - Ç_m$ olacaktır. Çıktı katmanında oluşan toplam hatayı bulmak için, bütün hataların toplanması gereklidir. Bazı hata değerleri negatif olacağından, toplamın sıfır olmasını önlemek

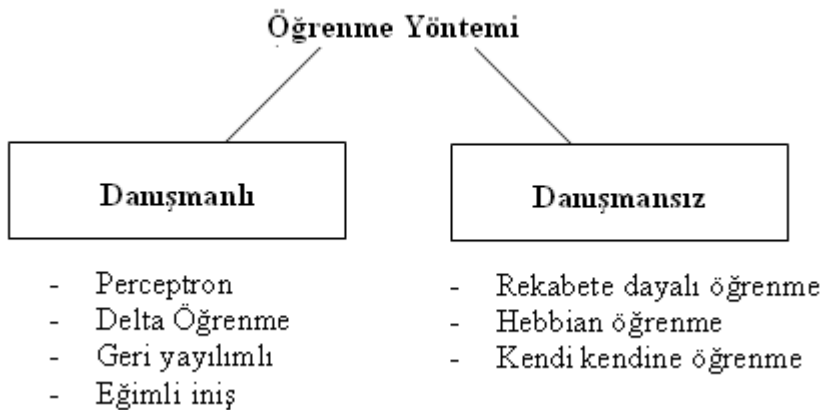
amacıyla ağırlıkların kareleri hesaplanarak sonucun karekökü alınır. Toplam hata aşağıdaki formül ile bulunur.

$$TH = \sqrt{\frac{1}{2} \sum_m E_m^2} \quad (2.5.1)$$

Toplam hatayı en aza indirmek için, hatanın kendisine neden olan proses elemanlarına dağıtılması gerekmektedir. Bu da, proses elemanlarının ağırlıklarını değiştirmek demektir [21].

2.6. Yapay Sinir Ağlarının Öğrenme Algoritmalarına göre Sınıflandırılması

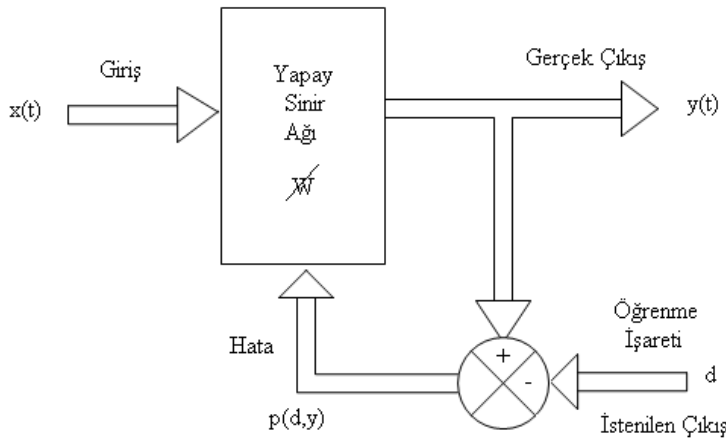
Yapay sinir ağlarında bilgi ağdaki bağlantıların ağırlıklarında depolanır. Bir ağda öğrenme kısaca istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. Sinirler arasındaki ağırlıkların öğrenme kuralları uyarınca dinamik olarak değiştirilebilen ağlar eğitilebilen yani öğrenebilen ağlardır. Bu şekilde ağlar yeni şekilleri tanıyabilir veya verilen bir girişin hangi sınıfa ait olduğuna karar verebilir. Temelde öğrenme yöntemleri danışmanlı ve danışmansız olarak ikiye ayrılır. Öğrenme yöntemleri özet olarak Şekil 2.8' de verilmiştir [16].



Şekil 2.8. Öğrenme Yöntemleri [16]

2.6.1. Danışmanlı öğrenme

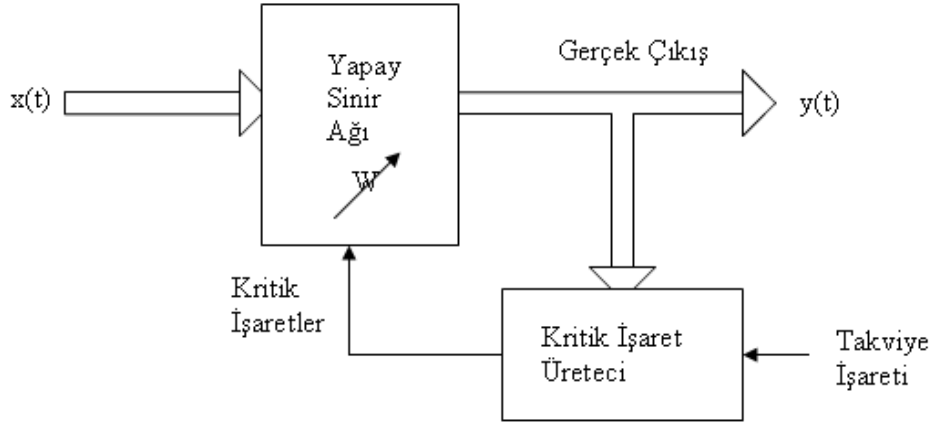
Danışmanlı öğrenmede önce yapay sinir ağı eğitilir. Eğitime işleminde sinir ağına giriş ve çıkış bilgileri sunulur. Bu bilgiler eğitime kümesi olarak tanımlanır. Her bir giriş kümesi için uygun bir çıkış kümesi ağı sağlanmalıdır. Belirli bir sıralamadaki girişler için istenilen istatistiksel doğruluk elde edildiği zaman eğitime işlemi bitirilir[15]. Şekil 2,9'da eğiticili öğrenme yapısı verilmiştir [22].



Şekil 2.9. Danışmanlı öğrenme yapısı [22]

Bu durumda bulunan ağırlıkların değeri sabit olarak alınır ve bir daha değiştirilmez. Giriş çıkış bilgilerinin nasıl sunulacağı ya da nasıl kodlanacağı bir ağı başarılı bir şekilde yönlendirmek için önemli bir unsurdur. Yapay sinir ağları sadece sayısal giriş bilgileri ile çalıştıklarından ham bilgiler genellikle ölçeklendirilmelidir. Danışmanlı öğrenmede performans kriteri hata terimidir. Bu hata terimi ortalama karesel hatadır ve karesel hata toplamlarının beklenen değeridir. Sistem öğrenme işleminin adımları geçildikçe hata terimi azalır. Hata fonksiyonunun minimum olduğu değer iterasyonun durdurulması gereken durumdur. Danışmanlı eğitimin en büyük sakıncası eğitici olmadan ağın yeni bir strateji öğrenme şansı olmamasıdır. Bunu gidermek için takviyeli öğrenme seçeneği sunulmuştur. Takviyeli sistem, ölçümler üzerinden hareket ederek performansı iyileştirmeye çalışır ve ölçümler sistem tarafından desteklenir. Bu nedenle takviyeli sistem hesaplamalı, geri beslemeli sistemdir. Bu sistemde giriş değerlerine karşı istenilen çıkış değerlerinin bilinmesine gerek yoktur. Yani yapay sinir ağına bir hedef verilmeyip elde edilen çıkışın verilen


giriş karşılık uygunluğunu değerlendiren bir ölçüt kullanılmaktadır. Bu sistemin en büyük sakıncası değişikliklerin yapıp sonuçların alınması zaman aldığı için yavaş olmasıdır[16,21]. Şekil 2.10'da takviyeli öğrenme modeli verilmiştir.



Şekil 2.10. Takviyeli öğrenme yapısı [22]

2.6.2. Danışmansız öğrenme

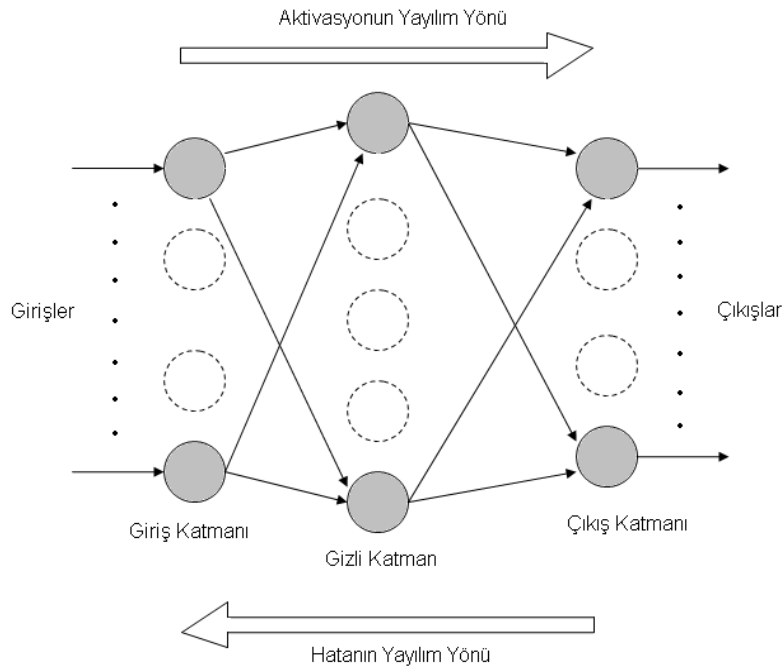
Danışmansız öğrenmede öğrenme işlemi gerçekleştirilen bir eğitici yoktur. Ağ, birbirine benzer giriş bilgilerini gruplamakta veya giriş bilgisinin hangi gruba ait olduğunu göstermektedir. Ağ eğitimi için sadece giriş bilgileri yeterli olmakta, eğitici bilgiye ihtiyaç duyulmamaktadır. Yani ağ performansını kendiliğinden izler. Ağ, giriş sinyallerinin yönüne veya düzenine bakmakta ve ağın fonksiyonuna göre ayarlama yapmaktadır. Rekabete dayalı öğrenme, kendi kendine öğrenme, Hebbian öğrenme kuralı eğitici olmadan öğrenmeye örnek olarak verilebilir [16,21]. Şekil 2.11'de eğitici olmadan öğrenme yapısı gösterilmiştir [22].



Şekil 2.11. Danışmansız öğrenme yapısı [22]

2.7. Çok Katmanlı Perceptron Eğitim Algoritması

Çok katmanlı perceptron sinir ağları, giriş katmanı, çıkış katmanı ve bir veya daha fazla gizli katmandan oluşur. Bu tip sinir ağlarının temel amacı ağın beklenen çıktısı ile ürettiği çıktı arasındaki hatayı en aza indirmektir. Giriş ve çıkış katmanları arasındaki ilave gizli katmanlar ile ağ çok katmanlı olmaktadır. Giriş ve çıkış katmanlarının oluşturulmasından farklı olarak gizli katman sayısı ile ilgili ön bilgi olmadan işleme başlanır. Sadece doğrusal kestirim yapabilen bu ağ karmaşık örüntüleri ayırt edememektedir. Ayrıca gizli katman sayısının fazla olması ağın genelleştirme yapmasını da engellemektedir. Zaten gizli katman sayısının artırılması ağın eğitimi için geçen süreyi de artırır. Burada yapılması gereken deneme yanılma yöntemi ile ağın çıkışı ile arzu edilen çıkış arasındaki hatayı tekrar geriye doğru yayararak minimuma indirilinceye kadar ağın ağırlıklarını değiştirmektir. Böylece uygun olan gizli katman sayısı tespit edilebilir [14,16,21]. Şekil 2.12’de çok katmanlı sinir ağı verilmiştir [4].



Şekil 2.12. Çok katmanlı sinir ağında hata ve aktivasyon yayılımı [4].

Eğitim algoritmaları, yapay sinir ağları uygulamalarında oldukça önemlidir. Bilgi nöronlar arasındaki bağlantıların ağırlıklarında yer alır. Bu nedenle eğitim algoritmaları bilgiye ait olan temsilci örneklerin ardı ardına ağa verilmesine ve ağın bu bilgiyi kendi yapısı içinde bütünleştirmesini sağlar.

2.7.1. Geri yayılım algoritması

Eğitim verileri ağın giriş katmanına uygulandıktan sonra istenen çıktılar çıkış katmanında karşılaştırılır. En son katmanın çıktısı ile istenilen çıktı arasındaki fark genellikle aktarım işlevinin türevi tarafından değiştirilen bir önceki katmana geri yayılır.

Rumelhart ve arkadaşları [24] tarafından sunulan geri yayılım algoritması $\Delta w_{ji}(k)$ şu şekilde ifade edilir:

$$\Delta w_{ji}(k) = -\alpha \frac{\partial E}{\partial w_{ji}(k)} + \mu \Delta w_{ji}(k-1) \quad (4)$$

Bu formülde, öğrenme katsayısı α , eğitim sırasında her bir ağırlığa yapılan ayarlama ile orantılıdır ve ağırlıkların çözüme yaklaşma hızını etkilemektedir. Momentum katsayısı μ , her iterasyon da hesaplanan ağırlık hatasının türevi ile orantılıdır ve uygun değerleri geri yayılım algoritmasının doğru olan minimuma yaklaşmasını sağlamaktadır. $\Delta w_{ji}(k-1)$ ise bir önceki iterasyondaki ağırlık değişimidir. Öğrenme ve momentum katsayılarının uygun değerleri bulunarak çözüm için hızlı ve kararlı yaklaşımların elde edilmesi mümkün olmaktadır. Fakat geri yayılım algoritmasının birçok uygulamada bazı problemleri vardır. En önemli problemlerinden biri, kabul edilebilir ağırlık çözümüne ulaşılabilmesi için geçen eğitim süresinin uzun olmasıdır. Bu nedenle yapay sinir ağlarının eğitimini hızlandırmak için Delta-bar-delta, genişletilmiş delta-bar-delta ve hızlı yayılım eğitim algoritmaları geliştirilmiştir [15,16].

2.7.2. Delta-bar-delta algoritması

Delta-bar-delta eğitim algoritması her bir bağıl değer kendine has kendini uyarlayabilen katsayıya sahip bir öğrenme metodu kullanmaktadır. Ancak geri yayılım modelindeki momentum faktörünü kullanmaz. Eski hata değerlerini gelecek hesaplanmış hata değerlerini tahmin etmekte kullanır. Bu algoritmaya doğrudan uygulanan kurallar ileri doğru lineerdir ve uygulaması kolaydır.

Delta-bar-delta eğitim algoritmasında nöronlar arasında mevcut olan bağlantıdaki değişim $\Delta w_{ji}(k)$ aşağıdaki formülle ifade edilir:

$$\Delta w_{ji}(k) = -\alpha_{ji}(k) \frac{\partial E}{\partial w_{ji}(k)} \quad (5)$$

Her bir bağlantı bağıl değerinin kendi öğrenme oranı vardır. $\alpha_{ji}(k)$ bağlantının öğrenme katsayısıdır. Öğrenme katsayısındaki değişim şu şekildedir:

$$\Delta\alpha_{ji}(k) = \begin{cases} A, & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} > 0 \\ -\varphi_{ji}(k), & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} < 0 \\ 0, & \text{diğer durumlar} \end{cases} \quad (6)$$

Bu öğrenme oranları standart geri yayılım ile birlikte bulunan mevcut hataya bağlı olarak değişir. Bağlantı bağıl değeri değiştiğinde bölgesel hata, çeşitli ardıl zaman adımları için aynı sinyale sahipse öğrenme oranı doğrusal olarak artırılır. Böylece öğrenme oranlarının çok büyük ve çok hızlı hale gelmesini önler. Bölgesel hata sinyallerini sık sık değiştirdiğinde ise öğrenme oranı geometrik olarak azaltılır. Bu da bağlantı öğrenme oranlarının her zaman pozitif olmasını sağlar. Dahası bu oranlar hatadaki değişikliğin büyük olduğu bölgelerde daha hızlı bir şekilde azaltılabilir. Bir ağda her bir bağlantı bağıl değeri için farklı oranlar olmasına izin verdiği için birçok negatif yönde iniş aramasına gerek kalmaz. Bunun yerine bağıl değer kendisi bakımından hatanın kısmi türevi bazında güncelleştirilir [15,16].

2.7.3. Genişletilmiş delta-bar-delta algoritması

Bu modelde delta-bar-delta öğrenme oranı artışına bir üst eksilmesi uygulayıp momentum unsurunu tekrar buna ekleyerek öğrenme oranı ve momentum katsayısına bir ek konulması ile geliştirilmiştir. Her bir bağıl değer için öğrenme oranı ve momentum oranı, bunların artış ve azalmalarının kontrol eden ayrı sabitlere sahiptir. Mevcut hata sinyali bir artışın mı yoksa bir azalmanın mı uygun olduğunu belirtmek için kullanılır. Azalma ayarlaması delta-bar-delta ile aynı şekilde sahipken öğrenme oranı ve momentum oranı artışları tartılmış eğim unsurların büyüklüğünün üst rakamlara dayanarak düşen işlevleri olmak üzere değiştirilirler. Böylece büyük artışlar büyük eğilmelere değil de küçük eğilme alanlarına uygulanarak delta-bar-delta salınım problemine kısmi bir çözüm oluşturulur. Azami sınırlar bireysel bağlantı öğrenme oranları ve momentum oranları üzerine yerleştirilir ve düzeltme özelliği olan hafıza algoritması içerisine kurulur. Eğitim verisinin her bir devir sunumundan sonra biriken hataları değerlendirilir. Eğer hata önceki en az hatadan

daha az ise hafızaya mevcut en iyiler olarak kayıt edilir. Burada kullanılan tolerans değişkeni düzeltme fazını kontrol eder [15,16].

Ağırlıklardaki değişim şu şekilde hesaplanır:

$$\Delta w_{jk}(k) = -\alpha_{ji}(k) \frac{\partial E(k)}{\partial w_{ji}(k)} + \mu_{ji}(k) \Delta w_{ji}(k-1) \quad (7)$$

Burada $\alpha_{ji}(k)$ öğrenme katsayısı, $\mu_{ji}(k)$ momentum katsayısıdır. Öğrenme katsayısındaki değişim şu şekildedir:

$$\Delta \alpha_{jk}(k) = \begin{cases} A_\alpha \exp(-\gamma_\alpha |D_{ji}(k)|), & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} > 0 \\ -\varphi_\alpha \alpha_{ji}(k), & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} < 0 \\ 0, & \text{diğer durumlar} \end{cases} \quad (8)$$

Burada A_α , φ_α ve γ_α pozitif sabitlerdir ve D_{ji} delta-bar-delta algoritmasındaki gibi hesaplanır. Momentum katsayısındaki değişim şu şekildedir:

$$\Delta \mu_{jk}(k) = \begin{cases} A_\mu \exp(-\gamma_\mu |D_{ji}(k)|), & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} > 0 \\ -\varphi_\mu \alpha_{ji}(k), & D_{ji}(k-1) \frac{\partial E}{\partial w_{ji}(k)} < 0 \\ 0, & \text{diğer durumlar} \end{cases} \quad (9)$$

Burada A_μ , γ_μ ve φ_μ pozitif sabitlerdir. Eşitlik 8'den görüldüğü gibi, öğrenme katsayısındaki artış sabit değildir ve ağırlıklı ortalama D_{ji} ifadesinin büyüklüğünün üssel olarak azalan bir fonksiyonudur. Ağırlık değerlerindeki salınımları önlemek için $\alpha_{ji}(k)$ ve $\mu_{jk}(k)$, önceden belirlenmiş α_{\max} ve μ_{\max} üst sınır değerlerinden aşağıda tutulur [4].

BÖLÜM 3. DİYABET HASTALIĞININ TEŞHİSİDE YAPAY SİNİR AĞI MODELİNİN BAŞARIMININ İNCELENMESİ

3.1. Yapay Sinir Ağının Giriş Parametreleri

Bu çalışma, konusunda uzman doktorlar ile yapılan görüşmeler sonucunda diyabet hastalığının teşhisinde belirleyici faktörler olan değerler belirlenerek on yedi nöron olarak seçilmiştir. Bu değerler aşağıdaki gibi belirtilebilir.

- Yaş
- BMI (Vücut kitle oranı)
- Gebelik durumu
- Aile öyküsü
- Açlık kan şekeri
- Toklu kan şekeri
- Üre değeri
- Kreatin değeri
- Total kolesterol
- HDL kolesterol
- LDL kolesterol
- Trigliserit
- HBA1C
- İnsülin değeri
- Sistolik kan basıncı
- Diyastolik kan basıncı

Bu bilgiler doğrultusunda 225 kişiye ait laboratuvar bilgileri kaydedilmiştir. Grup, yaşları 15 ile 82 arasında değişen 126 kadın ve 99 erkekten oluşmaktadır. Sağlık merkezlerinde yapılan muayenelerinde 225 kişiden 150 kişiye diyabet, 75 kişiye de

sağlıklı oldukları yönünde tanı konulmuştur. Diyabet hastası olanların 82 kadarı yaş aralıkları 15 ile 78 olan kadın ve 68 kadarı yaş aralıkları 16 ile 81 olan erkektir. Sağlıklı olan 44 kadının yaşları 24 ile 82 ve 31 erkeğin yaşları 17 ile 77 olup, çalışma grubunun ortalama yaşı 46,88 ve standart sapması 14,49 olmaktadır. Vücut kitle oranı 29,28 ve standart sapması 5,62, açlık kan şekeri 157,08 ve standart sapması 84,96, tokluk kan şekeri 227,70 ve standart sapması 117,48, HbA1-c 7,14 ve standart sapması 2,94, insülin 11,14 ve standart sapması 7,04 olarak tespit edilmiştir.

Bu çalışmada, ölçüt olarak belirlenen değerlere ait parametreler Tablo 3.1'de aşağıdaki gibi verilmiştir.

İsim	Tanım	Tip	Değerler	
			Ortalama	Standart Sapma
Cinsiyet	Erkek/Kadın	Sınıflandırılabilir (0/1)	—	—
Yaş	Kişilerin yaşı	Sayısal	46,88	14,49
BMI (Vücut kitle oranı)	Ağırlık(kg)/ (Boy) ²	Sayısal	29,28	5,62
Gebelik durumu	Gebelikte iri doğum öyküsü	Sınıflandırılabilir (0/1)	—	—
Aile öyküsü	Ailede diyabet hastalığının görülmesi (Evet/Hayır)	Sınıflandırılabilir (0/1)	—	—
Açlık kan şekeri	Açlık kan şekeri (mg/dL)	Sayısal	157,08	84,96
Tokluk kan şekeri	Tokluk kan şekeri (mg/dL)	Sayısal	227,70	117,48
Üre değeri	Üre değeri (mg/dL)	Sayısal	31,52	16,73
Kreatin değeri	Kreatin değeri (mg/dL)	Sayısal	0,90	0,81
Total kolesterol	Kolesterol (mg/dL)	Sayısal	199,56	40,1
HDL kolesterol	HDL kolesterol (mg/dL)	Sayısal	46,1	12,7
LDL kolesterol	LDL kolesterol (mg/dL)	Sayısal	110,04	38,34
Trigliserit	Trigliserit (mg/dL)	Sayısal	159,87	101,32
HbA1-c	HbA1-c (%)	Sayısal	7,14	2,94
İnsülin değeri	Plazma insülin konsantrasyonu (µU/ml)	Sayısal	11,14	7,09
Sistolik kan basıncı	Sistolik kan basıncı (mmHg)	Sayısal	128,68	21,54
Diyastolik kan basıncı	Diyastolik kan basıncı (mmHg)	Sayısal	79,22	9,73


Tablo 3.1. Çalışmada kullanılan yapay sinir ağına ait giriş parametreleri

3.2. Yapay Sinir Ağının Matlab Uygulaması

Yapılan çalışmada yapay sinir ağının oluşturulmasında Matlab 7.0 programına ait Neural Network Toolbox grafik ara yüzü kullanılmıştır. Diyabet hastalığının teşhisi için geri yayılım algoritması ile eğitilen iki gizli katmana sahip dört katmanlı sinir ağı geliştirilmiştir. Bu çalışmada 225 kişiden 135 kişiye ait kayıt sinir ağının eğitimi için geriye kalanları ise sinir ağının testi için kullanılmıştır. Eğitim verisi olarak kullanılan 135 kişinin 45'i sağlıklı, 90'ı diyabet hastasıdır. Test verisi olarak kullanılan 90 kişinin 30'ı sağlıklı, 60'ı diyabet hastasıdır.

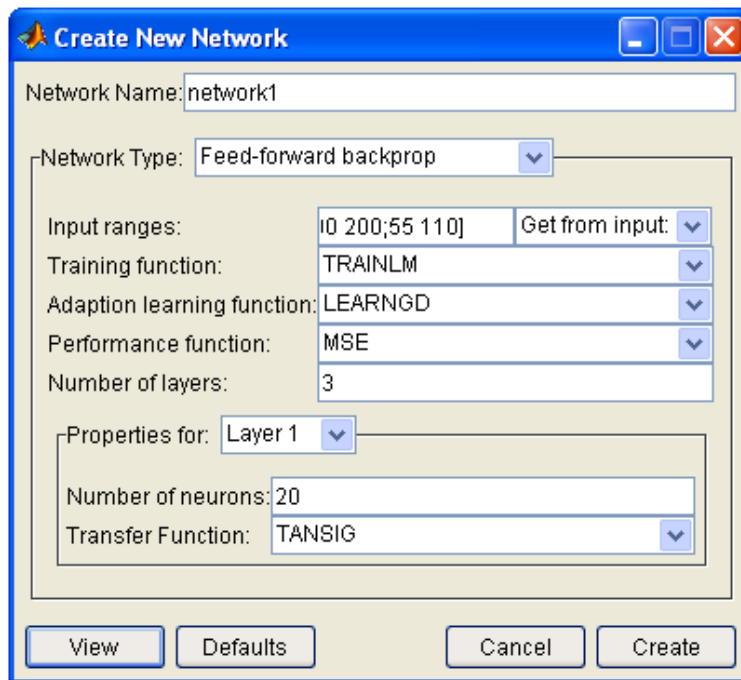
Yapay sinir ağına ait test verilerinin performans analizi üç şekilde yapılmıştır. Birincisi, yapay sinir ağının diyabet hastası olarak belirttiği değerlerin hekim tarafından hasta olarak belirtilen değere oranından elde edilir. İkincisi, yapay sinir ağının sağlıklı olarak belirttiği değerlerin hekim tarafından sağlıklı olarak belirtilen değere oranından elde edilir. Üçüncüsü ise yapay sinir ağının sağlıklı ve diyabet hastası olarak belirlediği değerlerin hekim tarafından sağlıklı ve diyabet hastası olarak belirttiği değere oranından elde edilir.

Bu çalışmada yapay sinir ağına ait katmanlar daha önceki çalışmalar da göz önünde bulundurularak deneme yanılma yöntemi ile elde edilmiştir. Yapılan denemeler sonucunda en sağlıklı sonuçların elde edildiği yapay sinir ağı, iki gizli katmana sahip dört katmanlı yapı olarak belirlenmiştir. Birinci katmanda giriş parametreleri olan on yedi nöron, ikinci (gizli) katmanda yirmi nöron, üçüncü (gizli) katmanda on iki nöron ve son olarak çıkış katmanında kişilerin diyabet hastası veya sağlıklı oldukları bilgisini veren nörondan oluşturulmuştur. Yapay sinir ağına ait model Şekil 3.1'de aşağıdaki gibi verilmiştir.



Şekil. 3.1 Yapay sinir ağı modeli

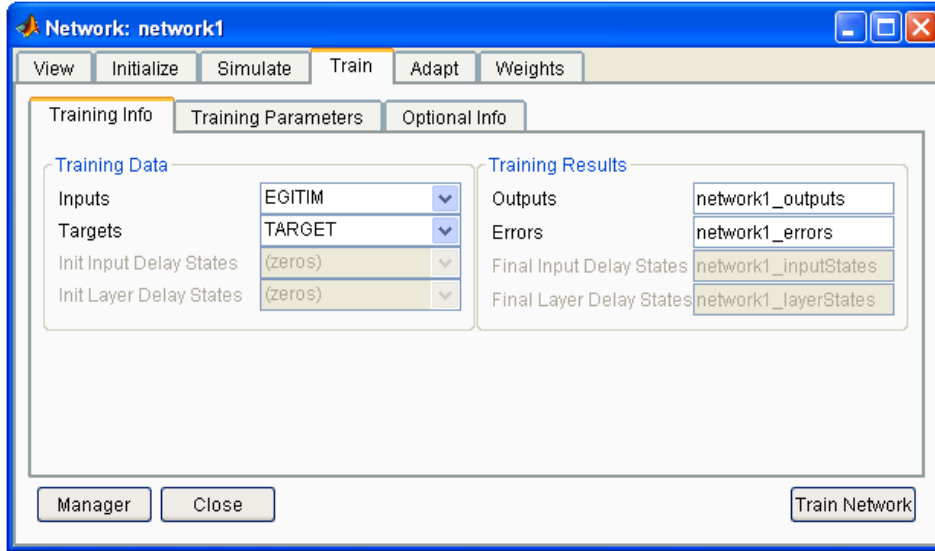
Bu çalışmada geri yayılım algoritması kullanılarak oluşturulan yapay sinir ağında eğitim fonksiyonu olarak Trainlm yani ağı ağırlıkların hesaplanmasında Levenberg-Marquardt eğimi kullanılmıştır. Adaptif öğrenme fonksiyonu olarak Learngd kullanılmıştır. Performans fonksiyonu olarak MSE yani ortalama karesel hata fonksiyonu kullanılmıştır. Transfer fonksiyonu olarak Tansig yani hiperbolik tanjant transfer fonksiyonu kullanılmıştır. Şekil 3.2’de yapay sinir ağına ait fonksiyon bilgileri aşağıda verilmiştir.



Şekil 3.2 Yapay Sinir Ağı Fonksiyon Bilgileri.

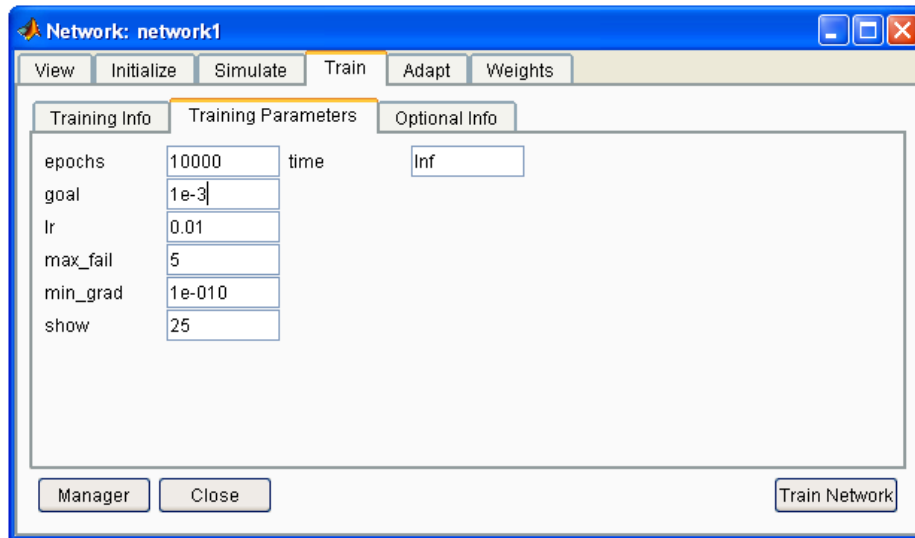
Matlab Neural network toolbox grafik ara yüzü kullanılarak oluşturulan bu yapay sinir ağının eğitimi için; giriş matrisi, hekim tarafından diyabet hastalığı tanısı

konulmuş veya sağlıklı teşhisi konulmuş hastalara ait laboratuvar verilerinden elde edilmiştir. Hedef matris, diyabet hastaları için atanan 1 değeri ile sağlıklı olanlar için atanan 0 değerinin sütun matrisi halinde yapay sinir ağına girilmesi ile elde edilir. Şekil 3.3’de eğitim verilerinin girişi aşağıda gösterilmiştir.



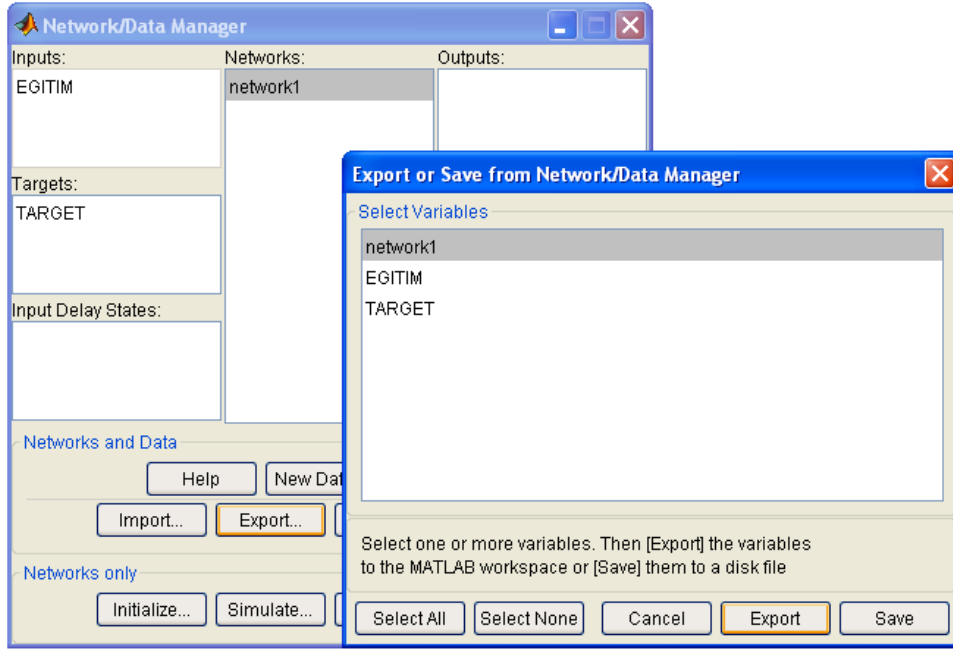
Şekil 3.3 Yapay Sinir Ağına ait Eğitim Bilgileri.

Training Parameters sekmesi altında epochs, iterasyon sayısı ve goal, hedeflenen hata değeri girildikten sonra yapay sinir ağının eğitimi Train Network sekmesi yardımı ile yapılır. Aşağıda verilen Şekil 3.4’de bu adımı görmek mümkündür.



Şekil 3.4 Yapay Sinir Ağına ait Eğitim Parametreleri.

Sonraki adımda, eğitilmiş yapay sinir ağı Şekil 3.5’de verildiği gibi grafik ara yüzünden Matlab workspace’e transfer edilir. Bu sayede komut penceresinde yazılacak olan program ile test verilerinin yapay sinir ağına uygulanması mümkün olacaktır.



Şekil 3.5 Yapay Sinir Ağı'nın transfer edilmesi

Çalışmada 225 kişiden 135' i yapay sinir ağı'nın eğitiminde, 90'ı yapay sinir ağı'nın test edilmesinde kullanılmıştır. Bu veriler doğrultusunda kullanılan yapay sinir ağıları içerisinde en başarılı olanı hakkında bilgiler sonuçlar bölümünde incelenmiştir.

BÖLÜM 4. SONUÇ VE ÖNERİLER

4.1. Sonuç

Yapay sinir ağları her türlü bilgiyi işlemek ve analiz etmek amacı ile kullanılır. Yapay sinir ağı girişleri çıkırları ile ilişkilendirilerek modelleme ve karar verme işlemlerinde kullanılan en önemli araçlardan biridir. Sınırlı ve tamamlanmamış olan veri tabanlarından en iyi sonucu çıkarabilmesi ve farklı eğitim algoritmaları ile eğitilmeleri sonucunda başarı artırılabilir. Bu eğitim algoritmalarından en çok kullanılanı geri yayılım algoritmasıdır.

Literatürde sinir ağlarının eğitiminde kullanılan algoritmaların performanslarını karşılaştıran çalışmalar varken algoritmaları performansları ile ilgili genel bir sonuç belirtilmemektedir. Çünkü bu çalışmaların sonucunda algoritmaların performanslarının çalışılan probleme bağlı olarak değiştiği görülmüştür.

Bu çalışmada 126 kadın ve 99 erkekten oluşan 225 kişiye ait verilerden 135 kişiye ait veri geri yayılım algoritması kullanılarak yapay sinir ağının eğitiminde 90 kişiye ait veri ise eğitilmiş olan ağın test edilmesinde kullanılmıştır. Tablo 4.1 dede görüleceği gibi kesinlik değeri olarak verilen yüzdesel değeri; yapay sinir ağı tarafından 'sağlıklı' sonucu elde edilen 29 kişinin uzman hekim tarafından 'sağlıklı' tanısı konulan 30 kişiye oranından elde edilmiştir ve bu değeri %96,7 dir. Hassasiyet olarak verilen yüzdesel değeri ise; yapay sinir ağı tarafından 'diyabet hastası' sonucu elde edilen 59 kişinin uzman hekim tarafından 'diyabet hastası' konulan 60 kişiye oranından elde edilmiştir ve bu değeri %98,3 dür.

Toplamda yüzdesel başarımları ise, geri yayılım algoritmasının kullanıldığı yapay sinir ağının ürettiği 88 doğru sonucun, uzman hekimlerin 90 kişiye koyduğu tanıya oranından %97,8 olarak elde edilmiştir.

	%	YSA Sonucu	Hekim Görüşü
Kesinlik (Sağlıklı)	%96.7	29 kişi	30 kişi
Hassasiyet (Diyabet)	%98.3	59 kişi	60 kişi
Toplam	%97.8	88 kişi	90 kişi

Tablo 4.1 Geri yayılım algoritmasına ait yapay sinir ağının başarımı

Bu sonuçlar doğrultusunda oluşturulan 17x20x12x1 boyutundaki yapay sinir ağının eğitiminde geri yayılım algoritmasının kullanımının doğru sonuçlar elde etmekte kullanışlı olduğu görülmektedir.

4.2. Öneriler

Yapay sinir ağının giriş katmanını oluşturan ve diyabet hastalığı teşhisi için bu çalışmada kullanılan laboratuvar parametrelerinden bazıları; aile öyküsü, vücut kitle oranı, üre gibi değerler çıkarılabilir. Bunların yerine fizikse aktivite ve bulanık görme gibi değerler eklenerek yapay sinir ağının diyabet hastalığının teşhisindeki başarımı sınanabilir.

Elde edilen bu yeni değerler kullanılarak başka eğitim algoritmaları kullanılarak yapay sinir ağının performansı test edilebilir. Ayrıca diyabet hastalığının çalışmada verileri kullanılan insanların yaşlarına göre dağılımı da incelenebilir.

KAYNAKLAR

- [1] GÜLER, İ., ÜBEYLİ, E.D., “Detection of Ophthalmic Artery Stenosis by Least-Mean Squares Backpropagation Neural Network”, Computers in Biology and Medicine, Vol 33, No 4, 333-343, 2003
- [2] ÜBEYLİ, E.D., GÜLER, İ., “Neural Network Analysis of Internal Carotid Arterial Doppler Signals: Predictions of Stenosis and Occlusion”, Expert Systems with Applications, Vol 25, No 1, 1-13, 2003.
- [3] GÜLER, İ., ÜBEYLİ, E.D., “ECG Beat Classifier Designed by Combined Neural Network Model”, Pattern Recognition, Vol 38, No 2, 199-208, 2005.
- [4] GÜLER, İ., ÜBEYLİ, E.D., “Çok katmanlı perseptron sinir ağı ile diyabet hastalığının teşhisi”, J. Fac.Eng.Arch. Gazi Univ. Vol.21, No 2, 319-326,2006.
- [5] FOSTER, D.W., Diabetes Mellitus, Harrison’s Principals of Internal Medicine, Vol 2., 1979.
- [6] HATEMİ, H., Diabetes Mellitus Tarihçesi, Aktüel Tıp Dergisi, 7:497-499, Kasım 1996.
- [7] DE FRONZO, R., Current Management of Diabetes Mellitus, Mosby-Yearbook Inc, 1-218, 1998.
- [8] İLİÇİN, G., BİBEROĞLU, K., SÜLEYMANLAR, G., ÜNAL, S., Temel İç Hastalıkları. Güneş Kitabevi, cilt 2:2279-2230, Ankara 2003.
- [9] The Expert Committe on the diagnosis and classification of DM: Report of the Expert Committe on the diagnosis and classification of DM. Diabetes Care 27(suupl.1):S:5-10, 2004.
- [10] KING, H., REWERS, M., and WHO ad hoc Diabetes Reporting grup. Global estimates for prevalence of diabetes mellitus and impaired glucose tolerance in adults. Diabetes care 16:157-177, 1993.
- [11] KING, H., AUBERT, RF., HERMAN, WH., Global burden of diabetes . 1995-2025. Diabetes care 21:1414-1431, 1998.
- [12] SATMAN, İ., YILMAZ, C., İMAMOLU, Ş., Diabetes mellitus ve

komplasyonlarının tanı, tedavi ve izlem kılavuzu. Türkiye Endokrinoloji ve Metabolizma Derneği 2007.9.

- [13] NARAYAN, K., BOYLE, J., THOMPSON, T., Lifetime risk for DM in the United States. 1884-1890, JAMA 2003.
- [14] TÜRKER, N., RF/Mikrodalga Düzlemsel İletim Hatlarının Yapay Sinir Ağı ile Analiz ve Sentezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 92s, İstanbul, 2004.
- [15] ELMAS, Ç., Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayıncılık ISBN 975 347 712 4, Nisan 2003.
- [16] ELMAS, Ç., Yapay Zeka Uygulamaları. Seçkin Yayıncılık ISBN 978-975-02-0614-6, Kasım 2007.
- [17] ANZAI, Y., 1992, Pattern Recognition And Machine Learning, Academic Pres Inc.
- [18] LAU, C., Neural Networks Theoretical Foundation And Analysis, IEEE Pres., 1991.
- [19] YOUNG, T., FU K.S., Handbook of Pattern Recognition and Image Processing, Academic Pres. 1997.
- [20] ÖZTEMEL, E., Yapay Sinir Ağları. Papatya Yayıncılık, Ekim 2006.
- [21] SARAÇ, T., Yapay Sinir Ağları. Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı, Seminer Projesi, 71s, Ankara 2004.
- [22] SAĞIROĞLU, Ş., BEŞDOK, E., ERLER, M., Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları. Ufuk Kitap Kırtasiye-Yayıncılık, 2003.
- [23] BOZTOPRAK, H., Wavelet Teorisi ve Uygulamaları. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Semineri, 52s, Isparta 2005.
- [24] RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., "Learning Representations by Back-Propagating Errors", Nature, Vol 323, 533-536, 1986.
- [25] http://www.tiptr.com/dizaynline/brain_anatomy/sekil7.jpg, erişim tarihi 22.11.09.

ÖZGEÇMİŞ

Faruk Açmalı, 04.08.1979 da Karabük'te doğdu. İlk, orta ve lise eğitimini Karabük'te tamamladı. 1995 yılında Karabük Demir Çelik Lisesinden mezun oldu. 1996 yılında başladığı KTÜ Elektrik Elektronik Mühendisliği bölümünü 2000 yılında bitirdi. Askerlik hizmetini tamamladıktan sonra 2002 – 2004 yılları arasında İçdaş Demir Çelik fabrikasında elektrik bakım mühendisi olarak çalıştı. 2004 yılından beri Phoenix Contact firmasında çalışmaya devam etmektedir.