

**T.C.
TRAKYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOSTATİSTİK ANABİLİM DALI
YÜKSEK LİSANS PROGRAMI**

**Tez Yöneticisi
Doç.Dr. Necdet SÜT**

**ÇOK KATMANLI PERSEPTRON YAPAY SİNİR
AĞLARIYLA S GARA ÇEME VE BIRAKMAYA ETKİ
EDEN FAKTÖRLERİN İNCELENMESİ**

(Yüksek Lisans Tezi)

Merve KARABACAK

Edirne 6 2012

**T.C.
TRAKYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOSTATİSTİK ANABİLİM DALI
YÜKSEK LİSANS PROGRAMI**

**Tez Yöneticisi
Doç.Dr. Necdet SÜT**

**ÇOK KATMANLI PERSEPTRON YAPAY SİNİR
AĞLARIYLA S GARA ÇEME VE BIRAKMAYA ETKİ
EDEN FAKTÖRLERİN İNCELENMESİ**

(Yüksek Lisans Tezi)

Merve KARABACAK

Destekleyen Kurum:

Tez No:

Edirne 6 2012

TE EKKÜR

Yüksek lisans eğitimim süresince tecrübelerinden yararlandığım, tezimin yazılması ve verilerin analiz edilmesi için her türlü yardım ve desteğini esirgemeyen değerli hocam Doç. Dr. Necdet SÜTÇÜ'ne sonsuz teşekkürlerimi sunarım.

Merve KARABACAK

Ç İ NDEK İLER

G İ R İ VE AMAÇ.....	1
GENEL B İLG İLER	3
YAPAY S İN İR A LARI.....	3
Yapay Sinir A lar,n,n Tarihçesi.....	4
Yapay Sinir A lar,n,n Özellikleri.....	6
Yapay Sinir A lar,n,n Dezavantajlar,.....	7
Yapay Sinir A lar,n,n Uygulama Alanlar,.....	7
YAPAY S İN İR A LARININ YAPISI VE TEMEL B İLE ENLER	9
Biyolojik Sinir Sistemleri.....	9
Yapay Sinir Hücresi.....	10
Yapay Sinir A lar,n,n Yap,s,.....	15
Yapay Sinir A lar,n,n E ğ itimi ve Testi	15
YAPAY S İN İR A LARININ SINIFLANDIRILMASI.....	16
A Yap,lar,na Göre S,n,fland,rma	16
Ö ğ renme Algoritmalar,na Göre S,n,fland,r,lmas,.....	18
Ö ğ renme Zamanlar,na Göre S,n,fland,r,lmas,.....	19
YAPAY S İN İR A İ MODELLER	20

Yapay Sinir A lar,n,n Ö renme Algoritmalar,.....	20
Çok Katmanlı, Perseptron Yapay Sinir A lar, (Multilayer Perceptron Neural Networks)	23
S GARA KULLANIMINI ETK LEYEN FAKTÖRLER.....	24
GEREÇ VE YÖNTEMLER.....	26
ARA TIRMANIN EKL	26
ARA TIRMANIN YAPILDI I YER VE ZAMAN.....	26
ARA TIRMANIN EVREN VE ÖRNEKLEM	26
VER LER N TOPLANMASI.....	26
VER LER N ANAL Z	27
BULGULAR	28
TARTI MA.....	53
SONUÇLAR.....	55
ÖZET	56
SUMMARY	57
KAYNALAR.....	59
EK LLER L STES	64
TABLolar L STES	66
ÖZGEÇM	67

S MGE VE KISALTMALAR

AUC: ROC e risi alt,nda kalan alan

MLP: Multilayer perceptron (Çok katmanl, perseptron)

NKD: Negatif kestirim de eri

PKD: Pozitif kestirim de eri

YSA: Yapay sinir a ,

G R VE AMAÇ

Günlük hayatta kararlaştırılan olaylar birçok etkeni içinde barındırır. İnsanlar bu olaylar, bazen özellikleri dikkate alınarak sınıflandırır, geneller ve bu genelleme sonucunda, sorunlara daha etkin bir biçimde yaklaşarak doğru anlaşılabilir çözümler üretebilir. İnsan beyni bu özelliğiyle yapay sinir ağları, (YSA) ile benzerlik gösterir. Yapay sinir hücreleri gerçek sinir hücrelerinin simüle edilmesiyle meydana gelir. YSA hücrelerinin birbirine bağlanmasıyla YSA oluşur. YSA normal yolla çözülmesi zor olan problemleri çözmek için tasarlanmıştır, tıbbi ve biyoloji alanlarında yapılan çalışmalarında, veri setleri oldukça karmaşık bir yapıya sahiptir. Veriler üzerinde çalışılmadan önce, bu karmaşık yapının düzenlenmesi gerekmektedir; düzenleme, belirlenen amaç doğrultusunda sınıflandırma yapılarak, mümkün olmaktadır (1).

Sınıflama, bilimsel çalışmalarda sorunların çözümünde sağladığı fayda nedeniyle oldukça sık başvurulan bir yöntemdir. Tıbbi alanlarda, hastalıkların sınıflandırılması ve bu sınıflandırmaya göre tedavi yöntemlerinin geliştirilmesi en belirgin örneklerdendir. Tıbbi alanlarda diğer bilim dallarında da sınıflandırma işlemi görülebilmektedir. YSA ile sınıflandırma; ağ yapılarına göre, öğrenme algoritmalarına göre ve öğrenme zamanlarına göre olmak üzere 3 ayrı dalda incelenir. Çalışmada kullanılacak olan YSA ile sınıflandırma, verilerin doğru atanmasında, güvenilir sonuçlar elde edilmesinde, elde edilen bilgilerden daha fazla fayda sağlanabilmesinde önemli rol oynar. YSA bilgi sınıflama ve bilgi yorumlamada içinde bulunduğu çok dilli problemlerin çözümünde kullanılmayan, sınırlı sayıda birçok alanda var olan yöntemlerin yerine başarıyla uygulanmaktadır (2). Yayınlanan bazı kaynaklar bazen, YSA modelleri ile bazı istatistik tekniklerin aynı olduğunu, bu iki alanın birbirleriyle ilişkileri

derecede ili kili oldu unu göstermi tir. YSA modelleri ile istatistik tekniklerin kar ,la t,r,lmas, birinin di erinin geli tirilmesinde önemli oldu unu ortaya ç,karm, t,r.

Perseptron, çok katmanl, perseptron gibi baz, YSA modelleri istatistiksel uygulamalar için faydal, olabilece i ve ayn, ekilde tahmin ölçütü, güven aral,klar,, tan,lama (diagnostic) ölçütleri gibi baz, istatistiksel tekniklerin de YSA uygulamalar,nda kullan,labilece i baz, bilim adamlar, taraf,ndan ileri sürülmektedir. YSA ve istatistiksel metodoloji aras,ndaki ileti imin geli tirilmesi her iki alan için de büyük yarar sa lamaktad,r (3).

Bu ara t,rmada çok katmanl, perseptron YSA yöntemiyle sigara içenleri, b,rakanlar, ve içmeyenleri, olas, faktörlere göre s,n,fland,rnak ve YSAØar,n performanslar,n, de erlendirmek amaçlanm, t,r.

GENEL B LG LER

YAPAY SINIRLAR

Yapay sinir a , (YSA) insan beyninin özelliklerinden olan ö renme, yeni bilgiler olu turabilme ö rendiklerini güncelleyebilme ve ke fedebilme gibi yetenekleri yard,m almadan otomatik olarak gerçekle tirebilen bilgisayar sistemleridir (6).

nsan beyninin taklit edilmesiyle olu an bu yap,lar nonosaniyeler içinde i lemleri yerine getirirken, insan beyni i lemleri milisaniyeler içinde gerçekle tirmektedir. Buna ra men karma ,k e le tirmelerin hassasl , ve yap,sal esnekli i ile gün geçtikçe uygulama alanlar, geni lemektedir (4).

YSA, istenen sistem performans,n, gerçekle tirebilen bir kontrol emas,n, ö renebilmek için uygun a ,rl,k ba lant,lar,yla kendi kendilerini biçimlendirirler (5).

YSA, lineer olmayan, sisteme ait bilginin tam olmad , veya hatal, oldu u sistemlerde çözüme ula mak için uygundur. Son y,llarda pek çok bilim dal,nda karma ,k problemlere çözüm üretmeleri YSA'na olan ilgiyi artt,rm, t,r. YSA'n, en önemli dezavantaj, ise var olan bir uzman bilgisinin problem çözümüne aktar,lmas,ndaki zorluktur (6).

YSA hücrelerinin birbirine ba lanmas,yla olu an bir YSA ö renme süreciyle performans,n, artt,rabilmektedir. Ö renme algoritmalar, a ,n istenen modele ula mas,n, sa layan fonksiyonlardan olu maktad,r. YSA sinir hücreleri aras,ndaki ba lant,lar,, e ik de erleriyle ve a yap,s, gibi parametreleri kullanarak farklı ayarlar yap,p e itim gerçekle tirir. YSA'da sinir a lar,ndaki bellek ve i lemci paralel olarak çal ,r. Bilgi sinir hücreleri aras,ndaki ba lar,da da saklanabilir veya de i tirilebilir. YSA çal, t , sürece ö renme, depolama ve bilgileri güncelleme yetene ine sahiptir (7,8,9).

Yapay Sinir A lar,n,n Tarihçesi

nsan beyninin nas,l çal, t, , ve fonksiyonlar, uzun y,llar ara t,r,lm, t,r. 1940'dan önce Helmholtz, Pavlov, Poincare gibi baz, bilim adamlar,n,n YSA kavram, üzerinde çal, t,klar, bilinmektedir. Ancak bu çal, malar,n matematiksel bir taban, yoktur. 1940'l, y,llarda McCulloch ve Pitts, Hebb, Rosenblatt gibi bilim adamlar,n,n bu konudaki çal, malar, YSA çal, malar,n,n mühendislik alan,na kaymas, ve günümüzdeki YSAø,n,n temelini olu turmaya ba lad,lar (6).

1943 y,l,nda bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, Sinir Aktivitesinde Dü üncelere Ait Bir Mant,ksal Hesap" ba l,kl, bir makale ile ilk dijital bilgisayarlara , ,k tutmu tur. Bu çal, ma modellemeye yönelik ara t,r,malar,n dönüm noktas,d,r (8,9).

1948 y,l,nda Wiener öCyberneticsö isimli kitab,nda, sinirlerin çal, mas,n, ve davran, özelliklerini ele alm, t,r. 1949'da ise, Donald Hebb öOrganization of Behaviorö isimli kitab,nda, ö renme ile ilgili temel teoriyi ele alm, t,r. Hebb, yapay hücrelerden olu an bir YSAø,n,n de erlerini de i tiren bir ö renme kural, geli tirmi tir (6,8,9).

John Von Neumann, Warren McCulloch ve Walter Pitts'ın yazm, oldu u makaleyi, öelektronik beyinlerö için bir kopya olarak görmü tür. John Von Neumann vakum tüplerini ve telgraf rölelerini kullanarak basit sinir i levlerini taklit etmeyi önermi tir (10,11).

1951 y,l,nda ilk neuro-bilgisayar üretilmi tir.1954'te Minsky taraf,ndan test edilmi tir (6).

Marvin Minsky, Hebb kuram, ile birlikte makroskobik zeka kavram,n, ortaya atm, ve uzman sistemlerin do mas,n, sa lam, t,r. Fank Rosenblatt, Bronx Yüksek Bilim Okulu'nda gözün hesaplamalar, ile ilgilenmi tir. Bu bilim adamlar, ö renme ve zeka konusunu bilgisayar simülasyonlar,nda nas,l koruyabileceklerini 1956'da düzenlenen ilk yapay zeka konferans,nda tart, m, lard,r (8,9).

1958'de Rosenblatt, nöron benzeri "Perception" denen elemanlar, ortaya koymu tur. Bu önemli bir geli medir. Çünkü bu model, daha sonralar, geli tirilecek ve YSA'nda devrim niteli inde olacak olan çok katmanl, alg,lay,c,lar,n temelini olu turmaktad,r (6,10).

1959'da Stanford üniversitesinden Bernard Widrow "ADALINE" olarak adland,r,lan bir adaptif lineer eleman, geli tirmi tir. ADALINE ve iki tabakal, biçimi olan "MADALINE" ses tan,ma, hava tahmini, karakter tan,ma ve adaptif kontrol gibi çok çe itli uygulamalar için kullan,lm, t,r. Bu çal, mayla YSA ilk defa gerçek bir probleme uygulanm, t,r (10).

1970'lerin ilk ba lar,nda Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, ö renme ve birle ik haf,zalar üzerine çal,malar yap,lm, bu çal,malar dan, mans,z ö renme metotlar,n,n geli mesine , ,k tutmu tur (8,9).

YSA ile ilgili 1969-1982 y,llar, karanl,k bir dönem olarak görölmektedir.1969 y,l,nda Minsky ve Papert'in yapm, oldu u çal,ma ile yap,n,n XOR lojik problemlere çözüm getiremedi inden YSA'ya olan ilgi azalm, ve karanl,k bir dönemin ba lang,c, olmu tur (6,11).

1974 y,l,nda Werbos, Geri Yay,lmal, algoritmay, tan,tm, t,r (8,9). Willshaw ve Malsburg 1976 y,l,nda öz düzenlemeli harita ad,nda kümeleme algoritmas,n, kurmu tur. 1982 y,l,nda Kohonen, öz düzenlemeli harita kuram,n, beyindeki olu umlar,n kar ,la t,rmal, haritas,n, ç,karabilmek için ortaya koymu tur (8,9).

Hopfield, 1982 y,l,nda moleküler biyolojiden beyin kuramc,l, ,na geçi yapan bir model geli tirmi tir. Günümüzde kendi ad,yla an,lan bir a yap,s, mevcuttur ve bu yap, birçok alanda uygulanm, t,r (10,12).

1986 y,l,nda, Rumelhart, 1974'te Werbos taraf,ndan bulunan çok katmanl, perseptron tipli geri yay,l,ml, algoritma denilen bir e itim algoritmas, geli tirmi tir. Bu algoritma güçlü olmakla birlikte oldukça karma ,k matematik esaslara dayanmaktayd,. Bu algoritman,n etkin bir ö renmeyi mümkün k,лма yetene i dikkatleri üzerine çekmi tir. Günümüzde dahi en çok kullan,lan ö retim sistemlerinden biri olan bu algoritman,n ortaya ç,kar,lm,as, YSA alan,nda ç, ,r açm, t, (13,14).

1987 y,l,nda ilk YSA sempozyumu yap,lm, sonras,nda uygulamalar artmaya ba lam, t,r.

1988'de Broomhead ve Lowe Radyal Tabanlı, Fonksiyonlar (Radial Basis Function - RBF) modelini geli tirdiler. Bu a ,n çok katmanl, perseptronlara alternatif olarak geli tirildi ini belirttiler. Özellikle filtreleme problemlerine oldukça ba ar,l, sonuçlar ürettiler. 1988'de Spect bu a lar,n daha geli mi ekli olan Probabilistik Sinir A lar, (Probabilistic Neural Networks - PNN) ve 1991'de Genelle tirilmi Regresyon Sinir A lar, (General Regression Neural Networks - GRNN) geli tirildi (6).

1991'den günümüze bu alanda birçok ara t,rma grubu bulunmakta olup farklı alanlarda farklı ara t,rmac,lar bu konuda çal, maktadı,r. Günümüzde sinir sistemi tabanlı, i lemciler olu turulmakta ve komplike problemlerin çözümüne yönelik uygulamalar geli mektedir. K,sacas,, bu alan günümüzde bir geçi dönemi içinde oldu u görölmektedir.

Yapay Sinir Ağlarının Özellikleri

Paralellik: Bilgisayarlar beyne göre çok hızlı, çalışmasıyla beraber beynin toplam hızı, bilgisayara göre çok yüksektir. Bilgisayarda işlemler seri bir düzen içerisindeyken YSA'da işlemler doğrusal değildir. YSA'da işlemler bütün ağa yayılmış, durumdadır. Bu sistemin eş zamanlı çalışmasıyla hız çok artmaktadır. Bu sayede doğrusal olmayan karmaşık problemlerinde çözümlenmesi mümkündür (12,15).

Öğrenilebilirlik: YSA ile sisteme önceden girilen örnekler kullanılarak ağlar, saptanmasıyla beraber her yeni çalışma bu öğrenme işlemi yenilenebilmektedir. YSA ağlar, ve bağlantılar, verilmese bile örneklerle kendini geliştirerek gerekli verileri oluşturabilir (12,15).

Hata Tolerans, YSA, paralel yapı, sayesinde ağın sahip olduğu bilginin tüm bağlantılara yayılmasıyla beraber çalışmaktadır. Ağın kısmen zarar görmesi halinde sistem çalışmaya devam eder. Yani hatayı, tolere etme yetenekleri yüksektir (12,15).

Uygulanabilirlik: Bir problemi çözmek için verilen sınırları, problemler ve koşullar farklılaştığında kendi kendini organize edebilme ve öğrenilebilirlik yeteneklerine sahiptirler. Bu özellik örnek tanıma, sinyal işleme, sistem tanımlama, denetim gibi alanlarda etkin olarak kullanılmaktadır (12,15).

Genelleme: Eğitim sonrasında, eğitim sırasında karşılaşılmayan test örneklerini de değerlendirip, arzu edilen tepkiler üretilebilir. Örneğin, karakter tanımlamada bozuk karakterlerin girişlerinde doğru karakterlerin elde edilmesi mümkündür (12,15).

Yerel Bilgi İşleme: YSA problemin tümü ile ilgilenmek yerine parçaları ile ilgilenilebilmesi ve görev paylaşımı, sayesinde çok karmaşık ve zor problemler çözülebilmektedir (17).

Gerçekleme Kolaylığı: Karmaşık fonksiyonların yerine basit işlemlerin kullanılması, gerçekleştirme kolaylığıyla beraber çalışmaktadır (17).

Donanım ve Hız: YSA, paralel yapı, sayesinde entegre devre teknolojisiyle gerçekleştirilebilir. Bu özellik, hız, bilgi işleme yeteneğini arttırmaktadır (15,16).

Yapay Sinir Ağlarının Dezavantajları,

YSA'ya eğitilebilmesine ve test edilebilmesine yetecek genlikte veri setine ihtiyaç duyulur. Bununla birlikte, yeterli veri seti genliği için kesin bir kriter yoktur, bu kriter uygulamaya bağlı olarak değişir. Dezavantaj sayılabilecek diğer bir nokta ise basit olarak görülebilecek modelleme yapılarına rağmen uygulamanın zor ve karmaşık olabilmesidir. Bazı durumlarda, bir yakınsama sağlamak bile imkansız olabilmektedir. Fakat bu durum da uygulama alanına bağlıdır. Genellikle çok karmaşık problemlerde ortaya çıkmaktadır (17).

Yapay Sinir Ağlarının Uygulama Alanları,

YSA eksik bilgilerle çalışabilme ve karmaşık problemlere çözüm üretebilme yetenekleri sayesinde birçok alanda başarıyla uygulanabilmektedir. Genel olarak uygulama alanları aşağıdaki gibidir.

Tıbbi uygulamalar: EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu, hastalıkların nedenlerinin belirlenmesi ve sınıflandırılması, genetik ve kan örnekleme haritalarının oluşturulması gibi konularda uygulanmaktadır (8,18).

Arıza analizi ve tespiti: Bir sistemin, cihazına da elemanının düzenli (doğru) çalışmasını sağlayan bir YSA yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanmasını olmaktadır. Bu amaçla YSA'lar elektrik makinelerinin, uçaklarına da bileşenlerinde v.b arıza analizinde kullanılmaktadır (18).

Finansal uygulamalar: Makro ekonomik tahminler, kredi kartı hilelerinin tespiti, kredi kartı kurumlarında iflas tahminleri, banka kredilerinin değerlendirilmesi, emlak kredilerinin yönetilmesi, döviz kuru tahminleri, risk tahminleri v.s örneklerde uygulama alanı bulunmaktadır (6).

Savunma sanayi uygulamalar,: Silahlar,n otomasyonu ve hedef izleme, nesneleri/görüntüleri ay,rma tan,ma, yeni alg,lay,c, tasar,m, ve gürültü önleme gibi alanlarda uygulanmaktad,r (18).

Haberle me uygulamalar,: Görüntü ve veri s,k, t,rma, otomatik bilgi sunma servisleri, konu malar,n gerçek zamanda çevirisi gibi alanlarda uygulanmaktad,r (14).

Üretim uygulamalar,: Üretim sistemlerinin optimizasyonu, ürün analizi ve tasar,m,, ürünlerin kalite analizi ve kontrolü, planlama ve yönetim analizi gibi alanlarda kullan,lmaktad,r (18).

Otomasyon ve kontrol uygulamalar,: Uçaklarda otomatik pilot sistemi otomasyonu, ula ,m araçlar,nda otomatik yol bulma ve gösterme, robot sistemlerin kontrolü, do rusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü gibi alanlarda uygulanmaktad,r (18).

Farklı alanlardaki uygulamalar incelendi inde YSA'n,n genel olarak tahmin, s,n,fland,rma, veri ili kilendirme, veri filtreleme, tan,ma ve e le tirme, te his, yorumlama fonksiyonlar, gerçekte tirmek amac,yla kullan,ld,klar, görülmektedir (6).

Tahmin: Bu amaçla kullan,lan YSA, a a sunulan bilgilerden yararlanarak kar ,l,k gelen ç,kt, de erlerini tahmin etmektedirler.

S,n,fland,rma: Bu amaçla kullan,lan YSA, kendilerine verilen bilgileri kategorize etmek görevini üstlenmektedirler.

Veri ili kilendirme: Bu amaçla e itilen a lar, a a sunulan verilerin hatal, olup olmad,klar,n, belirlemektedir. Ö rendikleri bilgiler ile eksik bilgileri tamamlamaktad,r,lar.

Veri filtreleme: Bu amaçla e itilen a lar, birçok veri aras,ndan uygun verileri belirleme görevini yerine getirmektedir.

Tan,ma ve e le tirme: De i ik ekil ve örüntülerin tan,nmas,, eksik, karma ,k, belirsiz bilgilerin i lenerek e le tirme ve tan,ma fonksiyonlar,n, gerçekte tirebilmektedir.

Te his: Bu amaçla geli tirilen a lar, sistemlerin olumsuzluklar,n,n ortaya konulmas, ve problemlerin belirlenmesi i lemini yerine getirmektedirler.


Yorumlama: Bir olay hakk,nda toplanan örneklerden elde edilen ve e itim sonucu olu turulan bilgileri kullanarak yeni olaylar,n yorumlanmas, i lemleri bu kapsamda dü ünülmektedir.

YAPAY S N R A LARININ YAPISI VE TEMEL B LE ENLER

Biyolojik Sinir Sistemleri

nsan beyni, sinir sisteminin merkezini olu turan temel elemand,r. Verilerin al,nmas,, yorumlanmas, karar verilerek gerekli yerlere iletir (8).

D, ar,dan veya ba ka bir organdan gelen sinyaller (uyar,) al,c,lar yoluyla sinir a lar,na iletilir. Sinyaller burada i lemden geçirilerek ç,kt, sinyaller olu tururlar. Olu turulan sinyaller iletici yoluyla d, ortama ya da di er organlara iletilir. Temel yap, ta , sinir hücreleridir (ekil 1). Sinir hücreleri (nöronlar) dendrit, akson, çekirdek ve ba lant,lar (sinaps) bölümlerinden olu maktad,r. Dendrit sinir hücrelerinin ucunda bulunur. A aç kökü görümüne sahiptir. Dendritlerin görevi ba l, oldu u di er nöronlardan veya duyu nöronlar,ndan gelen sinyalleri çekirde e iletmektir. Çekirdek dendrit taraf,ndan gelen sinyalleri bir araya toplayarak aksona iletir. Toplanan bu sinyaller akson taraf,ndan i lenerek nöronun di er ucunda bulunan ba lant,lara gönderir. Ba lant,lar yeni üretilen sinyalleri di er nöronlara iletir (17).



ekil 1. Biyolojik sinir hücresinin yap,s,

Yapay Sinir Hücresi

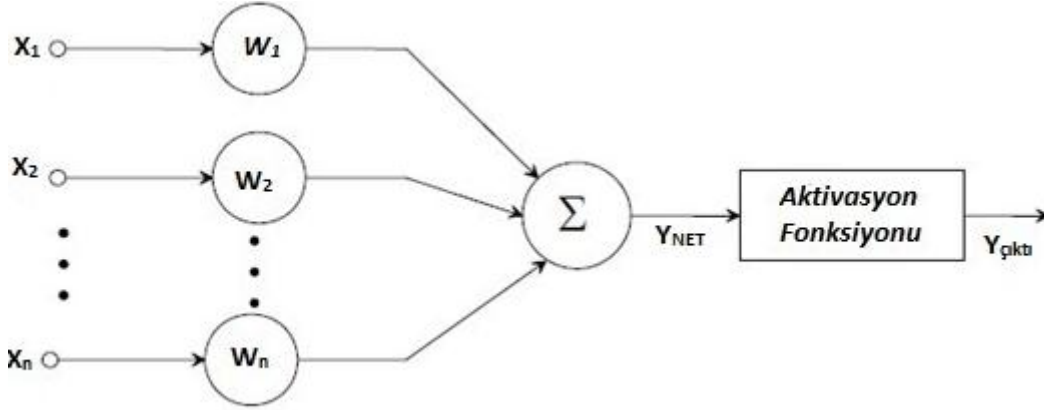
Bir YSA birbiriyle bağlantılı, çok sayıda yapay sinir hücresinden meydana gelmektedir. YSA da, birbirine bağımlı, doğrusal ve/veya doğrusal olmayan birçok elemandan oluşmaktadır. Yapay sinir hücreleri biyolojik sinir hücrelerinin basit bir modelidir. Biyolojik sinir sistemi ile YSA arasındaki benzerlikler aşağıdaki Tablo 1'deki gibidir (6,19).

Tablo 1. Biyolojik sinir ağı, ve yapay sinir ağı,nın karşılaştırılması,

Biyolojik Sinir Sistemi	Yapay Sinir Ağı,
Nöron	Algılayıcı, (Perseptron, Yapay Sinir Hücresi)
Dendrit	Toplama üyesi
Hücre Gövdesi	Etkinleştirme üyesi (Aktivasyon Fonksiyonu)
Aksonlar	Algılayıcı, (İlhamcı elman) çıkışı,
Sinapslar	Ağırlıklar

Hücreler, YSA'nın çalışmasında en küçük bilgi üyesi birimleridir. Yapay sinir hücresine her bir diğer sinirlerin çıkışları, göstermek üzere bir giriş kümesinden oluşur.

Her bir giri a ,rl,klarla çarp,lr. Bütün bu a ,rl,kl, giri ler ise nöronun aktivasyon düzeyini belirlemek için toplan,r.



ekil 2. Yapay sinir hücresinin yap,s,

Yukar,daki ekil 2 incelendi inde toplam a ,rl,kl, Y fonksiyonu ele al,n,rsa w ifadeleri x giri lerindeki a ,rl,klar, belirlemektedir. A ,rl,kl, toplam matematiksel olarak a a ,daki formülde ifade edilmi tir.

$$Y_{NET} = w_1x_1 + w_2x_2 + \dots + w_nx_n = \sum_{j=1}^n w_jx_j$$

Girdiler: Girdiler taraf,ndan bir yapay sinir hücresine bir ba ka yapay sinir hücresinden veya d, dünyadan bilgi al, , yap,lr. Bunlar a ,n ö renmesi istenen örnekler taraf,ndan belirlenir.

A ,rl,klar: A ,rl,klar, gelen bilgilerin hücre üzerindeki etkisini belirleyen de erlerdir. Bilgiler, ba lant,lar üzerindeki a ,rl,klar üzerinden hücreye girmektedir. Bir hücre e anl, olarak birçok girdi al,r. Her girdinin kendi nispi a ,rl, , (girdilerin matematiksel katsay,s,) vard,r. A ,rl,klar de i ken veya sabit de erler olabilirler. Baz, girdiler di erlerine göre daha önemli hale gelirler. Bu sayede, i lem eleman,n,n sinirsel tepki üretmesi i leminde daha fazla etkili olurlar (6,17).

Toplama fonksiyonu: Toplama fonksiyonu, bir hücreye giren net girdiyi hesaplar. Net girdi giri lerin ilgili a ,rl,klar ile çarp,m,lar,n,n toplam,d,r. Toplama fonksiyonu a yap,s,na göre de i erek maksimum alan, minimum alan ve ya çarp,m fonksiyonu ekinde

olabilir. Toplama fonksiyonu genellikle deneme yan, lma yoluyla bulunmaktad, r. Bazen ayn, YSAØ içindeki i lemci elemanlar, n baz, lar, ayn, toplama fonksiyonunu, di erleri ise ba ka fonksiyonlar, kullan, labilirler. Bu tamamen tasar, mc, n, n kendi karar, na ba l, d, r (6).

Transfer fonksiyonu (Aktivasyon fonksiyonu): Transfer fonksiyonu toplama fonksiyonunda elde edilen net girdiyi bir i lemden geçirerek bir ç, kt, ya dönü türür. Bu fonksiyon genelde do rusal olmayan fonksiyondur. Do rusal fonksiyonlar, n tercih edilmemesinin nedeni, do rusal fonksiyonlarda girdi ile ç, kt, n, n do ru orant, l, olmas, d, r. Bu durum ilk YSA denemelerinin ba ar, s, zl, kla sonuçlanmas, n, n temel nedenidir (20). Ama do rusal olmayan transfer fonksiyonlar, n, n da kullan, lmas, ile YSA daha karma , k problemlere uygulanmaya ba lanm, t, r.

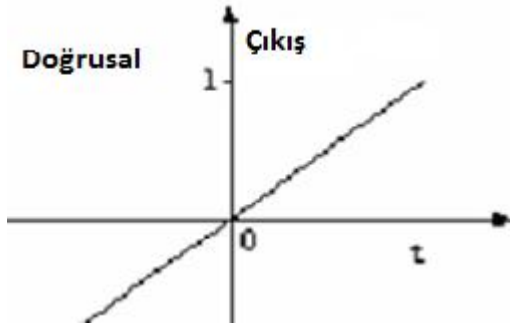
Fonksiyonun seçimi, YSAØn, n verilerine ve neyi ö renmesinin istendi ine de ba l, d, r. Aktivasyon fonksiyonu olarak en çok kullan, lanlar sigmoid fonksiyon ve hiperbolik tanjant fonksiyonlar, d, r.

Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi dönü türerek istenilen de erler aras, nda s, n, rland, rmaktad, r. Bu de erler kullan, lan aktivasyon fonksiyonun tipine göre genellikle [0,1] veya [-1,1] aras, ndad, r. Bu de er aktivasyonun fonksiyonunun, dolay, s, yla yapay sinir hücresinin ç, kt, de eri olarak ya d, ortama ya da girdi olarak ba ka bir yapay sinir hücresine iletilmektedir.

Aktivasyon fonksiyonu i lemi öncesinde sisteme tekdüze da , lm, bir rassal hata eklenebilmektedir. Bu rassal hatan, n kayna , ve büyüklü ü sistemin ö renme sürecinde belirlenir ve sebebi, insan beyninin i levinin, içinde bulundu u ortam, n ko ullar, ndan etkilenmesidir. Ancak günümüzde rassal hata i levi tam olarak kullan, lmamakta ve hala bir ara t, rma süreci içinde bulunmaktad, r. Ayr, ca baz, YSA, aktivasyon fonksiyonunun ç, kt, s, üzerinde ba ka i lemler, ölçeklendirme ve s, n, rland, rma yap, labilmektedir (17).

1-Do rusal aktivasyon fonksiyonu: Do rusal hareket fonksiyonlar, do rusal bir problemi çözmek amac, yla ya da katmanl, YSAØn, n ç, k, katman, nda kullan, labilir. Bu fonksiyon, gelen net girdileri do rudan hücre ç, k, , olarak vermektedir (ekil 3). Formülü a a ,daki ekildedir.

$$f(x) = x$$



ekil 3. Doğrusal aktivasyon fonksiyonunun ekilsel gösterimi

2- Ad,msal fonksiyonu (Keskin sınırlayıcı): Gelen net girdi değerinin belirlenen bir eşik değerinin altında ya da üstünde olmasına göre hücrenin çıktı, 1 veya 0 değerlerini almaktadır (ekil 4).

$$F(x) = \begin{cases} 0 & x < x_0 \\ 1 & \text{diğer} \end{cases}$$




ekil 4. Ad,msal fonksiyonunun ekilsel gösterimi

3-Sigmoid aktivasyon fonksiyonu: Sigmoid aktivasyon fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle uygulamada en çok kullanılan aktivasyon fonksiyonudur (ekil 5). Bu fonksiyon, net girdinin her değeri için 0 ile 1 arasında bir değer üretmektedir ve formülü aşağıdaki gibidir.

$$Y = F(s) = \frac{1}{1 + e^{-s}}$$

Fonksiyonun matematiksel ifadesinde e im parametresi de vardır. Bu katsayının değeri arttıkça, fonksiyon e ik fonksiyonuna yaklaşır. Fonksiyonun türevinin alınabilir

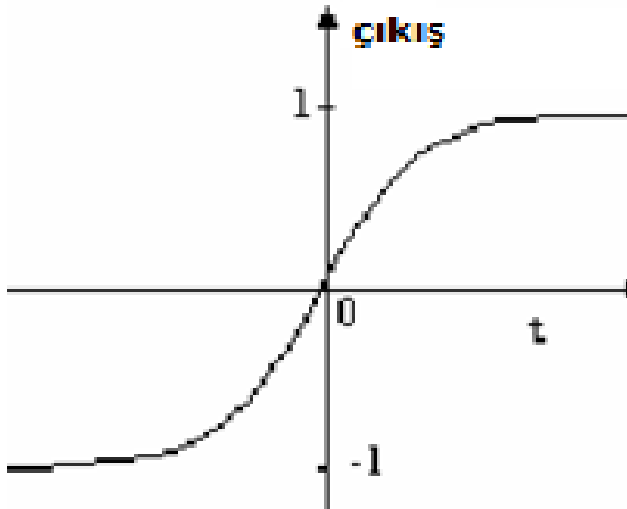
olması, dönüşümün analitik kontrolünü kolaylaştırmaktadır. Özellikle en küçük kareler metodunda öğrenme algoritmaları için fonksiyonun türevine ihtiyaç duyulur. Bu sebeple sigmoid fonksiyonu tercih edilir.



ekil 5. Sigmoid aktivasyon fonksiyonunun ekilsel gösterimi

4- Hiperbolik tanjant fonksiyonu: Hiperbolik tanjant fonksiyonu, gelen net girdinin tanjant fonksiyonundan geçirilmesi ile hesaplanmaktadır. Sigmoid aktivasyon fonksiyonunun farklı bir çeşididir. Sigmoid aktivasyon fonksiyonunda çıktı, 0 ile 1 arasında bir değer alırken, hiperbolik tanjant fonksiyonunda çıktı, -1 ile 1 arasında değişir (ekil 6). Hiperbolik tanjant fonksiyonu aşağıdaki formül yardımıyla hesaplanır (9).

$$Y = F(s) = \frac{e^s + e^{-s}}{e - e^{-s}}$$



ekil 6. Hiperbolik tanjant fonksiyonunun ekilsel gösterimi

Hücrenin ç,kt,s,: Aktivasyon fonksiyonu taraf,ndan belirlenen ç,kt, de eridir. Bu de er ya ba ka bir yapay sinir hücresine girdi olarak ya da d, ortama gönderilmektedir. Nöronun bir ç,kt,s, olmas,na ra men bu ç,kt, istenilen say,da nörona ba l, olabilir (6).

Yapay Sinir A lar,n,n Yap,s,

YSA, yapay sinir hücrelerinin bir araya gelmesiyle olu ur. Yapay sinir hücreleri genellikle birbiriyle ba lant,l, 3 katman halinde ve her katman içinde birbirine paralel olacak ekilde bir araya gelerek a , olu turduklar, görülür. Bu 3 katman, girdi katman,, ara katman ve ç,kt, katman, olarak adland,r,l,r (6).

Girdi katman,, d, ortamdan bilgileri alarak ara katmanlara iletmekle görevlidir. Bu katmanda veriler herhangi bir i leme tabi tutulmadan girdileri ile ayn, de erde ç,kt, üretir (6,21).

Ara katman, girdi katman,ndan gelen bilgileri i leyerek ç,kt, katman,na iletmekle görevlidir. Gizli katman olarak da adland,r,lan ara katman birden fazla olabilmektedir. Ara katmanlar çok say,da yapay sinir hücresi içermektedirler ve bu hücreler YSAø içindeki di er hücrelerle ba lant,l,d,rlar (6).

Ç,kt, katman,, ara katmandan gelen i lenmi bilgileri d, ortama aktarmakla görevlidir. Ç,kt, a yap,s,nda bulunan fonksiyona ba l,d,r. lemler gerçekte tirilir ve birimler kendi ç,kt,lar,n, üretir (6,22).

Yapay Sinir A lar,n,n E itimi ve Testi

YSAønda i lemci elemanlar aras,ndaki ba lant,lar,n a ,rl,k de erlerinin de i tirilmesi i lemne öa ,n e itilmesiö denilmektedir. Ba lang,çta rastgele atanan bu a ,rl,k de erleri, a a gösterilen örneklerle de i tirilmektedir. Amaç, a a gösterilen örnekler için do ru ç,kt,lar, üretecek a ,rl,k de erlerinin belirlenmesidir. YSAø,n e itilmesinde kullan,lan girdi ve ç,kt, çiftlerinden olu an verilerin tümüne öe itim setiö ad, verilmektedir (6).

YSAø,n e itim süreci, belli kurallar çerçevesinde olmaktadır. Bu kurallara ö renme kurallar, ad, verilmektedir. A ,rl,klar,n de i tirilmesi ö renme kurallar,na göre yap,l,r (6). YSAønda a ,rl,klar,n do ru de erlere ula mas,, örneklerin temsil etti i problem konusunda a ,n genellemeler yapabilme yetene ine kavu mas, demektir. Genelleme, YSAø,n e itiminde kullan,lmam, , ancak ayn, evrenden gelen girdi-ç,kt, örneklerini do ru s,n,fland,rabilme yetene i olarak tan,m,lan,r. A ,n bu genelle tirme özelli ine kavu mas, i lemne öa ,n ö renmesiö denilir.

YSA'da öğrenme iki amaçta gerçekleştirilir. Birinci amaçta amaçta gösterilen örnek için amaç üretecek çıktı, belirlenir. Bu çıktı, de erinin doğruluk derecesine göre, ikinci amaçta amaçla bağlantılarına sahip olduğu yapılar de iştirilmektedir. Amaç çıktıları belirlenmesi ve yapılar de iştirilmesi öğrenme kuralına bağlı olarak farklı ekollerde olmaktadır (6).

Bir YSA'nın etkinin tamamlanmasından, amaç öğrenip öğrenmediğini (performansını) ölçmek için denemeler yapılarak amaç test edilmesi gerekmektedir. Bir amaç, test etmek için amaç etkinin sırasında görmediği, yani veri setinden test amaçlı olarak ayrılan örnekler kullanılır ve bu örnekler test seti olarak alınır. Test ilerleminde amaçla farklı de erleri de iştirilmemektedir. Örnekler amaçta gösterilmekte ve amaç etkinin sırasında belirlenen amaçla farklı de erlerini kullanarak daha önce görmediği bu örnekler için çıktılar üretmektedir. Elde edilen çıktılar, doğruluk dereceleri amaç öğrenmesi hakkında bilgi vermektedir. Sonuç ne kadar iyi olursa etkinin performans, da o kadar iyi demektir (6).

Etkin ve test setleriyle ilgili temel sorun, yeterli etkin ve test verisi miktarının olması gerektiğidir. Sınırsız sayıda veri bulunabilmesi durumunda, YSA mümkün olduğunca çok veriyle etkinmelidir. Etkin verisinin yeterli olup olmadığının konusunda emin olmanın yolu, etkin verisinin miktarının arttırılarak, bunun amaç performansında bir de iştiriklik yaratıp yaratmadığına bakmaktır. Ancak bunun mümkün olmadığında, durumlarda YSA'nın etkin ve test verileri üzerindeki performansının yetersiz olması, da verilerin yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir. Bununla birlikte etkin setinin içermesi gereken veri miktarı, de iştirik yapay sınırlara ve özellikle problemin gösterdiği karmaşıklığa göre farklılık göstermektedir.

YAPAY SİNİRLERİN SINIFLANDIRILMASI

YSA'nın nöron dizilimlerine, nöronlar arasındaki düzenleme için yapılan hesaplamaların türüne ve zamanına göre üç farklı ekkilde incelenebilir.

1. Amaç yapılarına göre sınıflandırma
2. Zamana göre sınıflandırma
3. Öğrenme algoritmalarına göre sınıflandırma

A Amaç Yapılarına Göre Sınıflandırma

YSA içerdiği nöronların birbirine bağlantılarına göre ileri beslemeli ve geri beslemeli yapılar olarak 2 farklı ekkilde sınıflandırılmaktadır.

İleri beslemeli ağlar: İleri beslemeli YSA'da katmanlar ileri yöndedir, tersine bir yönelme yoktur (23). Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir (24). Böylece bu ağlar girilen verilere hızlı, bir şekilde çıktı üretebilmektedirler

İleri beslemeli YSA nöron adı verilen çok katmanlı yapılarından oluşur. Girdi ve çıktı katmanları, dış çevreyle bağlantılı olan katmanlardır. En az bir gizli katman girdi çıktı katmanları arasında bulunmaktadır. Bir katmandaki nöronların çıktıları, bir sonraki katmana bağlantılarından giriş olarak verilir (18,25).

Giriş katmanından, dış ortamlardan aldığı bilgileri hiçbir değişiklik yapmadan gizli katmandaki nöronlara iletir. Bilgi orta katmanlarda ve çıktı katmanında iletilenerek ağ çıkışı belirlenir. İleri beslemeli YSA, öğrenme algoritması olarak genellikle geri yayılım öğrenme algoritmasını kullanmakta ve bu nedenle bazen geri yayılım ağları olarak da adlandırılmaktadır. İkili tanıma, sinyal işleme ve sınıflandırma gibi problemlerde uygulanır (18). İleri beslemeli ağlara örnek olarak sıkça kullanılan çok katmanlı perseptron (Multilayer Perceptron-MLP) ve öğrenme vektör nicelendirmesi (Learning Vector Quantization-LVQ) ağları verilebilir.

Geri beslemeli ağlar: Geri beslemeli ağlar, ileri beslemeli ağların aksine dinamik bir yapıya sahiptir. Geri beslemeli YSA'da bir katmandaki hücre girdi olarak sadece kendinden önceki hücrenin çıktısından değil aynı zamanda o katmanın veya daha sonraki katmanların çıktılarından da alabilir (9,18,26).

Bir geri beslemeli sinir ağında temel olarak giriş ve ara katmanlardaki girişler, giriş birimlerine veya önceki ara katmanlara geri beslenebilir. Böylece girişler hem ileri yönlü hem de geri yönlü aktarılabilir. Geri beslemeli YSA dinamik hafızaya sahiptir ve bir andaki çıktı, hem o andaki hem de daha önceki girdileri yansıtır. Bu özelliği ile geri beslemeli YSA tahmin modellerinde sık kullanılır (9,18,26).

En yaygın geri beslemeli YSA, Hopfield, öz düzenlemeli harita, Elman ve Jordan ağlarıdır (9,26).

Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu sayede, geri beslemenin yapıldığı ekline göre farklı yapı ve davranışta geri beslemeli yapı sinir ağları elde edilebilir (18,9,26).

Geri dönüşümlü ağlar tam ve kısmi dönüşümlü ağlar olmak üzere ikiye ayrılır (6).

1-Tam geri dönü ümlü a lar: Bu a lar rastgele ileri ve geri bağlantılara sahip olan ağlardır. Bu bağlantılar, n hepsi e itilebilir.

2-Kısmi geri dönü ümlü a lar: Bu ağlarda a ,n i lem elemanlarına ek olarak, içerik elemanları da vardır. Bu ağlar, temelde ileri beslemeli ağlardır. İleri bağlantılar e itilebilir. Geri dönü üm olayı, sadece içerik elemanları tarafından yapılır ve bağlantılar e itilemezler. İçerik elemanları, ara katman elemanları, n, n geçmi durumları, n, hatırlamak için kullanılırlar. A ,n ç, kt, s, hem önceki durumu hem de a ,n o andaki durumuna bağlı olarak oluşturulmaktadır. Geçmi durumları, hatırlayabilmeleri bu ağlara dinamik hafızaya sahip olma özelliği kazandırmaktadır.

Geri dönü ümlü ağlara örnek olarak Elman, Hopfield, uyarlanabilir rezonans (Adaptive Resonance Theory - ART), öz örgütlemeli harita (SOM) ağları verilebilir. Bu ağlardan en basit yapıya sahip olan ve kullanılan, en kolay ağı Elman ağıdır (6,9,26).

Ö renme Algoritmalarına Göre Sınıflandırılması,

Sınırlar, n, n en önemli özelliği, öğrenme yeteneğidir. Bir sınırlarda öğrenmenin anlamı, a ,n belirli bir probleme ait doğru ç, kt, ları üretmesini sağlayacak optimum ağırlıklı değerlerinin bulunmasıdır. Öğrenme, ağırlıklı değerlerinin nasıl değiştirilmesi gerektiğini ifade eden bir öğrenme kuralına dayanır. Öğrenmeyi gerçekleştirecek olan sistem ve kullanılan öğrenme algoritması, öğrenme stratejilere bağlı olarak değişmektedir. Genel olarak 3 öğrenme stratejisinin ve 1 tane de bunları birleştiren sonuçta oluşan öğrenme stratejisinin uygulandığı görülmektedir. Bunlar aşağıdaki gibidir (6).

Dan, manlı öğrenme: YSA'da en fazla kullanılan öğrenme metodu olan dan, manlı öğrenmede, YSA'na örnek olarak girdi değerlerinden ve hedef ç, kt, (beklenen ç, kt,) değerlerinden oluşan bir örnek veri seti verilir. Bu ç, kt, yla ağı ürettiği ç, kt, karışılabilir. ki ç, kt, arasındaki fark hata olarak alınır. Başlangıçta genellikle rassal olarak verilen ağırlıklar tarafından minimize edilene kadar döngüler halinde değiştirilir (27).

Genelleştirilmiş delta kuralı ve geri besleme algoritması, dan, manlı öğrenme metoduna örnek olarak verilebilir.

Dan, masız öğrenme: Dan, masız öğrenmede, öğrenme süresince ağına sunulan bilgiler yalnızca girdi vektörlerinden oluşmakta ve hedef bilgiler ağına sunulmamaktadır. Bu nedenle, ağı üretmi olduğu ç, kt, ları, karışılabilir kontrol seviyesini gerçekleştireceği bir

dan, man, bulunmamaktadır (14). Girişte verilen örnek değerlere bakarak YSA, parametreler arasındaki ilişkileri kendi kendine öğrenir. Dan, mas,z öğrenmede amaç, hedef ç,kt, olmaks,z,n giriş bilgilerinin özelliklerine göre gruplama yapmak için amaçlı, k değerlerini ayarlar. Ardından amaç, her küme için örnek bir vektör üretir (28,29).

Dan, mas,z öğrenme genellikle s,n,fland,rma problemlerinin çözümünde kullanılmaktadır, uyarlan,r rezonans dan, mas,z öğrenmeye örnek olarak verilebilir (18).

Dan, mas,z öğrenme metodu, YSA'da sürekli araştırılan ve gelişen bir öğrenme metodudur. Bu metod, gelecekte bilgisayarlar,n insan yardım, olmadan öğrenebileceklerinin göstergesidir. Ancak günümüzde s,n,rl, kullan,m alanlar, bulan ve hala yolumun araştırma konusu olan bir öğrenme metodudur (27).

Destekleyici öğrenme: Bu tür stratejide de öğrenen sisteme bir öğretmen yardım,mc, olur. Fakat öğretmen her girdi seti için olması gereken (üretilmesi gereken) ç,kt, setini sisteme göstermek yerine sistemin kendisine gösterilen girdilere karş,lık ç,kt,s,n, üretmesini bekler ve üretilen ç,kt,n,n doğru veya yanlış olduğunu gösteren bir sinyal (skor veya derece) üretir. Sistem, dan, mandan gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. LVQ amaçlı, buna örnek olarak verilebilir (6,30).

Karma öğrenme: Hem dan, manlı, hem de dan, mans,z öğrenmeyi birlikte kullanan yapay sınırlar,d,r. Bu amaçlarda amaçlı,klar,n bir k,sm, dan, manlı, öğrenmeyle bir k,sm, da dan, mans,z öğrenmeyle ayarlan,r. Radyal tabanlı, YSA (Radial Basis Networks - RBN) ve olas,lık tabanlı, YSA (Probability Based Neural Networks - PBNN) bunlara örnek olarak verilebilir (31).

Öğrenme Zamanlarına Göre S,n,fland,r,ılması,

1-Çevrimiçi (On-line) öğrenme (Dinamik öğrenme): Bu kurala göre öğrenen sistemler, gerçek zamanda çalış,ırken bir taraftan fonksiyonlar,n yerine getirmekte, bir taraftan da kendini düzenlemeye devam eder. Böylece sürekli öğrenen bir YSA elde edilir. Bu yaklaşı,m daha çok farklı uygulamalar,n sıkça kullan,ıldı, ve öğrenilecek sistemin devamlı, olarak farklı davran,ışlar sergilediği uygulamalarda kullan,ılır (19).

2.Çevrimd, , (Offline) Ö renme (Statik Ö renme): A lar,n ço u için off-line çal, ma modu kullan,l,r. Bu YSA e itim verileriyle e itilir ve a ,n yap,s, kaydedilir. A bundan sonra hep ayn, yap,yla çal, ,r. Kullan,m, s,ras,nda herhangi bir de i ikli e u ramaz.

YAPAY S N R A I MODELLER

Yapay Sinir A lar,n,n Ö renme Algoritmalar,

YSA,n,n ö renmesi bir tak,m metot ve kurallar yard,m,yla a ,rl,klar,n de i tirilmesiyle sa lanabilir. Ö renme s,ras,nda, a ,n uyar,lmas, sonucunda a ,rl,klar,nda uyar,lmas, ve a ,n problemi çözmeye yönelik yeni tepkiler vermesi gerekir.

Literatürde, YSA yap,lar,na göre farklı,k gösteren ve a a ,daki bölümlerde k,saca anlat,lan çok say,da ö renme algoritmas, mevcuttur (32-39).

Geri yay,l,m (Back propagation) : YSA en çok tahmin amac,yla kullan,lmaktad,r. Tahmin için kullan,lan YSA içinde en yayg,n olarak kullan,lan, geriye yay,l,m algoritmas,d,r. Geriye yay,l,m algoritmas, katmanlar aras,nda tam bir ba lant,n,n bulundu u çok katmanl,, ileri beslemeli ve ö reticili olarak e itilen algoritmad,r. Hatalar, geriye do ru ç,k, tan giri e azaltmaya çal, mas,ndan dolay, bu ismi alm, t,r.

Geri yay,l,m bir giri setine kar ,l,k olarak özel bir fonksiyonel bir karakteristi i elde etmek için ç,k, lar, olu turmak üzere a ,rl,klar, ayarlama ilkesine dayanan bir algoritmad,r. Geriye yay,l,m algoritmas,, çok katmanl, a lar, e itmede en çok kullan,lan temel ö renme algoritmas,d,r.

Geri yay,l,m algoritmas,nda e itim veri setinin kalitesi de büyük önem ta ,r. Bu algoritman,n e itim süreci uzun oldu undan uygulamay, gerçekle tirmek zordur. E itim günlerce, haftalarca sürebilmektedir. Bu nedenle günümüzde bu algoritman,n ö renmesini h,zland,rma yöntemleri geli tirilmeye çal, ,lmaktad,r (40).

Momentumlu geri yay,l,m (Back propagation momentum): Geri yay,l,m algoritmas,n,n daha h,zl, çal, mas,n, sa layan yard,mc, sezgisel tekniklerden momentum kullan,larak da gerçekle tirilmektedir. Bu nedenle ad, momentumlu geri yay,l,m algoritmas,d,r. Ö renmeyi etkileyen di er bir parametre ö renme oran,d,r. Bu de erlerin seçiminde dikkatli olunmas, gerekmektedir. Özellikle geri yay,l,m algoritmas,nda ö renme oran, küçük seçilirse ö renme yava layacak, büyük seçilirse a ,rl,k de i imleri sal,n,ml, ve

kararsız olabilmektedir. Bu sakıncalar sebebiyle, momentumlu geri yayılım algoritmasında ağırlıklara uygulanacak düzeltme miktarı, belirleyen denklemlere momentum terimi γ eklenerek azaltılabilmesi mümkündür. Momentum katsayısı, $0 < \gamma < 1$ aralığında seçilmektedir. Momentum katsayısı, ağırlık daha hızlı toparlanmasını yardımcı eden faktördür. Amac, öğrenme esnasında ağırlık salınım yapmasını önlemektir (40).

Esnek geri yayılım (Back resilient propagation): Sinir düğümü yapısında sıklıkla sigmoid tabanlı fonksiyonlar kullanılır. Bu fonksiyonlar sonsuz giriş aralığındaki veriyi sonlu aralığa transfer ederler ve giriş değeri büyüdükçe fonksiyonlardaki eğiklik sıfıra doğru gider. Bu durum sigmoid fonksiyonların sahip sinir ağlarında türevdeki değeri eğikliklerin parametre üzerindeki etkisini azaltır. Bu yüzden türevin değeri yerine yalnızca eğikliğe göre parametrelerin yenilenmesini sağlamak amacıyla bu yöntem geliştirilmiştir. Bu yöntem önceki anlatılan yöntemden daha hızlı yakınsamaktadır (32-39).

Ele tirmeli gradyan azaltma geri yayılım (Conjugate Gradien): Basit geri-yayılım algoritması, ağırlık değerlerini eğimin negatifi yönünde dengeler. Bu doğrultu eğimin hızla düğümü doğrultu olarak bilinir. Bu doğrultuda performans fonksiyonu daha hızlı düşer. Performans fonksiyonundaki hızlı düşüş, ağırlık yakınsamasını sağlayabilir.

Bu algoritmalarla adım boyutu her bir iterasyonda yeniden düzenlenir. Performans fonksiyonunun yakınsama doğrultusu boyunca minimize edilmesi için güncelleme adım boyutunun belirlenmesi amacıyla ele tirmeli gradyan doğrultusu boyunca bir arama gerçekleştirilir (19).

Quasi-Newton: Newton yöntemleri hızlı optimizasyon için kullanılabilecek yöntemlerdir. QN ele tirmeli gradyan yöntemlerine göre çok daha fazla hafıza ve her iterasyonda çok daha fazla hesaplama gerektirse de genellikle birkaç iterasyonda sonuçları verir. Küçük boyutlu ağlarda kullanım, daha uygundur (32-39).

Delta-bar-delta: Jacobs tarafından geliştirilmiş bir çok katmanlı perseptron öğrenme algoritması, olan algoritmanın eğitim kuralı, ağırlıkların yakınsama hızını arttırmak için kullanılan sezgisel bir yaklaşımdır. Delta-bar-delta öğrenme algoritmasında, adım her bir bağlantıya atanan öğrenme katsayılarının optimum değerlerinin belirlenmesi çok zor ve

zaman al,c, olabilmektedir. Delta-bar-delta a a ,daki ad,mlar, ilerleterek bir e itim sürecinde ö renme oran,n, iyile tirmektedir.

- Her a ,rl,k kendi ö renme oran,na sahiptir.
- Her bir a ,rl,k için; her bir kom u bir önceki ad,mdaki kom ular, ile kar ,la t,r,l,r.
- Kom u ayn, yönde ise ö renme oran, artt,r,l,r.
- Kom u farklı yönde ise ö renme oran, azalt,l,r.

Bu de i imi sa layabilmek için a ,rl,klar, hatan,n derecesine ba l, olan k,smi türevlerine ve a ,rl,k de eri noktas,n,n çevresindeki hata yüzeyinin e rilik ölçüsüne göre güncellenmelidir.

Üstel olarak artan önceki e im bile ni ve mevcut e im bile ni ayn, i aretli ise ö renme katsay,s,, mevcut de eri ile orant,l, olarak birleştirilir. Mevcut e im bile ni üstel ortalamas,na göre z,t i aretli ise, ö renme katsay,s, mevcut de eri ile orant,l, olarak azalt,l,r. Bu ifade DBD algoritmas,n,n, ö renme katsay,s,n, do rusal olarak art,rmakta, fakat geometrik olarak azaltmakta oldu unu gösterir (32-39).

Geni letilmi delta-bar-delta (Extended delta-bar-delta): Bu algoritma isminden de anla ,labilece i gibi Jacobs taraf,ndan sunulan DBD algoritmas,n,n geli tirilmi halidir. DBD algoritmas,ndan farklı,l,klar,; sezgisel momentum kullanmas,, a ,rl,k uzay,nda büyük artmalar, ortadan kald,rmas, ve geometrik azalt,m,n büyük orandaki atlamalar,n, engellemede yeterince h,zl, olmalar, e klerinde s,ralanabilir (32-39).

H,zl, Yay,l,m (Quick propagation): H,zl, yay,l,m algoritmas,, Scatt Fahlman taraf,ndan Charnegie Mellon Üniversitesi'nde geli tirilen ve Newton metoduna dayanan, çok katlı, perseptronlar,n e itilmesi için kullan,lan bir sezgisel ö retme metodudur. Sezgisel algoritmalar, tecrübeye ve e itilmi tahmine dayalı, kurallar içermektedir. Bu algoritmalar optimum çözümü garanti etmeyip, ona yak,n çözümü bulmay, garanti etmektedir. Çözümünden fazla uzakla madan mümkün olan en büyük ad,mlarla k,sa sürede problem çözülür. H,zl, yay,l,m algoritmas,n,n performans testleri di er tekniklerle kar ,la t,r,ld, ,nda oldukça iyidir (32-39).

Levenberg Marquardt: Oldukça ba ar,l, bir optimizasyon metodu olan bu algoritma, ö renmede kullan,lan geri yay,l,m algoritmas,n,n farklı, ö renme tekniklerinden birisidir. Bu

ö renme algoritmas,n,n seçilmesinin sebebi, hızlı, ö renme ve iyi yak,n sayabilme özelli inden kaynaklanmaktadır. Temel olarak, maksimum kom uluk fikri üzerine kurulmu bir hesaplama metodu olup Gauss-Newton ve Steepest-Descent (ad,m azaltılmal,) algoritmalar,n,n en iyi özelliklerinden olu mu tur ve bu iki metodun k,s,tlamalar,n, ortadan kald,rmaktadır (32-39).

Çok Katmanlı, Perseptron Yapay Sinir A lar, (Multilayer Perceptron Neural Networks)

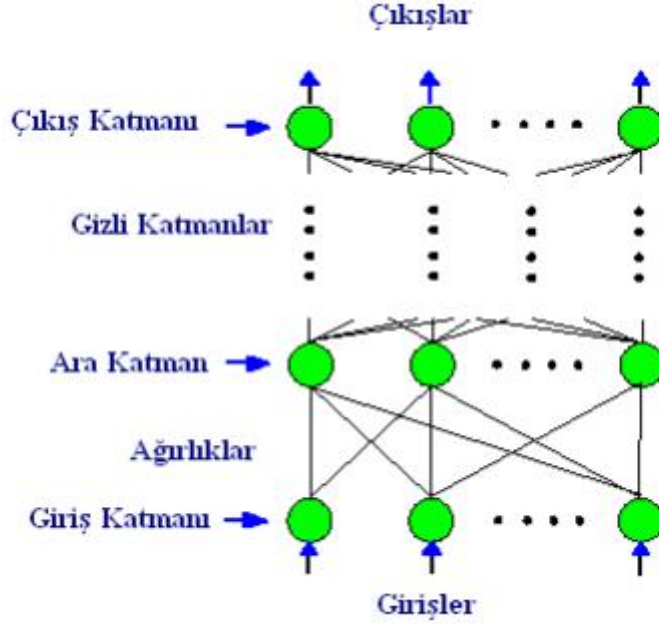
Bu a modeli özellikle t,p ve mühendislik uygulamalar,nda en çok kullan,lan sinir a , modeli olmu tur. Bu modelin yayg,n kullan,lmaz,n,n sebebi, birçok ö renme algoritmas,n,n bu a ,n e itiminde kolayl,kla kullan,labilmesidir. Çok katmanlı, a lar, bir girdi katman,, bir veya daha fazla gizli katman ve bir ç,kt, katman,ndan olu ur (ekil 7). Bir katmandaki bütün i lem elemanlar, bir üst katmandaki bütün i lem elemanlar,na ba l,d,r. Bilgi ak, , ileri do ru olup geri besleme yoktur. Giri katman,nda herhangi bir bilgi i leme yap,lmaz. Çok katmanlı, perseptron modelinde do rusal olmayan aktivasyon fonksiyonu kullanan en az bir gizli katman bulunur (41).

Çok katmanlı, perseptronlarda girdi katman, nöron say,s, genellikle problemdeki girdi say,s,na, ç,kt, katman, nöron say,s, da istenilen ç,kt, say,s,na e it tutulur. Gizli katman say,s, ve gizli katmandaki nöronlar,n say,s, deneylerle tespit edilir. Gizli katman ve gizli katmanlarda yer alan nöron say,s,n,n fazla olmas, e itim kümesinde hata oran,n, dü ürür ancak test kümesinde hata oran,n,n artmas,na neden olur. Nöron say,s,n,n artmas, ba lant, say,s,n,n dolay,s,yla e itilmesi gereken a ,rl,k say,s,n,n artmas,na neden olur (41).

Girdi katman,ndaki nöronlar, girdiler üzerinde bir de i iklik yapmadan sonraki katmana gönderir. Gizli katmanda ve ç,k, katman,nda ba lant,lar,n a ,rl,k de erleriyle çarp,larak gelen veriler toplan,r ve aktivasyon fonksiyonundan geçirilir. Aktivasyon fonksiyonunun türevlenebilir olmas, istendi inden genellikle sigmoid fonksiyonu kullan,lı,r (42).

Çok katmanlı, perseptron a lar,nda, a a bir örnek gösterilir ve örnek neticesinde nas,l bir sonuç türetece i de bildirilir. Örnekler giri katman,na uygulan,r, ara katmanlarda i lenir ve arzu edilen ç,k, aras,ndaki hata tekrar geri do ru a ,rl,klar üzerine yay,larak hata minimuma dü ünçeye kadar a ,rl,klar de i tirilir. Çok katmanlı, perseptron a , ileri beslemeli a olup, en genel sonuç ç,k, katman,ndan elde edilir. Kullan,lan e itme algoritmas,na göre

a ,n ç,k, , ile anlam,yla giri ile ç,k, uzay, aras,nda statik haritalama yaparlar, bir andaki ç,k, sadece o andaki giri in bir fonksiyonudur (43).



ekil 7. Genel bir çok katmanlı, perseptron yapısı,

Çok katmanlı, perseptronda ba ,ml, de i ken nominal, s,ral,, aral,k, veya oran ölçü inde olabilmektedir. Ba ,ms,z de i kenler ise kategorik veya ölçülebilir verilerden oluşabilmektedir. Ölçülebilir veriler ebekeinin öğrenmesinin geliştirilmesi amacıyla yeniden ölçeklendirmeye tabi tutulmaktadır. Frekans dağılımları, bu süreçte göz ardı edilmektedir (6,11).

SİGARA KULLANIMINI ETKİLEYEN FAKTÖRLER

Kişinin, daha önceden de er verdi i di er u ra lardan ve nesnelere daha fazla öncelik tanıyarak madde al,m,n,n devam etmesi ve kulland, , madde miktar,n,n giderek artt,r,lması, madde bırak,ld, ,nda yoksunlu un ortaya ç,kması, madde ba ,ml, oldu unu gösterir (44).

Sigara ba ,ml,lik yapı,c, bir maddedir. Sigaran,n içinde bulunan nikotin ilk nefesin çekilmesinden birkaç saniye sonra beyine ula rarak ilk bir rahatlama, endi e ve s,k,nt,lar,n hafiflemesi ve zihnin daha h,zl, çal,ması, etkileriyle beraber haz duygusunu oluşturup ba ,ml,lik, , ba lat,r. Bu durum tahmin edilenin aksine sigaran,n yaratt, , bir rahatlama

olmay,p, ço u kez yoksunluk hisseden ki inin vücudunun arad, , maddeye kavu mas, ile duydu u iyilik hissidir (45). Bu durum sigara içilmedi inde ise öho olmayanö yoksunluk belirtisine yol açar. Yani ba ,ml,l,k ki inin madde al,m, üzerindeki kontrolünü kaybetmesini ifade eder (46). Sigara içme al, kanl, , kazanan ki iler sigarayla ve onun zararlar,yla bütünle tikleri için sigaradan uzak duramazlar (47). DSÖ de erlendirmelerine göre sigara tiryakisi say,lmak için ödüzenli olarak günde 1 sigara içmekö yeterlidir (47). Sigara, toplumda kullan,m s,kl, , en fazla olan, ba ,ml,l,k yap,c, maddeler aras,nda birinci s,radad,r. Ba lang,çta belirgin olan öhazö duygusu ve bu duygunun geli ti i fizik ve piskolojik ba ,ml,l, ,n zeminini olu tururken, ba ,ml,l,k geli tikten sonra nikotin al,nmad, ,nda ilk 24 saat içinde yoksunluk belirtilerine yönelik içme ön plana geçer (48,49).

DSÖ sigara ba ,ml,l, ,n, öDünyada en h,zl, yay,lan en uzun hastal,kö olarak tan,m,mlam, t,r (50-52). Sigaraya ba lama al, kanl, ,n,n sosyal, psikolojik ve farmakolojik faktörleri vard,r. Sigara içmede as,l önemli olan sosyal ve ailesel faktörlerdir. Aile içinde ya da arkada çevresinde sigara içilmesi, nikotin ba ,ml,l, ,, genetik ve psiko-sosyal faktörler sigara içme davran, ,n, etkilemektedir. Ayr,ca ki inin e itim durumu, ya , cinsiyet sigara içmede etkendir (50-52). Sigaray, b,rakmay, etkileyen olas, sebepler incelendi inde ise bunlar,n; cinsiyet, ya , e itim durumu, çekirdek ailesinde sigara içen olup olmamas,, sigaraya maruz kalma süreleri ve b,rakma giri im say,lar,, nedensiz, bir sa l,k sorunu nedeniyle veya hekim tavsiyesiyle, görsel ve yaz,l, medyan,n ve sigara kar ,t, kampanyalar,n oldu u görölmektedir (50-52).

GEREÇ VE YÖNTEMLER

ARA TIRMANIN EKL

Ara tırma kapsamında 18 ya ve üzeri 250 sigara içen, 250 sigaray, b,rakm, ve 250 sigara içmeyen kontrol olmak üzere toplam 750 bireye anket uygulanmış olup elde edilen veriler çok katmanlı, perseptron YSA ile değerlendirildi.

ARA TIRMANIN YAPILDI İ YER VE ZAMAN

Ara tırmanın verileri 01.03.2011 ile 30.05.2011 tarihleri arasında İstanbul Küçükçekmece ilçesine bağlı, aile hekimliği polikliniklerinden elde edildi.

ARA TIRMANIN EVREN VE ÖRNEKLEM

Ara tırma evrenini İstanbul Küçükçekmece ilçesine bağlı, aile hekimliği polikliniklerine muayene olmaya gelen 18 ya üzeri hastalar oluşturulmaktadır.

Ara tırma örnekleme ise ara tırma katılmayı kabul eden 750 hastadan (250 sigara içen, 250 sigaray, b,rakm, ve 250 sigara içmeyen kontrol) oluşturulmaktadır. Çalışmaya katılmaya gönüllü olanlar ara tırma dahil edilmiştir.

VERİLERİN TOPLANMASI

Verilerin toplanmasında katılımcıların yaşı, eğitim durumu, gelir düzeyi, sosyodemografik özellikleri, sigara içme durumları sorgulandı, anket formu kullanıldı.

VERİLERİN ANALİZİ

Anket formuyla elde edilen verilerin değerlendirilmesinde hastalara ilişkin tanımlayıcı istatistikler ortalama \pm standart sapma ya da sayı (yüzde) olarak ifade edildi. Hastaların sigara içme durumuna bağlı olarak sosyo-demografik özelliklerine göre karşılaştırmalarında bivariate istatistiksel test yöntemleri (Tek yönlü Varyans analizi, Kruskal-Wallis test ve Ki-kare testleri) kullanıldı. İstatistiksel analizlerde $p < 0,05$ derecesi istatistiksel anlamlılık olarak kabul edildi.

Çalışmaya dahil edilen 750 hasta sigara durumlarına göre (sigara içen, sigara içmeyen ve sigarayı bırakmış) sınıflandırıldı. Veriler çok katmanlı perseptron YSA yöntemi ile bilgisayar ortamında modellendi. Örneklemin rastgele seçilen %30'lık kısmı test amaçlı için ayrılırken, %70'lik kısmı modelin eğitim çalışmasında kullanıldı. Uygulamada 13 nöronlu bir giriş katmanı, 3 nöronlu bir gizli katman ve 2 nöronlu bir çıkış katmanı yapay sinir ağ modeli kullanıldı. Çok katmanlı perseptron YSA'nın performansının değerlendirilmesinde ROC eğrileri, kalırsız grafikleri, kazanç grafikleri ile duyarlılık, özgüllük, pozitif-negatif kestirim değerleri ve doğruluk değerleri esas alındı.

Sınıflandırma için çok katmanlı perseptron YSA öğrenme algoritmalarından ölçekli Conjugate Gradient algoritması kullanıldı. Algoritmanın tuning parametreleri aşağıdaki Tablo 2'de gösterildi.

Tablo 2. Çok katmanlı perseptron YSA'nın tuning parametreleri

Algoritma parametresi	Değer
Yakınsama toleransı, (Convergence tolerance)	0,000001
Delta değerinde minimum artış,	0,0000001
Minimum gradient	0,0000001

BULGULAR

Çal, maya kat,lanlar,n sosyo-demografik özelliklerine ili kin bilgiler Tablo 3'e gösterildi. Hastalar,n ya ortalamas,n,n $38,4 \pm 11,5$ oldu u, karde say,s,n,n ortalama $3,8 \pm 1,8$ oldu u ve ayl,k gelir ortalamalar,n,n 1721 ± 1192 oldu u bulundu. Hastalar,n 380'ü kad,n 370'ü erkekti. Medeni durumlar, incelendi inde 468'inin evli, 206's,n,n bekar, 76's,n,n dul oldu u bulundu. E itim durumlar, incelendi inde 30'u okuryazar/ okuryazar de il, 108'ü ilkokul, 140'ü ortaokul, 258'ü lise, 214'ü üniversite mezunuydu. Alkol kullanma durumlar, incelendi inde hastalar,n 392'sinin alkol kullanmad, ,, 275'inin toplant,, davette alkol kulland, ,, 83'ünün s,k s,k alkol kulland, , saptand,. Ailede sigara içme durumlar, incelendi inde 113'ünün ailesinde sigara içmeyen, 637'sinin ailesinde sigara içen oldu u saptand,.

Tablo 3. Hastaların sosyo-demografik özelliklerine göre dağılımı,

	Toplam (n=750)
Yaş	38,4 ± 11,5
Kardeş sayısı,	3,8 ± 1,8
Gelir	1721 ± 1192
Cinsiyet	
Erkek	370
Kadın	380
Medeni durum	
Evli	468
Bekar	206
Dul	76
Eğitim durumu	
Okur yazar/ okur yazar değil	30
İlkokul	108
Ortaokul	140
Lise	258
Üniversite	214
Alkol	
Hiç içmem	392
Toplantı, Davet	275
Sık sık içerim	83
Aile öyküsü	
Yok	113
Var	637

750 hasta ösigara içenö, ösigara içmeyenö ve ösigaray, b,rakm, ö olarak s,n,fland,r,ld,. Hastalar,n sigara içme durumlar,na göre sosyo-demografik özelliklerinin da ,l,m, Tablo 4öte gösterildi.

Tablo 4 incelendi inde, sigara içen hastalar,n ya ortalamas,n,n $37,5 \pm 10,8$ oldu u, sigaray, b,rakm, hastalar,n ya ortalamas,n,n $40,7 \pm 10,4$ oldu u, sigara içmeyen hastalar,n ya ortalamas,n,n $36,7 \pm 12,7$ oldu u ve aralar,nda istatistiksel anlaml, farkl,l,k oldu u saptand, ($p < 0,001$). Bu farkl,l, ,n sebebi sigaray, b,rakanlar,n ya lar,n,n içen ve içmeyenlerden anlaml, olarak yüksek olmas,ndan kaynaklanmaktad,r.

Hastalar,n sigara içme durumlar,na göre karde say,lar, incelendi inde; sigara içen grupta karde say,s,n,n $4,0 \pm 2,3$ oldu u, sigaray, b,rakan grupta $3,4 \pm 1,2$ oldu u ve sigara içmeyen grupta $3,9 \pm 1,8$ oldu u bulundu. Hastalar,n sigara içme durumlar, ile karde say,lar, aras,nda anlaml, fark bulundu ($p = 0,038$). Bu farkl,l,k sigaray, b,rakan grupta karde say,s,n,n içen ve içmeyenlerden anlaml, olarak dü ük olmas,ndan kaynaklanmaktad,r.

Hastalar,n sigara içme durumlar,na göre ayl,k gelir düzeyleri incelendi inde; sigara içen grupta gelir düzeyinin 1607 ± 798 TL oldu u, sigaray, b,rakan grupta 1816 ± 954 TL oldu u ve sigara içmeyen grupta 1779 ± 1671 TL oldu u bulundu. Hastalar,n sigara içme durumlar, ile gelir düzeyleri aras,nda anlaml, fark bulunmad, ($p = 0,058$).

Hastalar,n sigara içme durumlar,na göre cinsiyet da ,l,mlar, incelendi inde; sigara içen hastalar,n 130ünun (%52,0) erkek, 120ünin (%48,0) kad,n oldu u, sigaray, b,rakan hastalar,n 142ünin (%56,8) erkek, 108ünin (%43,2) kad,n oldu u, sigara içmeyen hastalar,n 98ünin (%39,2) erkek, 152ünin (%60,8) kad,n oldu u bulundu. Hastalar,n sigara içme durumlar, ile cinsiyetleri aras,nda istatistiksel anlaml, farkl,l,k bulundu ($p < 0,001$). Bu farkl,l,k sigara içmeyen grupta kad,n oran,n,n di er iki gruptan yüksek olmas,ndan kaynaklanmaktad,r.

Hastalar,n sigara içme durumlar,na göre medeni durumlar, incelendi inde; sigara içen hastalardan 150ünin (%60,0) evli, 68ünin (%27,2) bekar, 32ünin (%12,8) dul, sigaray, b,rakan hastalardan 165ünin (%66,0) evli, 57ünin (%22,8) bekar, 28ünin (%11,2) dul, sigara içmeyen hastalardan 153ünün (%61,2) evli, 81ünin (%32,4) bekar, 16ün,n,n (%6,4) dul oldu u saptand,. Hastalar,n sigara içme durumlar, ile medeni durumlar, aras,nda anlaml, fark bulundu ($p = 0,033$).

Hastalar,n sigara içme durumlar,na göre e itim durumlar, incelendi inde; sigara içen hastalardan 12ünin (%4,8) okuryazar/ okuryazar de il, 36ün,n,n (%14,4) ilkokul mezunu, 51ünin (%20,4) ortaokul mezunu, 96ün,n,n (%38,4) lise mezunu, 55ünin (%22,0) üniversite

mezunu oldu u, sigaray, b,rakan hastalardan 100'nun (%4) okuryazar/ okuryazar de il, 300'nun (%12,0) ilkokul mezunu, 530'nun (%21,2) ortaokul mezunu, 990'nun (%39,6) lise mezunu, 580'nin (%23,2) üniversite mezunu oldu u, sigara içmeyen hastalardan 80'nin (%3,2) okuryazar/ okuryazar de il, 420'sinin (%16,8) ilkokul mezunu, 360's,n,n (%14,4) ortaokul mezunu, 630'nun (%25,2) lise mezunu, 1010'nin (%40,4) üniversite mezunu oldu u belirlendi. Hastalar,n sigara içme durumlar, ile e itim durumlar, aras,nda anlaml, fark bulundu ($p<0,001$).

Hastalar,n sigara içme durumlar,na göre alkol kullanma durumlar, incelendi inde; sigara içenlerden 1140'nun (%45,6) alkol kullanmazken, 940'nun (%37,6) toplant, davet v.s alkol kulland, ,, 420'sinin (%16,8) s,k s,k alkol ald, ,, sigaray, b,rakanlardan 1070'sinin (%42,8) alkol kullanmad, ,, 1120'sinin (%44,8) toplant,, davet gibi yerlerde alkol kulland, ,, sigara içmeyenlerin 1710'nin (%68,4) alkol kullanmad, ,, 690'nun (%27,6) toplant,, davet gibi yerlerde alkol kulland, ,, 100'nun (%4,0) s,k s,k alkol ald,klar, belirlendi. Hastalar,n sigara içme durumlar, ile alkol kullanma durumlar, aras,nda anlaml, fark bulundu ($p<0,001$).

Hastalar,n sigara içme durumlar,na göre aile öyküsü incelendi inde; sigara içenlerin 210'nin (%84,0) ailesinde sigara içenlerin bulunmad, ,, 2290'nun (%91,6) ailesinde sigara içenlerin bulundu u, sigaray, b,rakan hastalardan 360's,n,n (%31,9) ailesinde sigara içenlerin bulunmad, ,, 2140'nun (%33,6) ailesinde sigara içenlerin bulundu u, sigara içmeyenlerin 560's,n,n (%49,6) ailesinde sigara içenlerin bulunmad, ,, 1940'nun (%30,5) ailesinde sigara içenlerin bulundu u saptand,. Hastalar,n sigara içme durumlar, ile aile öyküleri aras,nda anlaml, fark bulundu ($p<0,001$).


Tablo 4. Hastalar, n sigara içme durumlarına göre sosyo-demografik özelliklerinin dağılımı

	çiyor (n=250)	B,rakm, (n=250)	çmiyor (n=250)	P
Ya	37,5 ± 10,8	40,7±10,4	36,7±12,7	<0,001
Karde say,s,	4,0 ± 2,3	3,4 ± 1,2	3,9 ± 1,8	0,038
Gelir	1607 ± 798	1816 ± 954	1779 ± 1671	0,059
Cinsiyet				
Erkek	130 (%52,0)	142 (%56,8)	98 (%39,2)	<0,001
Kad,n	120 (%48,0)	108 (%43,2)	152 (%60,8)	
Medeni durum				
Evli	150 (%60,0)	165 (%66,0)	153 (%61,2)	0,033
Bekar	68 (%27,2)	57 (%22,8)	81 (%32,4)	
Dul	32 (%12,8)	28 (%11,2)	16 (%6,4)	
E itim durumu				
Okuryazar/ okuryazar de il	12 (%4,8)	10 (%4,0)	8 (%3,2)	<0,001
İlkokul	36 (%14,4)	30 (%12,0)	42 (%16,8)	
Ortaokul	51 (%20,4)	53 (%21,2)	36 (%14,4)	
Lise	96 (%38,4)	99 (%39,6)	63 (%25,2)	
Üniversite	55 (%22,0)	58 (%23,2)	101 (%40,4)	
Alkol				
Hiç içmem	114 (%45,6)	107 (%42,8)	171 (%68,4)	<0,001
Toplant,, davet	94 (%37,6)	112 (%44,8)	69 (%27,6)	
S,k s,k içirim	42 (%16,8)	31 (%12,4)	10 (%4,0)	
Aile öyküsü				
Yok	21 (%84,0)	36 (%31,9)	56 (%49,6)	<0,001
Var	229 (%91,6)	214 (%33,6)	194 (%30,5)	

Sigara içenler ile b,rakm, lar,n e itim (training) ve test (testing) sonuçlar,na ili kin duyarlı,k, özgüllük, PKD, NKD ve do ruluk oranlar, Tablo 5’te gösterildi. E itim sonuçlar,na göre duyarlı,k %83,4, özgüllük %62,3, PKD %68,9, NKD %79,2 ve do ruluk oran, %72,9 olarak bulundu. Test sonuçlar,na göre ise duyarlı,k %65,3, özgüllük %46,7, PKD %55,0, NKD %57,4 ve do ruluk oran, %56,0 olarak bulundu.


Tablo 5. Sigara içenler ile b,rakm, lar,n e itim (training) ve test (testing) sonuçlar,

	E itim (Training)	Test (Testing)
Duyarlı,k	83,4	65,3
Özgüllük	62,3	46,7
PKD	68,9	55,0
NKD	79,0	57,4
Do ruluk	72,9	56,0
AUC	0.747	0,614




ekil 8. Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin e itim (training) verisinin ROC e risi

Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin e itim (training) verisinin ROC e risi ekil 8’de gösterildi. Buna göre e ri alt,nda kalan alan 0.747 olarak bulundu.




ekil 9. Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin test (testing) verisinin ROC e risi

Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin test (testing) verisinin ROC e risi ekil 9da gösterildi. Buna göre e ri alt,nda kalan alan 0.614 olarak bulundu.



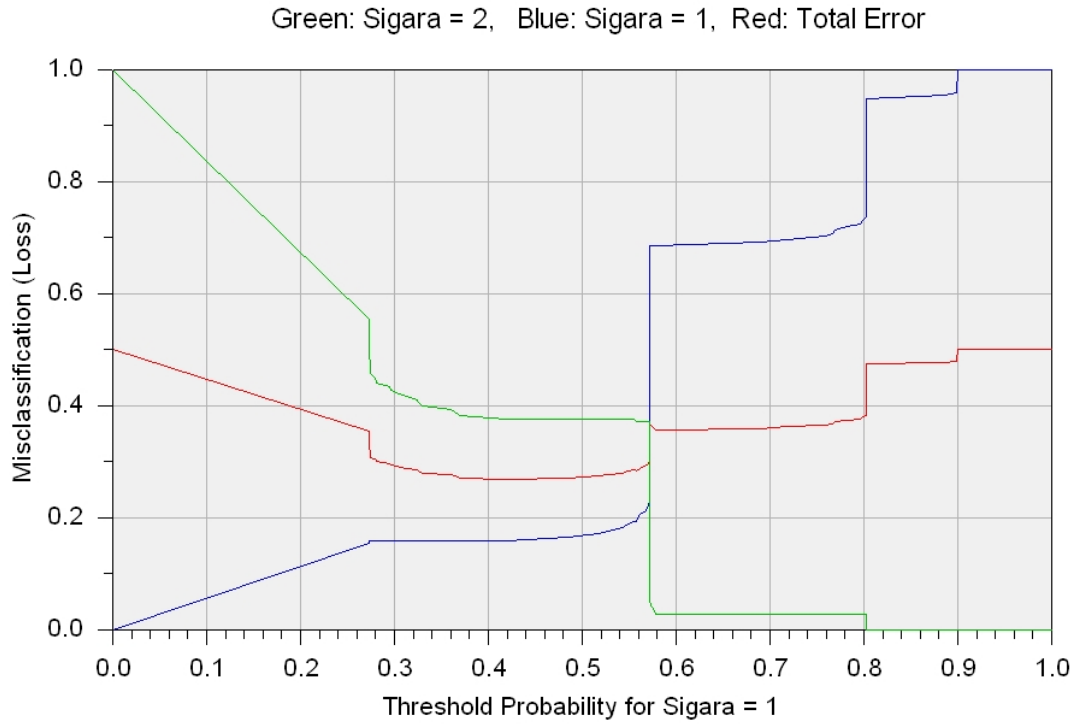
ekil 10. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim (training) verisinin olas,l,k kalibrasyon (Probability Calibration) grafi i

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim verisinin olas,l,k kalibrasyon grafi i ekil 10da gösterildi. Buna göre e itim verisinin a ,rl,kl, ortalama hatas, 0.0589 olarak bulunurken, a ,rl,kl, ortalama karesel hata 0.0805 olarak bulundu.




ekil 11. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin olas,l,k kalibrasyon (Probability Calibration) grafi i

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test verisinin olas,l,k kalibrasyon grafi i ekil 11de gösterildi. Buna göre e itim verisinin a ,rl,kl, ortalama hatas, 0.1262 olarak bulunurken, a ,rl,kl, ortalama karesel hata 0.1343 olarak bulundu.




ekil 12. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim (training) verisinin denge grafi i (Balance chart)

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim verisinin denge grafi i ekil 12de gösterildi. ekildeki ye il çizgi sigaray, b,rakanlar içerisindeki yanl, s,n,fland,rma oran,n,, mavi çizgi sigara içenler içerisindeki yanl, s,n,fland,rma oran,n,, k,r,m,z, çizgi ise a ,r,l,kl, yanl, s,n,fland,rma oran,n, göstermektedir.




ekil 13. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin denge grafi i (Balance chart)

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test verisinin denge grafi i ekil 13te gösterildi. ekildeki ye il çizgi sigaray, b,rakanlar içerisindeki yanl, s,n,fland,rma oran,n,, mavi çizgi sigara içenler içerisindeki yanl, s,n,fland,rma oran,n,, k,r,m,z, çizgi ise a ,r,l,kl, yanl, s,n,fland,rma oran,n, göstermektedir.



ekil 14. Sigara içenler ile bırakılmayanların ayrıştırılmaya ilişkin eğitim (training) verisinin kazanç grafiği (Gain chart)

Sigara içenler ile bırakılmayanların ayrıştırılmaya ilişkin eğitim verisinin kazanç grafiği ekil 14'te gösterildi. Kazanç (Gain) grafiği; Toplam olgu sayısının hedeflenen yüzdesiyle, başlıca, de ikenin herhangi bir kategorisindeki olguların toplam sayısının yüzdesinin grafiksel gösterimidir. Buna göre ortalama kazanç 1,4016 olarak bulundu.




ekil 15. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin kazanç grafi i (Gain chart)

Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin test verisinin kazanç grafi i ekil 15øte gösterildi. Buna göre ortalama kazanç 1,2431 olarak bulundu.



ekil 16. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim (training) verisinin kald,raç grafi i (Lift chart)

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim verisinin kald,raç grafi i ekil 16da gösterildi. Kald,raç (Lift) grafi i: Toplam olgu say,s,n,n hedeflenen yüzdesiyle, ba ,ml, de i kenin herhangi bir kategorisindeki olgulara rastlanma olas,l, ,n,n model kullanmamaya göre kaç kat fazla oldu unu gösterir. E itim veri kümesine dayanarak gerçekte tirilen modelin test veri setinde ba ar,l, olarak gerçekte tirdi i tahminlerin oran,n, % olarak gösterir. Örne in bu modelde olgular,n %10unu kullanarak sigara içen birine rastlama oran,n,n model kullanmamaya göre yakla ,k 1,9 kat daha fazla oldu u görülmektedir.




ekil 17. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin kald,raç grafi i (Lift chart)

Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test verisinin kald,raç grafi i ekil 17de gösterildi. Kald,raç (Lift) grafi i: Toplam olgu say,s,n,n hedeflenen yüzdesiyle, ba ,ml, de i kenin herhangi bir kategorisindeki olgulara rastlanma olas,l, ,n,n model kullanmamaya göre kaç kat fazla oldu unu gösterir. E itim veri kümesine dayanarak gerçekte tirilen modelin test veri setinde ba ar,l, olarak gerçekte tirdi i tahminlerin oran,n, % olarak gösterir. Örne in bu modelde olgular,n %20sini kullanarak sigara içen birine rastlama oran,n,n model kullanmamaya göre yakla ,k 1,6 kat daha fazla oldu u görülmektedir.

Sigara içenler ile içmeyenlerin eğitim (training) ve test (testing) sonuçlarına ilişkin duyarlılık, özgüllük, PKD, NKD ve doğruluk oranları, Tablo 6'da gösterildi. Eğitim sonuçlarına göre duyarlılık %81,1, özgüllük %84,6, PKD %84,0, NKD %81,8 ve doğruluk oranı %82,9 olarak bulundu. Test sonuçlarına göre ise duyarlılık %70,7, özgüllük %57,3, PKD %62,4, NKD %66,2 ve doğruluk oranı %64,0 olarak bulundu.


Tablo 6. Sigara içenler ile içmeyenlerin eğitim (training) ve test (testing) sonuçları,

	Eğitim (Training)	Test (Testing)
Duyarlılık	81,1	70,7
Özgüllük	84,6	57,3
PKD	84,0	62,4
NKD	81,8	66,2
Doğruluk	82,9	64,0
AUC	0.863	0,666




Şekil 18. Sigara içenler ile içmeyenleri ayırt etmede eğitim verisinin ROC eğrisi

Sigara içenler ile içmeyenleri ayırt etmede eğitim verisinin ROC eğrisi Şekil 18'de gösterildi. Buna göre eğri altında kalan alan 0.863 olarak bulundu.




ekil 19. Sigara içenler ile içmeyenleri ay,rt etmede test (testing) verisinin ROC e risi

Sigara içenler ile içmeyenleri ay,rt etmede test verisinin ROC e risi ekil 19da gösterildi. Buna göre e ri alt,nda kalan alan 0.666 olarak bulundu.



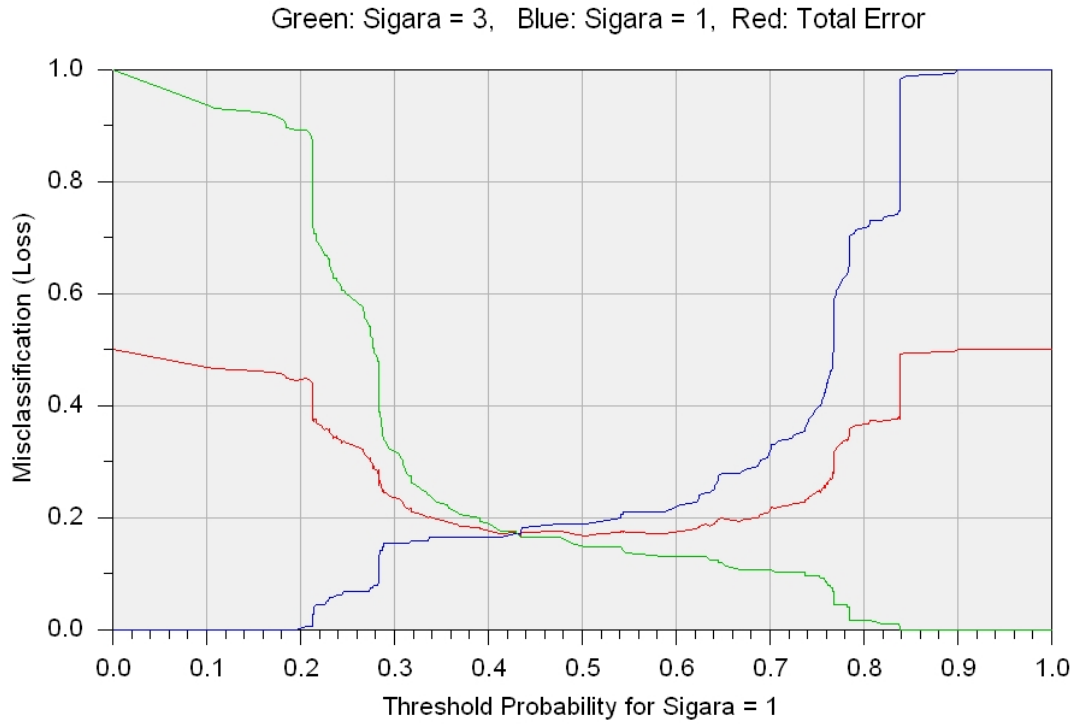
ekil 20. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim (training) verisinin olas,l,k kalibrasyon (probability calibration) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim verisinin olas,l,k kalibrasyon grafi i ekil 20de gösterildi. Buna göre e itim verisinin a ,rl,kl, ortalama hatas, 0.0784 olarak bulunurken, a ,rl,kl, ortalama karesel hata 0.0987 olarak bulundu.




ekil 21. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test (testing) verisinin olas,l,k kalibrasyon (probability calibration) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test verisinin olas,l,k kalibrasyon grafi i ekil 21øde gösterildi. Buna göre e itim verisinin a ,rl,kl, ortalama hatas, 0.1442 olarak bulunurken, a ,rl,kl, ortalama karesel hata 0.1676 olarak bulundu.



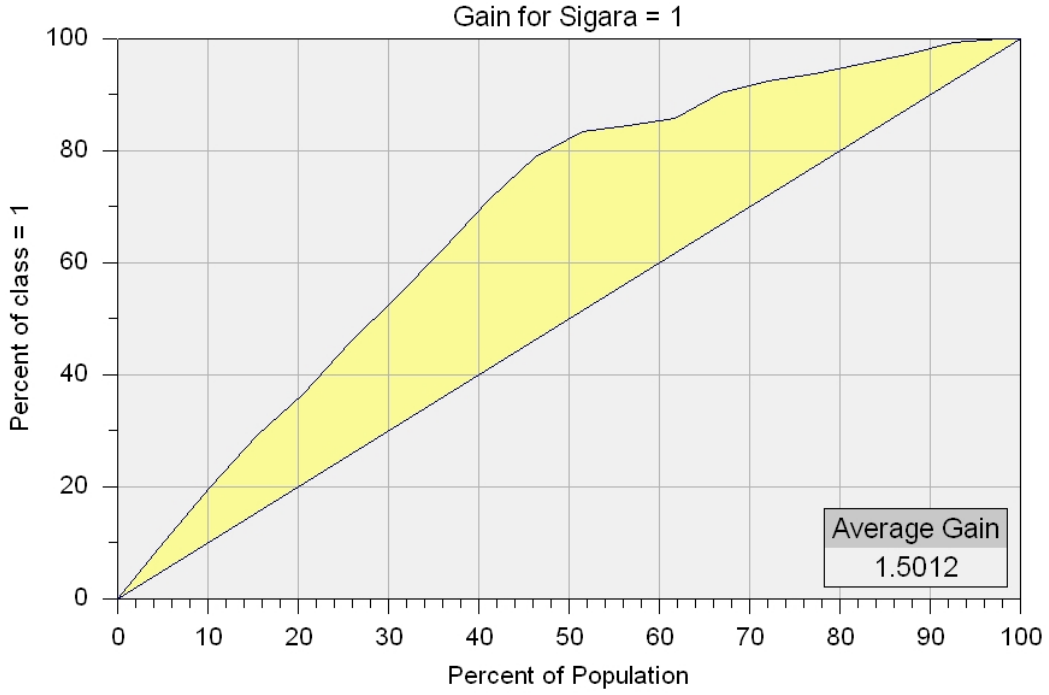
ekil 22. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim (training) verisinin denge (balance) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim verisinin denge grafi i ekil 22de gösterildi. ekildeki ye il çizgi sigara içmeyenler içerisindeki yanl, s,n,fland,rma oran,n,, mavi çizgi sigara içenler içerisindeki yanl, s,n,fland,rma oran,n,, k,rm,z, çizgi ise a ,rl,kl, yanl, s,n,fland,rma oran,n, göstermektedir.



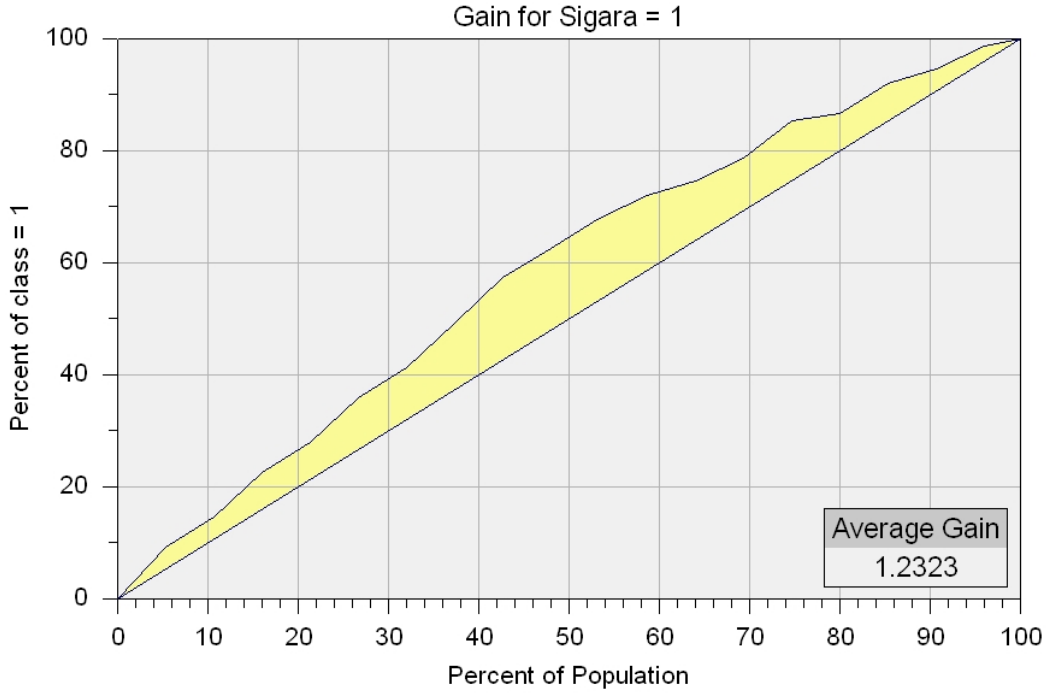
ekil 23. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test (testing) verisinin denge (balance) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test verisinin denge grafi i ekil 23te gösterildi. ekildeki ye il çizgi sigara içmeyenler içerisindeki yanl, s,n,fland,rma oran,n,, mavi çizgi sigara içenler içerisindeki yanl, s,n,fland,rma oran,n,, k,rm,z, çizgi ise a ,rl,kl, yanl, s,n,fland,rma oran,n, göstermektedir.



ekil 24. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan eğitim (training) verisinin kazanç (gain) grafiği

Sigara içenler ile içmeyenleri ayırt etmeye ilişkin eğitim verisinin kazanç grafiği ekil 24'te gösterildi. Kazanç (Gain) grafiği; Toplam olgu sayısı, hedeflenen yüzdesiyle, başlıca, de ikenin herhangi bir kategorisindeki olguların toplam sayısının yüzdesinin grafiksel gösterimidir. Buna göre ortalama kazanç 1,501 olarak bulundu.




ekil 25. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test (testing) verisinin kazanç (gain) grafi i

Sigara içenler ile içmeyenleri ay,rt etmeye ili kin e itim verisinin kazanç grafi i ekil 25'te gösterildi. Kazanç (Gain) grafi i; Toplam olgu say,s,n,n hedeflenen yüzdesiyle, ba ,ml, de i kenin herhangi bir kategorisindeki olgular,n toplam say,s,n,n yüzdesinin grafiksel gösterimidir. Buna göre ortalama kazanç 1,232 olarak bulundu.



ekil 26. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim (training) verisinin kald,raç (lift) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan e itim verisinin kald,raç grafi i ekil 26da gösterildi. Kald,raç (Lift) grafi i: Toplam olgu say,s,n,n hedeflenen yüzdesiyle, ba ,ml, de i kenin herhangi bir kategorisindeki olgulara rastlanma olas,l, ,n,n model kullanmamaya göre kaç kat fazla oldu unu gösterir. E itim veri kümesine dayanarak gerçekte tirilen modelin test veri setinde ba ar,l, olarak gerçekte tirdi i tahminlerin oran,n, % olarak gösterir. Örne in bu modelde olgular,n %10ünü kullanarak sigara içen birine rastlama oran,n,n model kullanmamaya göre yakla ,k 1,9 kat daha fazla oldu u görülmektedir.



ekil 27. Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test (testing) verisinin kald,raç (lift) grafi i

Sigara içenler ile içmeyenleri s,n,fland,rmada kullan,lan test verisinin kald,raç grafi i ekil 27'da gösterildi. Kald,raç (Lift) grafi i: Toplam olgu say,s,n,n hedeflenen yüzdesiyle, ba ,ml, de i kenin herhangi bir kategorisindeki olgulara rastlanma olas,l, ,n,n model kullanmamaya göre kaç kat fazla oldu unu gösterir. E itim veri kümesine dayanarak gerçekte tirilen modelin test veri setinde ba ar,l, olarak gerçekte tirdi i tahminlerin oran,n, % olarak gösterir. Örne in bu modelde olgular,n %10'ünü kullanarak sigara içen birine rastlama oran,n,n model kullanmamaya göre yakla ,k 1,1 kat daha fazla oldu u görülmektedir.

TARTI MA

Çal, mada, ya , cinsiyet, medeni durum, karde say,s,, gelir düzeyi, e itim durumu, alkol kullan,m, ve aile öyküsü de i kenlerinin sigara içme ve b,rakma üzerine olan etkileri çok katmanl, perseptron YSA yöntemiyle analiz edildi.

Son y,llarda çok katmanl, perseptron YSA yönteminin sa lık alan,nda uygulamalar,n,n yayg,nla t, , görülmektedir. Süt ve ark. çal, malar,nda koroner arter hastal, , tan,s, koymada çok katmanl, perseptron YSA yönteminin etkinli ini incelemi ler ve bu yöntemi lojistik regresyon analizi ve quadratik diskriminant analizi ile kar ,la t,rm, lard,r. Çal, ma sonucunda çok katmanl, perseptron YSA yönteminin koroner arter hastal, , tan,s, koymada lojistik regresyon analizi ve quadratik diskriminant analizinden daha do ru tan, koydu unu bildirmi lerdir (53).

Süt ve ark. temporomandibular eklem hareketlerinin, dil hareketlerinin, antropometrik ölçümlerin, Cormack lehane s,n,fland,rma skoru ile mallampati skorunun zor entübasyonu tahmin etmedeki s,n,fland,rma özelliklerini çok katmanl, perseptron yapay sinir a lar, ve karar a açlar,yla inceledikleri çal, malar,nda zor entübasyonu tahmin etmede hastan,n antropometrik ölçümlerinden yararlanman,n di er yöntemlere göre daha yüksek do ruluk oranlar, sa lad, ,n, bildirmi lerdir (54).

Yan ve ark. çal, malar,nda kalp hastal, , tan,s, koymada çok katmanl, perseptron YSA yönteminin etkinli ini incelemi lerdir. T,bbi karar destek sistemleri ile çok katmanl, perseptron YSAın, kar ,la t,rm, lard,r. Çal, mada çok katmanl, YSA geri yayl,m algoritmas, kullan,larak çok katmanl, perseptron YSA yönteminin t,bbi karar destek sistemlerinden daha do ru tan, koydu unu bildirmi lerdir (55).

Türe ve ark. çal, malar,nda hipertansiyonu tahmin etmede s,n,fland,rma tekniklerinin performanslar,n, kar ,la t,rm, lard,r. Çal, mada yapay sinir a lar, (MLP, RBF), karar a açlar,

(CART, QUEST, CHAID, MARS) ve istatistiksel sınıflandırma yöntemleri (FDA, lojistik regresyon analizi) kullanılarak söz konusu yöntemlerin sınıflandırma performansları karşılaştırıldı. Sonuç olarak YSA'nın (MLP ve RBF) diğer tekniklere göre hipertansiyon hastalarının tahmin etmede daha doğru sonuçlar verdiğini bildirmişlerdir (56).

Subaşı ve ark. YSA ve lojistik regresyon analizi kullanarak EEG frekanslarının bazal epilepsi tanısında koymadaki performansları karşılaştırdıkları çalışmalarında MLP'nin lojistik regresyondan daha iyi sınıflandırma sonuçları verdiğini bulmuşlardır (57).

Güler ve Ubeyli göz tutulumu olan Behçet hastaları ile sağlıklı kişileri sınıflandırmada oftalmik arterial dopler sinyallerinin etkinliğini MLP yöntemini kullanarak incelemiştir. Çalışma sonucunda MLP'nin sağlıklı bireyleri doğru sınıflandırma yüzdesinin %96,43 olduğunu, göz tutulumlu Behçet hastalarını doğru sınıflandırma yüzdesinin %93,75 olduğunu bulmuşlardır. Oftalmik arterial dopler sinyalleri baz alınarak delta bar delta e-İtim algoritması ile e-İtilen MLP'nin Behçet tanısında koymada etkin olduğunu bildirmişlerdir (58).

Çalışmamızdan elde edilen sigara içenler ile bırakılmayanları ayırt etmede çok katmanlı YSA'nın e-İtim (training) ve test (testing) sonuçları incelendiğinde e-İtim sonuçlarına göre duyarlılık %83,4, özgüllük %62,3, PKD'nin %68,9, NKD'nin %79,2 ve doğruluk oranının %72,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %65,3, özgüllük %46,7, PKD %55,0, NKD %57,4 ve doğruluk oranı %56,0 olarak bulundu. ROC e-İrisi altında kalan alan ise e-İtim verisine göre 0,747, test verisine göre ise 0,614 olarak bulundu. Poynton ve ark. çalışmalarıda 20 farklı deri kenarı kullanarak ösigara içenleri ve ösigaray bırakılmayanları ayırt etmede backpropagation YSA yöntemi kullanılmaları ve ROC e-İrisi altında kalan alan 0,766 olarak belirlenmiştir. Çalışmamızda 8 girdi deri kenarı kullanılarak ROC e-İrisi altında kalan alan 0,614 olarak bulunmuştur, oysa Paynton ve ark. çalışmalarıda 20 girdi deri kenarı kullanılarak e-İrisi altında kalan alan 0,766 olduğu bildirilmiştir (59).

Sigara içenler ile içmeyenleri ayırt etmede çok katmanlı YSA'nın e-İtim (training) ve test (testing) sonuçları incelendiğinde e-İtim sonuçlarına göre duyarlılık %81,1, özgüllük %84,6, PKD'nin %84,0, NKD'nin %81,8 ve doğruluk oranının %82,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %70,7, özgüllük %57,3, PKD %62,4, NKD %66,2 ve doğruluk oranı %64,0 olarak bulundu. ROC e-İrisi altında kalan alan ise e-İtim verisine göre 0,863, test verisine göre ise 0,666 olarak bulundu.

SONUÇLAR

- Çal, maya katılan hastaların yaş ortalaması, $38,4 \pm 11,5$ olarak bulundu.
- Hastaların 380'i (%50,6) kadın, 370'i (%49,4) erkekti.
- Sigara içenler ile bırakmayanlar, ayrıştırmada çok katmanlı YSA'nın eğitim sonuçlarına göre duyarlılığı %83,4, özgüllüğü %62,3, PKD'nin %68,9, NKD'nin %79,2 ve doğruluk oranı %72,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %65,3, özgüllük %46,7, PKD %55,0, NKD %57,4 ve doğruluk oranı %56,0 olarak bulundu. ROC eğrisi altında kalan alan ise eğitim verisine göre 0,747, test verisine göre ise 0,614 olarak bulundu.
- Sigara içenler ile içmeyenleri ayrıştırmada çok katmanlı YSA'nın eğitim (training) ve test (testing) sonuçları incelendiğinde eğitim sonuçlarına göre duyarlılığı %81,1, özgüllüğü %84,6, PKD'nin %84,0, NKD'nin %81,8 ve doğruluk oranı %82,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %70,7, özgüllük %57,3, PKD %62,4, NKD %66,2 ve doğruluk oranı %64,0 olarak bulundu. ROC eğrisi altında kalan alan ise eğitim verisine göre 0,863, test verisine göre ise 0,666 olarak bulundu.

ÖZET

Çalışmada, çok katmanlı, perseptron yapay sinir ağı (YSA) yöntemiyle sigara içenleri, bırakmayanlar ve içmeyenleri, olasılık faktörlerine göre sınıflandırmak ve YSA performansını belirlemek amaçlandı. Çalışmaya dahil edilen 750 hasta sigara durumlarına göre (sigara içen n=250, sigara içmeyen n=250 ve sigaray bırakmayan n=250) sınıflandırıldı. Veriler çok katmanlı, perseptron YSA yöntemi ile bilgisayar ortamında modellendi. Örneklemin rastgele seçilen %30'dük kısmı, test amaçlı için ayrılarak, %70'dük kısmı, modelin eğitim çalışması için kullanıldı. Uygulamada 13 nöronlu bir girdi katmanı, 3 nöronlu bir gizli katman ve 2 nöronlu bir çıkış katmanı, yapay sinir ağı modeli kullanıldı. Çok katmanlı, perseptron YSA'nın performansını belirlemek için ROC eğrileri, kaldıraç grafikleri, kazanç grafikleri ile duyarlılık, özgüllük, pozitif-negatif kestirim oranları ve doğruluk oranları esas alındı. Sigara içenler ile bırakmayanlar, ayrıştırmada çok katmanlı, YSA'nın eğitim sonuçlarına göre duyarlılık %83,4, özgüllük %62,3, PKD (pozitif kestirim oranı) %68,9, NKD (negatif kestirim oranı) %79,2 ve doğruluk oranı %72,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %65,3, özgüllük %46,7, PKD %55,0, NKD %57,4 ve doğruluk oranı %56,0 olarak bulundu. ROC eğrisi altında kalan alan ise eğitim verisine göre 0,747, test verisine göre ise 0,614 olarak bulundu. Sigara içenler ile içmeyenleri ayrıştırmada ise eğitim sonuçlarına göre duyarlılık %81,1, özgüllük %84,6, PKD %84,0, NKD %81,8 ve doğruluk oranı %82,9 olduğu bulundu. Test sonuçlarına göre ise duyarlılık %70,7, özgüllük %57,3, PKD %62,4, NKD %66,2 ve doğruluk oranı %64,0 olarak bulundu. ROC eğrisi altında kalan alan ise eğitim verisine göre 0,863, test verisine göre ise 0,666 olarak bulundu. Sonuç olarak çok katmanlı, perseptron YSA'nın sigara içenleri ve bırakmayanlar, sınıflandırmada etkin model olduğu görüldü.

Anahtar kelimeler: Yapay sinir ağı, Çok katmanlı, perseptron, Sigara, Duyarlılık

INVESTIGATION OF AFFECTING FACTORS ON SMOKING AND SMOKING CESSATION STATUS WITH MULTILAYER PERCEPTRON ARTIFICIAL NEURAL NETWORK

SUMMARY

In this study, it was aimed to classify smokers, non-smokers and smoking cessation by multilayer perceptron artificial neural network method in accordance with possible factors. Seven hundred and fifty patients included into the study were classified in accordance with their smoking situations as (smokers n= 250, non-smokers n=250 and cessation n=250). All data was modelled by multilayer perceptron artificial neural network method in the computer environment. While the randomized 30% of the sampling was separated for testing, 70% was used for the training study of the modal. On the practice a 13 neuron input layer, a 3 neuron hidden layer and a 2 neuron output layer were used as an artificial neural network modal. On the evaluation of the performances of multilayer perceptron artificial neural networkø sensitivity, specificity, positive-negative predictive values and truth values were based on with ROC curves, lever graphs, and gain graphs. In accordance with the training results of multilayer perceptron artificial neural networkø to distinguish the smokers and non-smokers, it was found out that sensitivity was 83,4, specificity was %62,3, positive predictive value was %68,9, negative predictive value was %79,2 and accuracy rate was %72,9. As for the testing results it was found out that sensitivity was 65,3, specificity was %46,7, positive predictive value was %55,0, negative predictive value was %57,4 and accuracy rate was

%56,0. As for the area under the ROC curve, it was found out 0,747 in accordance with training data and 0,614 in accordance with testing data. As for distinguishing the smokers and non-smokers, it was found out that - in accordance with training data, sensitivity was %81,1, specificity was %84,6, positive predictive value was %84,0, negative predictive value was %81,8, and accuracy rate was %82,9. As for the testing results, it was found out that sensitivity was %70,7, specificity was %57,3, positive predictive value was %62,4, negative predictive value was %66,2, and accuracy rate was %64,0. As for the area under the ROC curve, it was found out 0,863 in accordance with training data and 0,666 in accordance with testing data. As a conclusion it was found out that multilayer perceptron artificial neural network is an effective model on classifying smoking and cessation status.

Key words: Artificial neural network, Multilayer perceptron, Smoking, Sensitivity

KAYNAKLAR

1. Ercan , Ediz B, Hac,mustafao lu M, Kani , Bostan Ö. Kümeleme çözümlemesinin yeni do an sar,l,kl, olgulara uygulanmas,. Uluda Üni T,p Fak Derg 1997; 24(1-2-3): 17-22.
2. Elmas Ç. Yapay sinir a lar,, Ankara: Seçkin Yay,nc,l,k, 2003.
3. Memmedov M, Ery,lmaz H. Yapay sinir a lar, ile baz, istatistiksel modeller aras,ndaki ili ki. International XII. Turkish Symposium on Artificial Intelligence and Neural Network, 2003.
4. Efe Ö, Kaynak O. Yapay sinir a , uygulamalar,. stanbul: Bo aziçi Üniversitesi Yay,nlar,, 2004.
5. Gülba A. Yapay Sinir A , ve Bulan,k Mant,k Tabanlı, Algoritmalar ile Uçucu Organik Bile iklerin Miktersal Tayini (tez). Sakarya: Sakarya Üniversitesi Mühendislik Fakültesi; 2006.
6. Öztemel E. Yapay sinir a lar,, stanbul: Papatya Yay,nlar,, 2006
7. Yapay sinir a lar, <http://www.ahmetkakici.com/>
8. Hayk,n S. Neural networks for financial Forecasting. USA: John Wiley& Sons, Inc, 1999.
9. Bolat S. Yapay Sinir A lar, ile Elektrot ve zolatör Biçim Optimizasyonu (tez). stanbul: .T.Ü Mühendislik Fakültesi; 2003.

10. Altu S. İstanbul Menkul Kıymetler Borsasında Yapay Sinir Ağları, Kullanılarak Fiyat Öngörüsü (tez). Ankara: Bilkent Üniversitesi Ekonomi ve Sosyal Bilimler Enstitüsü; (1994)
11. Elmas Ç. Yapay sinir ağları, (Kuram, Mimari, Eğitim, Uygulama). Ankara: Seçkin Yayıncılık. 2003.
12. Simpson P. K., Artificial neural systems foundations, paradigms, applications, and implementations. Pergamon Press, Inc,1990.
13. Güzeli C. Genelleştirilmiş hücreli yapay sinir ağları, Elektrik Mühendisliği 5. Ulusal Kongresi, Trabzon, 1993.
14. Çelen Z. Yapay sinir ağları, ilkeleri. Su Vakfı Yayınları, 2004.
15. Seven A. Yapay Sinir Ağları ile Doku Sınıflandırma (tez). İstanbul: İstanbul T.Ü Mühendislik Fakültesi; 1993
16. Mehrotra K, Mohan C.K, and Ranka S. Elements of artificial neural networks. London: The MIT Press, 1997.
17. Yurtulu H. Yapay Sinir Ağları, Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği (Uzmanlık Tezi). Ankara: Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü; 2005.
18. Saraç T. Yapay sinir ağları, Seminer Projesi, Ankara: Gazi Üniversitesi Mühendislik Fakültesi, 2004.
19. Sarıoğlu, Bekdemir E, Erler M. Mühendislikte yapay zeka uygulamaları, I: Yapay Sinir Ağları, Kayseri: Ufuk Yayıncılık 2003.
20. Minsky M.L, and Papert, S.S. Perceptrons. Cambridge: MA:MIT Press, 1969.
21. Hawley D.D, Johnson J. D. ANN: Past, present and future, in advances in economics, finance and management. Eds. Johnson J. D. Whinston A.B. JAI Press Inc. 1994.
22. Lee C.W, Park J.A. Assessment of health-related performance using an artificial neural network. Information & Management 2001.
23. Haykin S. Neural networks: A comprehensive foundation. New York: MacMillan College Publishing Company, 1994.

24. Karlık B. Çok Fonksiyonlu Protezler için Yapay Sinir Ağları, Kullanılmaları, Milyon Elektrik Kontrol (tez). İstanbul: Yıldız Teknik Üniversitesi Mühendislik Fakültesi; 1994.
25. Auger M. Detection of Laser-Welding Defects Using Neural Networks. A Thesis for The Degree Of Master of Science (Engineering): Queen's University; 2001
26. Eker S. Artificial Neural Networks for System Identification and Control. Ders Notları, 2001.
27. Anderson D. ve McNeil G. Artificial neural networks technology, Data & Analysis Center for Software 1992.
28. Bayramoğlu F. Finansal Endekslerin Öngörüsünde Yapay Sinir Ağları, Modellerinin Kullanılması: MKB Ulusal 100 Endeksinin Güncel En Yüksek ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama (tez). Zonguldak: Karadeniz Üniversitesi İktisadi ve İdari Bilimler Fakültesi; 2007.
29. Fausset L. Fundamentals of neural network (architectures, algorithms and applications). Prentice Hall, 1999.
30. Jain A.K, and Mao J. Artificial neural networks: a tutorial. IEEE Computer Special Issue on Neural Computing 1996.
31. Masters T. Practical Neural Network Recipes in C++. USA: Academic Press 1993.
32. Narendra K. S, Parthasarathy K. Identification and control of dynamic systems using neural networks. IEEE Transactions on Neural Networks 1990; 4-27.
33. Giannakis G. B, and Mendel J. M. Identification of non-minimum phase systems using higher-order statistics. IEEE Trans. Acoust., Speech, Signal Processing 1989; 37: 360-377.
34. Zhi Q. A Quasi-ARMAX approach to modelling of non-linear systems. International Journal of Control 2001.
35. Yang ZJ, Sagara S, Tsuji T. System impulse response identification using a multiresolution neural network. Automatica 1997; 33: 1345-1350
36. Narendra K.S, Mukhopadhyay S. Adaptive control using neural networks and approximate models. IEEE Trans. on Neural Networks 1997; 8: 475-485
37. Chen S, Billings S. A. Neural networks for nonlinear dynamic system modeling and identification. International J. Control 1992; 2: 319-346

38. Billings S. A, Zheng G. L. Radial basis function network configuration using genetic algorithms. Neural Networks 1995.
39. Bossley K.M. Neuro-Fuzzy Approaches in System Identification University of Southampton (Doctor of Philosophy Thesis). England: Faculty of Engineering and Applied Science, Electronics and Computer Science Department: Southampton University; 1997.
40. Öz ahin M. Türkiye Otomotiv Sektörünün Kendini Örgütleyen Haritalar ile Finansal Analiz (tez). Adana: Çukurova Üniversitesi Mühendislik Fakültesi; 2009.
41. Auclair A. Feed-Forward Neural Networks Applied to the Estimation of Magnetic Distributions (M.S. Thesis). Kanada: Department of Electrical and Computer Engineering; McGill University; 2004 128s
42. Mohamed N. M. S. High-Speed Network Traffic Prediction and its Applications Using Neural Networks and Self-Similar Models (Ph. D. Thesis). ABD: Graduate Faculty of the School of Engineering: Southern Methodist University; 2004. 160s.
43. Demuth H, Beale M, Hagan M. T. Neural network Design. Wadsworth Publishing Company Pub. 1995.
44. Özyard,mc, N. Sigara ve sa l,k. Uluda Üniversitesi T,p Fakültesi Yay,n, 2000: 49-85.
45. Bay,k A. Sigara içen hastalar,n, sigaray, b,rakmaya yönelik motivasyon geli tirmeleri için hem irelik dan, manl , üzerine bir çal, ma. Sigara ile Sava I. Ulusal Hem irelik Sempozyumu Bildiri Özet Kitab, s.9, zmir, 1993.
46. Türk Toraks Derne i <http://www.toraks.org.tr/journal/text.php3?id=14>
47. Sigara ve Beyin
[http://www.havanikoru.com/Docs Tutun Dumaninin Zararlari/Sigara ve Beyin.pdf](http://www.havanikoru.com/Docs_Tutun_Dumaninin_Zararlari/Sigara_ve_Beyin.pdf)
48. Johnson J.L, Lovato C.Y, Maggi S, et al. Smoking and adolescence: narratives of indentity. Research in Nursing & Health 2003 Oct; 26(5): 387-397
49. Gençöz F, Soykan Ç, Soykan A, Gençöz T. Sigara ba ,ml,l , ve tedavisi, Ankara: Art Ofset Matbaac,l,k San. Tic. Ltd. ti., 2003.

50. Ergeneilek E. Sigara Kullanan Hemirelerin Sigaray, Bırakmaya Yönelik Girişimleri ve Sonuçlar, (tez). Adana: Çukurova Üniversitesi Sağlık Bilimleri Enstitüsü Hemirelik Anabilim Dalı, 2005.
51. Yılmaz N. Sigara İçen Eğitim Fakültesi Öğrencilerinin Sigara İçme Davranışları ve Bırakma İsteğinin Belirleyicileri (tez). Zonguldak: Karadeniz Üniversitesi Tıp Fakültesi; 2010.
52. Dabak S. Cigarette smoking and health. A scientific aspect of cigarette smoking. Logos Yayınları, 2005; 35-73.
53. Süt N, Şenocak M. Assessment of the performances of multilayer perceptron neural networks in comparison with recurrent neural networks and two statistical methods for diagnosing coronary artery disease, Expert Syst 2007; 24:131-142.
54. Süt N, Çopuroğlu E, Çolak A, Yılmaz A. Yapay sinir ağları ve karar ağaçları zor entübasyon tanısında koymadaki etkinliklerinin karşılaştırılması, XIII. Ulusal Biyoistatistik Kongresi 12-14 Eylül 2011 Kızılcakhamam-Ankara, Bildiri özetleri kitabı, sf:73.
55. Yan H, Jiang Y, Zheng J, Peng C, Li Q. A multilayer perceptron-based medical decision support system for heart disease diagnosis, Expert Syst 2006; 30:272-281.
56. Türe M, Kurt I, Kurum AT, Ozdamar K. Comparing classification techniques for predicting essential hypertension, Expert Syst 2005;29:583-588.
57. Subaşı A, Erçelebi E. Classification of EEG signals using neural network and logistic regression, Computer Methods and Programs in Biomedicine, 2005; 78:87-99.
58. Güler S, Übeyli E. Detection of ophthalmic arterial doppler signals with Behcet disease using multilayer perceptron neural network, Computers in Biology and Medicine, 2005; 35:121-132.
59. Poynton MR, McDaniel AM. Classification of smoking cessation status with a backpropagation neural network. Journal of Biomedical Informatics 2006; 39:680-686.

EK LLER L STES

ekil 1: Biyolojik sinir hücresinin yap,s,

ekil 2:Yapay sinir hücresinin yap,s,

ekil 3: Do rusal aktivasyon fonksiyonunun ekilsel gösterimi

ekil 4: Ad,msal Fonksiyonunun ekilsel Gösterimi

ekil 5: Sigmod Aktivasyon Fonksiyonunun ekilsel Gösterimi

ekil 6: Hiperbolik tanjant fonksiyonunun ekilsel gösterimi

ekil 7: Genel bir çok katmanl, perseptron yap,s,

ekil 8. Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin e itim (training) verisinin ROC e risi

ekil 9. Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin test (testing) verisinin ROC e risi

ekil 10. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim (training) verisinin olas,l,k kalibrasyon (Probability Calibration) grafi i

ekil 11. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin olas,l,k kalibrasyon (Probability Calibration) grafi i

ekil 12. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan e itim (training) verisinin denge grafi i (Balance chart)

ekil 13. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin denge grafi i (Balance chart)

ekil 14. Sigara içenler ile b,rakm, lar, ay,rt etmeye ili kin e itim (training) verisinin kazanç grafi i (Gain chart)

ekil 15. Sigara içenler ile b,rakm, lar, s,n,fland,rmada kullan,lan test (testing) verisinin kazanç grafi i (Gain chart)

ekil 16. Sigara içenler ile bırakılmayanlar arasında kullanılan eğitim (training) verisinin kaldıraç grafiği (Lift chart)

ekil 17. Sigara içenler ile bırakılmayanlar arasında kullanılan test (testing) verisinin kaldıraç grafiği (Lift chart)

ekil 18. Sigara içenler ile içmeyenleri ayırt etmede eğitim (training) verisinin ROC eksiği

ekil 19. Sigara içenler ile içmeyenleri ayırt etmede test (testing) verisinin ROC eksiği

ekil 20. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan eğitim (training) verisinin olasılık kalibrasyonu (probability calibration) grafiği

ekil 21. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan test (testing) verisinin olasılık kalibrasyonu (probability calibration) grafiği

ekil 22. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan eğitim (training) verisinin denge (balance) grafiği

ekil 23. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan test (testing) verisinin denge (balance) grafiği

ekil 24. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan eğitim (training) verisinin kazanç (gain) grafiği

ekil 25. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan test (testing) verisinin kazanç (gain) grafiği

ekil 26. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan eğitim (training) verisinin kaldıraç (lift) grafiği

ekil 27. Sigara içenler ile içmeyenleri sınıflandırmada kullanılan test (testing) verisinin kaldıraç (lift) grafiği

TABLÖLAR İÇİNDİR

Tablo 1. Biyolojik sinir ağı, ve yapay sinir ağı, karşılaştırılması,

Tablo 2. Çok katmanlı, perceptron YSA'larının tuning parametreleri

Tablo 3. Hastaların sosyo-demografik özelliklerine göre dağılımı,

Tablo 4. Hastaların sigara içme durumlarına göre sosyo-demografik özelliklerinin dağılımı,

Tablo 5. Sigara içenler ile bırakmış olanların eğitim (training) ve test (testing) sonuçları,

Tablo 6. Sigara içenler ile içmeyenlerin eğitim (training) ve test (testing) sonuçları,

ÖZGEÇM

1985 y,1,nda stanbulda do du, ilk, orta ve lise ö renimini Küçükçekmece'de tamamlad,. 2005 y,1,nda Mimar Sinan Güzel Sanatlar Üniversitesi Fen Edebiyat Fakültesi statistik Bölümünü kazand,, 2009 y,1,nda mezun oldu. ubat 2010 tarihinde Trakya Üniversitesi Sa 1,k Bilimleri Enstitüsünde Biyoistatistik yüksek lisans e itimine ba lad,.