

ÖZET

Doktora Tezi

HİBRİT BULANIK SİNİR AĞINI KULLANARAK BİR SINIFLANDIRMA VE KURAL ÇIKARMA SİSTEMİNİN GELİŞTİRİLMESİ

Humar KAHRAMANLI

Selçuk Üniversitesi Fen Bilimleri Enstitüsü

Matematik Anabilim Dalı

Danışman: Prof. Dr. Novruz ALLAHVERDİ

2008, 189 sayfa

Jüri: Prof. Dr. Ahmet ARSLAN

Prof. Dr. Novruz ALLAHVERDİ

Doç. Dr. Galip OTURANÇ

Doç. Dr. İbrahim TÜRKOĞLU

Yrd. Doç. Dr. Aynur KESKİN

Otomatik veri toplama araçları ve veri tabanı teknolojilerindeki gelişme, her geçen gün büyük miktarda bilgi depolanması sonucunu doğurmuştur. Bu verilerin içindeki gizli örüntüler, geleneksel çözümleme araçlarıyla bulunamamaktadır. Toplanan veri miktarı büyüdükçe ve toplanan verilerdeki karmaşıklık arttıkça, daha iyi çözümleme tekniklerine ihtiyaç duyulmaktadır.

Sınıflandırma, veri madenciliği araştırmalarının önemli bir parçasıdır. Amaç, yeni bir nesnenin, belirli sınıflar içinde hangi sınıfa ait olup olmadığını belirleyecek bir sınıflayıcı oluşturmaktır. Bu amaçla bir çok yöntem geliştirilmiştir. Bu yöntemler genellikle başarılı olmasına rağmen özellikle tıbbi veri madenciliği gibi gerçek dünya problemlerinde henüz arzu edilen seviyeye ulaşamamıştır.

Bu çalışmada tıp alanında sınıflandırma yapılabilmesi için hibrit bulanık bir sinir ağı önerilmiş ve bir algoritma geliştirilmiştir. Çalışmada bu güne kadar yapılandırılmış farklı olarak, ayrık nitelikler ikili olarak kodlanırken, gerçel nitelikler bulanıklaştırılmaktadır. YSA ve BSA'nın birleşiminden oluşan bir hibrit ağ oluşturularak kodlanmış veriler hibrit ağa sunulmaktadır. Eğitim algoritması olarak, Geri Yayılım kullanılmaktadır. Bu ağın iki farklı veri tabanında uygulaması gerçekleştirilmektedir. Sistemin performansını değerlendirmek için 10 kez çapraz doğrulama ve "eğitim"+"test" yöntemleri kullanılmaktadır.

Yapay Sinir Ağları (YSA) sınıflandırma problemlerinde önemli bir yere sahiptir. Ancak YSA yapısı itibariyle "kara kutu" olduğundan, çıkan sonucun yorumlanması mümkün olmamaktadır. Sonucun doğru şekilde yorumlanması için son yıllarda bir çok çalışma yapılmış ve değişik kural çıkarma algoritmaları sunulmuştur.

Bu çalışmada ikinci olarak, hibrit sistemden kural çıkarmak için bir yöntem sunulmaktadır. Bunun için sinir ağı eğitimi bitirdikten sonra oluşan fonksiyon çıkarılmakta ve optimize edilmektedir. Optimizasyon için bir yapay bağışıklık algoritması olan Opt-aiNET kullanılmaktadır. Yöntem iki veri tabanında test edilmekte ve başarılı olduğu gözlemlenmektedir.

Anahtar Kelimeler – Sınıflandırma, Kural çıkarma, Sinir Ağları, Bulanık Mantık, Optimizasyon, Yapay Bağışıklık.

ABSTRACT

Phd Thesis

DEVELOPING A CLASSIFICATION AND RULE EXTRACTION SYSTEMS USING HYBRID FUZZY NEURAL NETWORK

Humar KAHRAMANLI

Selçuk University

Graduate School of Natural and Applied Sciences

Department of Mathematics

Supervisor: Prof. Dr. Novruz ALLAHVERDI

2008, 189 pages

Jury: Prof. Dr. Ahmet ARSLAN

Prof. Dr. Novruz ALLAHVERDI

Assoc. Prof. Dr. Galip OTURANÇ

Assoc. Prof. Dr. İbrahim TÜRKOĞLU

Asist. Prof. Dr. Aynur KESKIN

Developments in automatic data collecting tools and database technologies have caused the result of storing large amount of data day by day. Hidden patterns in this datas can not be founded by conventional solution tools. The necessity of better solution

techniques increases as the amount of collected data and the complexity in the collected data increase.

Classification is an important part of data mining researches. Forming a classifier that will determine to which class a new object belongs to among the other specific classes, is the aim. Many methods have been improved via this aim. Although these methods are usually successful, the classification accuracy hasn't reached at the desired level especially in real world problems like medical data mining.

In this study, a hybrid fuzzy neural network has been proposed for being done classification in the field of medicine and an algorithm has been improved. In the study, as different from the studies till today; real attributes are fuzzified while crisp attributes are being coded as binary. By forming an hybrid network that occurs by the combination of ANN and FNN, coded data are presented to this hybrid network. Back propagation is used as training algorithm. Application of this network in two different databases is implemented. 10-fold cross validation and "training" + "test" methods are used for evaluating performance of the system.

Artificial Neural Networks (ANN) has an important place in classification problems. But being ANN a "black - box" because of its structure, interpretation of the result is impossible. Many studies have been performed and different rule extraction algorithms have been presented in recent years for obtaining the correct interpretation of result.

In this study, as secondly proposed, a method has been presented for extraction of rules from a hybrid system. For this reason, the function that forms after neural network finishes training, is extracted and optimized. Opt-aiNET which is an Artificial Immune Algorithm, is used for optimization. The method has been tested in two databases and it has been observed that the method is successful.

Keywords: Classification, rule extracting, neural networks, fuzzy logic, optimization, artificial immune methods.

1. GİRİŞ

Veri, kaydedilen ve sezgisel anlamı olan bilinen gerçeklerdir. Veri tabanı ise mantıksal olarak ilişkili verilerin koleksiyonudur. Veri tabanı aşağıdaki özelliklere sahiptir.

- Bir veri tabanı gerçek dünyanın bazı yönlerini sunar;
- Bir veri tabanı mantıksal olarak uyumlu veri koleksiyonudur;
- Bir veri tabanı özel amaçlar için tasarlanır ve oluşturulur;
- Bir veri tabanı herhangi bir büyüklükte ve istenilen karmaşıklıkta olabilir.

Otomatik veri toplama araçları ve veri tabanı teknolojilerindeki gelişme, veritabanlarında, veri ambarlarında ve diğer bilgi depolarında çok miktarda bilgi depolanması sonucunu doğurmuştur. Büyük miktarlardaki verilerin içindeki gizli örüntüler, geleneksel çözümleme araçlarıyla bulunamaz. Toplanan veri miktarı büyüdükçe ve toplanan verilerdeki karmaşıklık arttıkça, daha iyi çözümleme tekniklerine olan ihtiyaç da artmaktadır (internet: Tıp Bilişimi Güz Okulu, http://www.turkmia.org/eski/file/231verimadenciligi_baykal.ppt, son erişim: Ocak, 2008). Veri tabanındaki gizli bilgiler, bilgi keşfi ya da veri madenciliği olarak bilinen teknikler yardımıyla çözümlenebilir. Veri madenciliği, temel olarak bilgisayar destekli bir bilgi çözümleme işlemi olup, verilerin içerisindeki desenlerin, ilişkilerin, düzensizliklerin, kuralların keşfedilmesidir. Amaç, daha önceden fark edilmemiş veri desenlerini tespit edebilmektir. Keşif, ne olabileceği konusunda önceden belirlenmiş bir fikir ya da hipotez olmadan, veri tabanı içerisinde gizli desenleri arama işlemidir (internet: Veri Madenciliği ve Elektronik Ticaret, <http://www.inet-tr.org.tr/inetconf7/eposter/inceoglu.doc>, son erişim: Ocak, 2008). Büyük veri tabanlarında kullanıcının bulamayacağı ve hatta bulmak için gerekli soruyu bile düşünemeyeceği birçok gizli desen olabilir. Bu özelliklerinden dolayı veri madenciliği son yıllarda tıp, ticari ve finansal sektörlerde önem kazanan bir kavram olarak karşımıza çıkmaktadır. Büyük miktarlardaki veriden faydalı bilgi çıkarımını

amaçlayan veri madenciliği ile ilgili çalışmalar gün geçtikçe artmakta, farklı tekniklerin kullanımı ile ilerleme kaydetmektedir.

Veri madenciliği ve bilgi keşfi özellikle elektronik ticaret, bilim, tıp, iş ve eğitim alanlarındaki uygulamalarda yeni ve temel bir araştırma sahası olarak ortaya çıkmaktadır. Veri madenciliği teknikleri kullanılarak, eldeki yapısız gibi görünen veriden, anlamlı ve kullanışlı bilgiyi çıkarmaya yarayacak tümevarım işlemleri formüle edilir, analiz yapılır, geniş veri kümelerinden desenler, değişiklikler, düzensizlikler ve ilişkiler çıkartılır.

Temel olarak veri madenciliği, veri kümeleri arasındaki desenlerin ya da düzenin, verinin analizi ve yazılım tekniklerinin kullanılması ile ilgilidir. Veriler arasındaki ilişkiyi, kuralları ve özellikleri belirlemekten bilgisayar sorumludur. Amaç, daha önceden fark edilmemiş veri desenlerini tespit edebilmektir. Bulunması gereken bilgi türüne bağlı olarak veri madenciliğinin birliktelik kuralı bulma, sınıflandırma, kümeleme gibi değişik teknikleri kullanılır (internet: Veri Madenciliği ve Elektronik Ticaret, <http://www.inet-tr.org.tr/inetconf7/eposter/inceoglu.doc>, son erişim: Ocak, 2008).

Veri birikmesinin en yoğun yaşandığı alanlardan birisi, tıptır. Özellikle günümüzde artık neredeyse tüm tıbbi cihazların sayısal hale gelmesi bu sonucu doğal hale getirmiştir. Kağıt üzerinde veri toplanan klasik hastane bilgi sistemlerinden farklı olarak sayısal verilerden yararlanmak her ne kadar çok daha kolay gibi görünse de, aslında diğer alanlardaki veriler gibi bunların da bireysel çalışmalarla işlenmesi ve yorumlanması imkansız hale gelmiştir. Bu nedenle veri madenciliği teknikleri tıbbi araştırmaların neredeyse vazgeçilmez araçlarından biri haline gelmiştir. Tıpta veri madenciliği tıp alanında uzmanların ve veri madenciliği uzmanlarının birlikte çalışmasını gerektiren bir alandır.

Tıbbi karar verme, çok yönlü bir işlemdir ve öncelikli amaç doğru teşhisin yapılmasıdır. Bu amaca ulaşmak için uygun verinin bulunması, verinin özelliklerinin çıkarılması ve yeni verinin analizinin yapılması gerekmektedir. Hekimler, karar verme işleminde çeşitli istatistiksel teknikler ile veriyi işlemektedirler. Verinin karmaşıklığı ve boyutunun artması durumunda veri analizi için bilgisayarların kullanımı gerekli olmaktadır. İstatistiksel analizlerin yanı sıra bu tip problemlerin

çözümü için yeni yöntemler geliştirilmeye çalışılmaktadır. Geliştirilen bu yöntemlerden en çok kullanılanları ÇKP, LVQ, Kohonen, Elman gibi YSA algoritmaları, bulanık mantık teknikleri, genetik algoritmalar ve k -en yakın komşu, k -ortalamalar, bulanık c -ortalamalar, karar ağaçları gibi makine öğrenimi yöntemleridir.

Sınıflandırma veri madenciliğinde önemli alanlardan biridir. Sınıflandırma neticesinde bir model oluşturulmakta ve yeni gelen bir verinin hangi sınıfa ait olacağı belirlenebilmektedir. Buna tıp alanında hastalık teşhisi için sıklıkla ihtiyaç duyulmaktadır. Sınıflandırma için kullanılan en yaygın yöntemlerden birisi Yapay Sinir Ağları'dır. YSA'lar bu tip problemlerde genellikle başarılı olmalarına rağmen, özellikle tıbbi problemler gibi gerçek dünya problemlerinde arzu edilen başarıya ulaşamamaktadırlar. Bu sorunu çözmek için BM-YSA, genetik-YSA, BM-genetik gibi değişik hibrit sistemler geliştirilmiştir.

1.1. Çalışmanın Amacı ve Önemi

Bu çalışmadaki temel amaç bazı tıbbi verilerin sınıflandırılması ve yeni bir hastayla ilgili tahminin elde edilebilmesidir. Bu tür verilerle çalışırken bir çok problemle karşılaşilmektedir. Bunlar veri toplama araçlarındaki eksiklikler, yeterli miktarda verinin bulunmaması, ölçümlerin yanlış yapılmış, bazen yapılmamış veya kaydedilmemiş olmasıdır. Bu olumsuzluklara rağmen bu konuda bir çok çalışma yapılmıştır. Ancak bu çalışmalarda elde edilen sonuçların tam başarılı olduğu söylenememektedir.

Araştırmacılar genellikle verileri ikili veya gerçel olarak kodlamış ve uygulama yapmışlardır. Ama tıbbi verilerde nitelikler genellikle iki tiptir: Ayrık ve gerçel. Örneğin bir hastalık dolayısıyla başvuran hastanın kalp ağrısı varsa, bu sadece tipik anjin (kalbe yetersiz kan gelmesi sonucu oluşan ağrı), atipik anjin, anjin olmayan ağrı ve asemptomatik ağrı olmak üzere dört şekilde olabilmektedir veya bir hastanın ailesinde belli bir hastalık ya vardır yada yoktur. Bu tip veriler ikili

kodlamaya çok müsaitken, hastanın tansiyonunun değeri, kolesterol miktarı geniş bir alanda değer alabilmekte ve doktorlar tarafından düşük, normal, yüksek olarak değerlendirilmektedir. Bu düşük, normal ve yüksek değerler göreceli olabilmekte, bir hasta için düşük sayılan 90 tansiyon değeri, örneğin böbrek rahatsızlığı olan birisi için normal bir değer olabilmektedir. Bundan dolayı bu tür verileri ikili değil bulanık veri olarak değerlendirmenin doğru olacağı düşünülerek bu çalışmada iki farklı kodlama yapılmıştır. Kesin nitelikler ikili olarak, bulanık nitelikler ise üyelik dereceleriyle kodlanmıştır. Sınıflandırma için Yapay Sinir Ağı (YSA) ve Bulanık Sinir Ağı (BSA)’nın birleşiminden oluşan bir hibrit bulanık sinir ağı geliştirilmiştir.

Yalnız önerilen hibrit bulanık sinir ağı yüksek sınıflandırma başarısına ulaşmasına rağmen, sinir ağları “kara kutu” özelliğini taşıdığı için buradaki çözüm pek anlaşılır olmamaktadır. Bu sorunu çözmek için sinir ağının oluşturduğu yüzey fonksiyonunun optimizasyonuna dayalı bir yöntem önerilmiş, sonuç olarak veri tabanını modelleyecek olan “Eğer - O halde” kuralları kümesi elde edilmiştir.

Bu çalışmada temel olarak aşağıdakiler amaçlanmıştır:

1. Geleneksel sınıflandırma ve kural çıkarma yöntemleri incelenerek, bu sistemlerin avantaj ve dezavantajlarının belirlenmesi;
2. Sınıflandırma yapmak için hibrit bulanık sinir ağının ve bu ağın eğitim algoritmasının oluşturulması;
3. Hibrit bulanık sinir ağından kural çıkarmak için yöntem oluşturulması;
4. Oluşturulan yöntemlerin uygulanması;
5. Sonuçların analizi.

Bu çalışmada önerilen hibrit bulanık sinir ağı ve kural çıkarma yöntemleri kullanılarak belirli bir alandaki hastalık çok düşük bir hatayla teşhis edilebilmektedir. Bu da çalışmanın önemini göstermektedir. Ayrıca, yöntem hem tıp, hem de diğer alanlardaki veri tabanları için de uygulanabilir niteliktedir.

1.2. Sınıflandırma ve Kural Çıkarma

Sınıflandırma, veri madenciliği araştırmalarının önemli bir parçasıdır. Her biri önceden belirlenmiş bir sınıfa ait olduğu belli olan veriler kümesi verildiğinde yeni bir verinin hangi sınıfa ait olacağına karar verecek modeli bulma, sınıflandırma problemidir. Oluşturulan model eğitim verisinin analizine dayanmaktadır (Han ve Kamber, 2001).

Genelde sınıflandırma süreci iki adımdan oluşmaktadır. İlk adımda gözlenmiş veriler ve bir sınıflandırma algoritması kullanılarak sınıflandırma kuralları oluşturulur. İkinci adımda ise oluşturulan sınıflandırma kuralları kullanılarak veriler sınıflandırılır.

Genellikle sınıflandırma problemlerini çözmek için istatistiksel yöntemler, makine öğrenimi (örneğin yapay sinir ağları ve karar ağaçları (Duda ve ark., 2000) ve uzman sistemler (Jackson, 1998)) teknikleri kullanılmaktadır.

Sınıflandırma için kullanılan istatistiksel yöntemler: Fisher Doğrusal Diskriminant Analizi (LDA) (Fisher, 1936), Quadratik ve Lojik Diskriminant analizdir. Bu teknikler dağılım grupları ve diskriminant fonksiyonuna göre farklılık gösterirler (Pendharkar ve ark., 1999). Doğrusal modeller kolay yorumlanabilir ve güvenilir sonuçlar ürettiği için karar verme (decision making) için sıklıkla tercih edilmiştir (Hand, 1981). Doğrusal olmayan modeller eğitim verisinde daha başarılı olmalarına rağmen test verisinde başarıları keskin düşme eğilimindedir (Altman ve ark., 1981). İstatistiksel yöntemlerin en büyük dezavantajı gerçek dünya verilerinin (real-world data) sıklıkla parametrik dağılım varsayımına uygun olmayışdır. Parametrik olmayan yöntemler daha az kısıtlayıcı olmaktadır (Pendharkar ve ark., 1999). Parametrik olmayan yöntemlerin içinde yaygın kullanılanlar k -en yakın komşu ve lineer programlama yöntemleridir (Freed ve Glover, 1981; Hand, 1981).

Sınıflandırma için kullanılan makine öğrenimi yöntemleri iki kategoriye ayrılmaktadır: 1) İlişkili (connectionist) ve 2) tümevarımsal (induktiv) (Pendharkar ve ark., 1999). İlişkili yöntemlerden en çok kullanılan algoritma geri yayılımdır

(Rumelhart ve ark., 1986). Sınıflandırma için bir çok tümevarımsal algoritma önerilmiştir. Bunların arasında en yaygın kullanılanlar CART (Breiman ve ark., 1984), ID3 (Quinlan, 1986), ve CN2 (Clark ve Niblett, 1987)'dir.


Sınıflandırma için son yıllarda dikkat çeken üçüncü grup yöntemler genetik algoritmalar ve genetik programlamayı içeren evrimsel hesaplamalardır. (Bhattacharyya & Pendharkar, 1998; Koehler, 1991).

YSA bir çok alanda veri madenciliği problemlerini çözmek için başarıyla uygulanmıştır. Bu bağlamda çok katmanlı algılayıcılar (perseptron) yüksek sınıflandırma başarısına ulaşabilirler, ancak bu tip ağların elde ettiği bilgiler genellikle insanlar için anlaşıl mazdır (Duch ve ark., 2000), yani yorumlanamamaktadır. Bu durum, insanların anlayıp yorumlayabilecekleri örüntülerin gerekli olduğu veri madenciliği uygulamalarında önemli sorundur (Kaufman ve Rousseeuw, 1990). Bu nedenle, YSA'dan kural çıkarmak için bir çok yöntem geliştirilmiştir (Hruschkaa ve Ebecken, 2006).

Çok katmanlı ağlardan kural çıkarmak için kullanılan yöntemleri iki gruba ayırmak mümkündür. Birinci grup çıkış sınıflarını doğrudan giriş verileriyle ifade eden genel kurallardan oluşmaktadır. İkinci grup daha yerel kurallar çıkarmaktadır. Bunun için çok katmanlı ağ tek katmanlı ağ kümesine dönüştürülmektedir. Kümedeki her ağ için kurallar oluşturulup, sonra bu kurallar mantıksal işlemcilerle bir araya getirilmektedirler (Craven, 1996).

Şekil 1.1'de en basit bir sinir ağı görülmektedir. Bu ağ bir giriş ve bir çıkış katmanına sahiptir. Bu ağın girişi ve çıkışı Boole değerlerdir. Bu tip ayrık giriş ve çıkışlara sahip her ağ giriş vektörlerinin sayısı sınırlı olduğundan dolayı sınırlı sayıda kurallarla ifade edilebilir. Bu ağ için evet 1, hayır 0 olarak kodlanmış olsun. Ekleştirme fonksiyonu olarak eşik fonksiyonu kullanılmaktadır.

$$y = \begin{cases} 1 & , \sum w_i x_i > \theta \\ 0 & , \text{diğer} \end{cases} \quad (1.1)$$



Şekil 1.1 Kural çıkarma için örnek ağ

Ağın eğitiminin tamamlanmış olduğunu, $w_1 = 5$, $w_2 = 4$, $w_3 = -4$, $w_4 = 5$ ve $\theta = 8$ değerlerinin belirlenmiş olduğunu varsayılmaktadır. Bu eğitilmiş ağdan kural çıkarmak için x_1 , x_2 , x_3 , ve x_4 'ün alabileceği bütün değerlere karşılık gelen y 'leri hesaplarsak, örneğin, $x_1 = 0$, $x_2 = 0$, $x_3 = 0$ ve $x_4 = 0$ olursa, $\sum w_i x_i < \theta$ olacağından $y=0$ olur. Hesaplanan sonuçlar Çizelge 1.1'de görülmektedir.

Çizelge 1.1 Örnek kural çıkarma çizelgesi

x_1	x_2	x_3	x_4	y
0	0	0	0	0
0	0	0	1	0
0	0	1	0	0
0	0	1	1	0
0	1	0	0	0
0	1	0	1	1
0	1	1	0	0
0	1	1	1	0
1	0	0	0	0
1	0	0	1	1
1	0	1	0	0
1	0	1	1	0
1	1	0	0	1
1	1	0	1	1
1	1	1	0	0
1	1	1	1	1

Çizelge 1.1'den görüldüğü üzere ağdan çıkan kurallar aşağıdaki gibidir:

$$y = \overline{x_1} \overline{x_2} \overline{x_3} x_4 + \overline{x_1} \overline{x_2} x_3 \overline{x_4} + \overline{x_1} x_2 \overline{x_3} \overline{x_4} + \overline{x_1} x_2 x_3 \overline{x_4} + x_1 \overline{x_2} \overline{x_3} x_4 \quad (1.2)$$

Burada, $\overline{}$ mantıksal değil işaretidir. Boole cebiri kurallarına dayanarak bu ifade sadeleştirilirse

$$\begin{aligned}
y &= \overline{x_1} \overline{x_2} \overline{x_3} x_4 + x_1 \overline{x_2} \overline{x_3} x_4 + x_1 \overline{x_2} x_3 \overline{x_4} + x_1 x_2 \overline{x_3} \overline{x_4} + x_1 x_2 x_3 \overline{x_4} + \\
&+ x_1 x_2 \overline{x_3} x_4 + x_1 x_2 x_3 x_4 + x_1 \overline{x_2} x_3 \overline{x_4} = \\
&= x_2 \overline{x_3} x_4 (\overline{x_1} + x_1) + x_1 \overline{x_3} x_4 (\overline{x_2} + x_2) + (x_4 + \overline{x_4}) + x_1 x_2 x_4 (\overline{x_3} + x_3) = \\
&= x_1 x_2 \overline{x_3} + x_1 x_2 x_4 + x_1 \overline{x_3} x_4 + x_2 \overline{x_3} x_4
\end{aligned} \tag{1.3}$$

elde edilir. Bu son ifade

$$y = x_1 x_2 (\overline{x_3} + x_4) + \overline{x_3} x_4 (x_1 + x_2) \tag{1.4}$$

veya

$$y = x_1 \overline{x_3} (x_2 + x_4) + x_2 x_4 (x_1 + \overline{x_3}) \tag{1.5}$$

olarak da gösterilebilir.

(1.3), (1.4) ve (1.5) ifadelerinin her biri Şekil 1.1'deki ağdan çıkan kuralları temsil etmektedir.

Kural çıkarma için bir çok yöntem geliştirilmiştir. Bazı araştırmacılar olası bütün kural birleşmelerine dayalı kural çıkarma yöntemi geliştirmişlerdir. Yalnız burada olası kuralların sayısının çokluğu problem teşkil etmektedir. Şöyle ki, n sayıda ikili giriş varsa, her giriş 0, 1 veya tanımsız olduğundan dolayı $s=3^n-1$ adet tekli kural ortaya çıkacaktır. Örnek olarak 3 girişli bir sistemde $s=3^3-1=26$ kural oluşabilmektedir. Oluşabilecek kurallar aşağıda görülmektedir.

1 - x	14 - $\overline{\overline{yz}}$
2 - y	15 - xz
3 - z	16 - $x\overline{z}$
4 - $\overline{x}$	17 - $\overline{xz}$
5 - $\overline{y}$	18 - $\overline{\overline{xz}}$
6 - $\overline{z}$	19 - xyz
7 - xy	20 - $xy\overline{z}$
8 - $x\overline{y}$	21 - $x\overline{y}z$
9 - $\overline{xy}$	22 - $\overline{\overline{xyz}}$
10 - $\overline{\overline{xy}}$	23 - $\overline{xyz}$
11 - yz	24 - $\overline{\overline{xyz}}$
12 - $y\overline{z}$	25 - $\overline{\overline{xyz}}$
13 - $\overline{yz}$	26 - $\overline{\overline{\overline{xyz}}}$

Buna göre örneğin $x=0$, $y=1$, $z=0$ ise giriş bilgisi $\overline{\overline{xyz}}$ olacak ki, bu da 24. kuralın çalıştığı anlamına gelmektedir.

Oluşturulan s adet tekli kurallardan birleşik kurallar üretilirse

$$m = \sum_{k=1}^n \binom{s}{k} * s \quad (1.6)$$

sayıda değişik kurallar kümesi oluşturulabilmektedir. (1.6)'dan görüldüğü gibi n arttıkça m sayısı çok büyük sayılara ulaşmaktadır. Bu sorunu aşmak için bazı

araştırmacılar kural kümesindeki eleman sayısını yani kural birleşimlerini sınırlamak yoluna gitmektedirler. Bazı araştırmacılar ise olası bütün kuralları incelemek yerine kural çıkarmak için farklı modeller geliştirdiler.

Bu kısa analizden görüldüğü gibi çoklu veri içeren veri tabanlarını işlerken bu verilerden belirli desenler elde edebilmek ve onları yorumlamak için verimli bir yöntem geliştirmek gerekmektedir.

1.3. Literatür Araştırması

Sınıflandırma tıp, finans, ekonomi, pazarlama araştırmaları, insan kaynakları yönetimi, üretim sistemleri, örüntü tanıma, çevre, ekoloji ve enerji yönetimi gibi alanlarda çok önemlidir (Arondel ve Girardin, 1998; Berkson, 1944; Brans ve Mareschal, 1994; Dias ve Tsoukias, 2004; Jaszkievicz ve Ferhat, 1999; Keeney ve Raiffa, 1976). Aşağıda bu alanlarda yapılan çalışmaların bazılarına kısaca yer verilmiştir.

Altman (1968) MDA (Multivariate Discriminant Analysis) kullanarak finans durumu tehlikede olan şirketleri tahmin etmiştir.

Aynı amaç için Korobow ve ark. (1976) regresyon analizi, Pantalone ve Platt (1987) ise lojistik regresyon kullanmıştır.

Tam (1991) aynı problem için yapay sinir ağı kullanmış ve elde ettiği sonuçları MDA, lojistik regresyon, k -en yakın komşu ve ID3'le kıyaslamıştır. O, YSA'nın tahmin konusunda en başarılı yöntem olduğunu rapor etmiştir.

Yine, Tam ve Kiang (1992) finans durumu tehlikede olan şirketleri tahmin etmek için istatistiksel yöntemler ve karar ağaçlarını uygulamış ve en başarılı yöntemin YSA olduğunu rapor etmişlerdir.

Jo ve ark. (1997) MDA ve CBFS (Case-Based Forecasting System) ve yapay sinir ağlarını kullanarak Kore firmalarını finans durumuna göre sınıflandırmış ve en başarılı sistemin yapay sinir ağı olduğunu rapor etmişlerdir.

Olmeda ve Fernandez (1997) İspanya bankaları için iflas durumu araştırması yaparken MLFF-BP, lojistik regresyon, MARS (Multivariate Adaptive Splines), C4.5 ve MDA algoritmalarını tek tek ve değişik kombinasyonlu hibritler şeklinde kullanmışlar. Sinir ağının tek kullanıldığı zaman iflas durumundaki bankaları tahmin etmede diğer bütün ağlardan daha başarılı olduğunu ve sinir ağı, lojistik regresyon, C4.5 ve MDA kombinasyonunun aynı problem için diğer bütün kombinasyonlarından daha iyi olduğunu rapor etmişlerdir.

Ahn ve ark. (2000) Kore firmalarının finans durumunun incelenmesi için kaba kümeler ve MLFF-BP'nin hibridinden oluşan bir sistem geliştirmişler. Bu çalışmada hibrit sistemlerin MLFF-BP ve DA'dan daha başarılı olduğu görülmüştür.

Shin ve ark. (2005) şirketlerin iflas durumunu araştırmak için Destek Vektör Makinesi (Support Vector Machines – SVM) kullanmışlar ve şirketlerin mali durumuna göre sınıflandırılmasında SVM'nin MLFF-BP'den daha başarılı olduğunu açıklamışlardır. SVM'nin MLFF-BP'ye göre daha az veriyle eğitilebilmesinin bir avantaj teşkil ettiğini not etmişlerdir.

Sigillito ve ark. (1989) çok katmanlı perseptron kullanarak ionosferden dönen radarları sınıflandırmışlar.

Marzban ve Stumpf (1996) kasırga olup olmayacağını tahmin etmek için yapay sinir ağı kullanmışlar.

Smith ve ark. (1988) sınıflandırma yapmak için ADAP algoritması kullanmışlar ve yöntemi diyabet veri kümesine uygulamışlardır. Bu veri kümesi 768 hasta verisinden oluşmaktadır. Verilerin 576'sı eğitim, 192'si test için kullanılmıştır. Test verisinde %76 oranında sınıflandırma başarısı elde edilmiştir. Bu veri kümesi üzerinde bir çok araştırma yapılmış ve çeşitli sonuçlar elde edilmiştir.

Quinlan (1993) aynı veritabanına C4.5 algoritmasını uygulamıştır. Test verisinde %71.1 başarı elde edilmiştir.

Wahba ve ark. (1992) aynı veritabanına PSA (Penalized log likelihood Smoothing Spline Analysis) ve GLIM (Generalized Linear Models) algoritmalarını uygulamışlar. Glikoz ve BMI'si sıfır olan hastalar elenerek, kalan 752 veriden 500'ü eğitim, 252'si test için kullanılmıştır. Test verisinde PSA %72, GLIM ise %74 sınıflandırma başarısına ulaşılmıştır.

Michie ve ark. (1994) bu veritabanına 22 farklı algoritma ve 12 kez çapraz doğrulama uygulamış ve Çizelge 1.2'de belirtilen sonuçları rapor etmişler. Bu algoritmalarından en başarılısının %77.7 doğru sınıflandırma oranıyla lojik diskriminant, en başarısızının %67.6 doğru sınıflandırma oranıyla k -en yakın komşu algoritması olduğu gözlemlenmiştir.

Oates (1994) yine aynı veri tabanına MSDD (Multi-Stream Dependency Detection) algoritmasını uygulamıştır. Verilerin 2/3'ü eğitim, 1/3'ü test için kullanılmıştır. Test verisinde sınıflandırma başarısı %71.33 olarak rapor edilmiştir.

Bioch ve ark. (1996), Wahba ve ark. (1992) gibi glükoz ve BMI'si sıfır olan hastaları elemişler ve elde edilen verilere Bayes sinir ağını uygulamışlar. Standart sinir ağının sınıflandırma başarısı %75.4 iken, Bayes sinir ağının sınıflandırma başarısı %79.5 olarak rapor edilmiştir.

Carpenter ve Markuzon (1998) Smith'le aynı eğitim ve test verisi kullanmış ve ARTMAP-IC, ARTMAP, lojistik regresyon ve k -en yakın komşu algoritmalarını uygulamışlar. Bu çalışmada ARTMAP-IC'nin başarısı %81, ARTMAP'in başarısı %66, lojistik regresyon ve KNN'nin başarısı %77 olarak rapor edilmiştir.

Eklund ve Hoang (1998) bu veri tabanına 5 farklı algoritma uygulamışlardır. Verilerin %80'i eğitim, %20'si test için kullanılmıştır. Algoritmaların başarısı aşağıdaki gibi rapor edilmiştir: C4.5 algoritması %71.02, C4.5 kural %71.55, ITI %73.16, LMDT %73.51 ve CN2'nin başarısı %72.19 olarak rapor edilmiştir.

Çizelge 1.2 Michie ve ark. (1994) rapor edilen sınıflandırma sonuçları.

Yöntem	Başarı %
Discrim	77.5
Quaddisc	73.8
Logdisc	77.7
SMART	76.8
ALLOC80	69.9
k-NN	67.6
CASTLE	74.2
CART	74.5
IndCART	72.9
NewID	71.1
AC ²	72.4
Baytree	72.9
NaiveBay	73.8
CN2	71.1
C4.5	73
Itrule	75.5
Cal5	75
Kohonen	72.2
DIPOL92	77.6
Backprop	75.2
RBF	75.7
LVQ	72.8

King ve ark. (1998) bu veri tabanında 14 algoritma denemişler. İnsulini sıfır olan verileri eleyerek 532 veri kullanmışlardır. Çizelge 1.3’de görülen sonuçları rapor etmişlerdir.

Liu (1998) sınıflandırma ve birliktelik kuralları madenciliğini CAR (Class Association Rules) algoritmasında birleştirmiştir. CAR modeli %73.1, C4.5 kurallar algoritması %75.5 başarı elde etmiştir.

Loo (2005) Fuzzy ARTMAP (SFAM) algoritmasını önermiş ve bu yöntemi 5 tıbbi veri tabanına uygulamıştır. Dermatoloji veri tabanında doğru teşhis oranı %93.14, hepatit veritabanında %75.16, Wiskonsin Göğüs Hastalıkları veritabanında %93.14, Cleveland Kalp Hastalıkları veritabanında %75.16 ve Kalaazar hastalıklarında %89.21 olarak elde edilmiştir.

Çizelge 1.3 King ve ark. (1998) rapor edilen sınıflandırma sonuçları

Yöntem	Başarı %
CART	76
Scenario	30
See5	73
S-Plus	79
WizWhy	74
DataMind	69
DMSK	67
NeuroShell2--Neural	77
PcOLPARS	81
PRW	80
MQ Expert	77
NeuroShell2—PolyNet	78
Gnosis	81
KnowledgeMiner	78

Tang ve ark. (2004) GSVM (Granular Support Vector Machines) algoritmasını önermiş ve bu algoritmayı Wisconsin Göğüs Kanseri, Cleveland Kalp Hastalıkları, BUPA Karaciğer Hastalıkları veritabanlarında denemişlerdir. Göğüs Kanseri veritabanında hastalık teşhisi için GSVM %97.72, SVM %96.4, Cleveland Veri Tabanında GSVM %84.04, SVM %83.84, BUPA veritabanında GSVM %49.66, SVM %48.97 ile başarılı olmuştur.

Adam ve ark. (2002) karar ağacı algoritmasını prostat kanseri veri kümesine uygulamış ve %96 başarı elde etmişlerdir.

Ball ve ark. (2002) astroglial tümörün tespiti için üç katmanlı perseptron kullanmış ve bu ağı geri yayılım algoritması ile eğitmişlerdir. Bu veri kümesinde sadece 12 veri bulunmaktadır. Hastalık teşhisi için elde edilen başarı %83 olmuştur.

Quinlan (1996) C4.5 algoritmasını Göğüs Kanseri veri tabanına uygulamış ve %94.74 teşhis başarıları elde etmiştir.

Hamilton ve ark. (1996) aynı veritabanına RIAC algoritması uygulamış ve %96 teşhis başarıları elde etmişlerdir.

Ster ve Dobnikar (1996) aynı veritabanına Lineer Diskriminant Analizi uygulamış ve %96.8 teşhis başarıları elde etmişlerdir.

Bennet ve Blue (1997) Göğüs Kanseri veritabanına SVM uygulamış ve %97.2 teşhis başarıları elde etmişler.

Nauck ve Kruse (1999) sinirsel bulanık yöntemlerle aynı veritabanında sınıflandırma yapmış ve %95.06 teşhis başarıları elde etmişlerdir.

Pena-Reyes ve Siper (1999) bulanık-GA kullanarak sınıflandırma yapmış ve %97.51 teşhis başarıları elde etmişlerdir.

Cheung (2001) Karaciğer Hastalıkları veri tabanında sınıflandırma yapmak için 4 algoritma kullanmıştır. Çalışmada C4.5 algoritması kullanılarak %65.5, Naive Bayes sınıflandırması kullanılarak %63.39, BNND (Bayesian Network with Dependence) kullanılarak %61.83 ve BNNF (Bayesian Network with Naive Dependence and Feature Selection) kullanılarak %61.42 sınıflandırma başarıları elde edilmiştir.

Van Gestel ve ark. (2002) SVM kullanarak aynı veritabanında %69.2 sınıflandırma başarısı elde etmişlerdir.

Lee ve Mangasarian (2001a) aynı veritabanına SSVM (Smooth Support Vector Machine) algoritması uygulamış ve %70.33 sınıflandırma başarısı elde etmişlerdir.

Lee ve Mangasarian (2001b) aynı veritabanına RSVM (Reduced Support Vector Machine) algoritması uygulamış ve %74.86 sınıflandırma başarısı elde etmişlerdir.

Pham ve ark. (2000) aynı veritabanına RULES-4 algoritmasını uygulamış ve %55.90 sınıflandırma başarısı elde etmişlerdir.

Bu analizden de görüldüğü gibi sinir ağları genelleştirme becerilerinden dolayı çok cazip yöntemler olmaktadır. Ancak YSA'lar çözdükleri problemle ilgili “bilgileri” ağırlıklar ve nöronlar arası bağlantılara bağlı tuttukları için bu bilgilerin anlamı kullanıcılar tarafından bilinmemektedir. Bazı uygulama alanlarında (örneğin, tıp problemlerinde) sinir ağının bulduğu çözümün açıklanması gerekmektedir. Bu sebeple sinir ağından kural çıkarmaya gerek duyulmuş ve bu konuda bir çok çalışma yapılmıştır.

İlk kural çıkarma algoritmalarından biri Saito ve Nakano tarafından geliştirilmiştir (1988). İkili verilere sahip problemlerde Önce Enine arama (Breadth-first - BFS) algoritması kullanarak bileşik kurallar çıkarmışlardır. Oluşabilecek kural kümelerinin sayısını azaltmak için iki kısıtlama kullanılmıştır. İlk kısıtlama olarak derinlik adı verdikleri bir $t < n$ sayısı belirlemiş ve kural kümelerinin eleman sayısını en fazla t ile sınırlamışlar. İkinci kısıtlama olarak ise verilerden yola çıkarak bazı kuralları elemişler. Örneğin, eğer veri kümesinde $x_1=doğru$, $x_2=doğru$ şeklinde bir veri yoksa, $y=x_1x_2$ şeklinde bir kural hiçbir zaman doğru olmayacağına göre, bu kural baştan elenmiştir. Çalışmada kuralların ağı ifade ettiğini test etmek için aşağıdaki yöntem kullanılmıştır: Önce pozitif girişlere 1, diğer bütün girişlere 0 atanmış ve ağın çıkışı hesaplanmıştır. Sonra değilli girişlere 1 atanmış, diğerleri aynı kalmış ve ağın çıkışı hesaplanmıştır. Eğer ilk denemede sınıflandırma işlemi doğru, ikincide yanlış yapılmışsa, bu kural doğru olarak kabul edilmiştir.

Gallant (1993), Saito ve Nakano'nun geliştirdiği yönteme benzer bir algoritma geliştirmiştir. Gallant'ın çalışmasındaki fark, kuralların hangisinin ağı ifade ettiğini test etme yöntemidir. Bu yöntemde ağı girişine sadece kuralda belirtilen girişlerin değerleri atanmış ve ağı çıkışı sadece bu girişlere bağlı olarak hesaplanmıştır. Örneğin, üç girişli bir ağda $\overline{x_1 x_3}$ kuralı denenecekse, ağı birinci girişine 1, üçüncü girişine 0 atanmış, ikinci girişine ise veri atanmamıştır. Gallant bu yöntemin sadece geçerli kuralları bulduğunu iddia etmiştir.

Thrun (1995) Gallant'ın yönteminin genelleştirilmiş ve daha güçlü modeli olan VIA yöntemini sunmuştur. İki yöntem arasındaki temel fark ağı girişlerini tespit etmek için doğrusal programlama kullanmasıdır. Bu da aktivasyon aralığının geriye yayılarak girişlerin hesaplanmasını ve giriş için daha dar aralıkların bulunmasını sağlamaktadır. Bu yöntemde ilk aşamada Gallant gibi ağa sınırlı veriler girilmiş ve çıkış hesaplanmıştır. Sonra çıkışa göre girişleri hesaplamıştır. Bu yöntemle Thrun, Gallant'ın tespit edemediği kuralları bulmuştur.

Tchoumatchenko ve Ganascia (1994) sinir ağından çoğunluk-oyu (majority vote) kuralı çıkarmak için yeni bir yöntem önerdi. Çoğunluk oyu kuralı bir sınıfa ait verileri doğrulayan veya doğrulamayan değerler listesidir. Çoğunluk oyu kuralındaki değerlerin çoğu örnekle aynıysa, örnek kuralda belirtilen sınıfa ait kabul edilir. Tchoumatchenko ve Ganascia'nın bu çalışmasında özel bir aktivasyon fonksiyonu kullanarak sinir ağının ağırlıklarının $\{-1,0,1\}$ 'e çok yakın değerlere ulaşması sağlanmıştır. Daha sonra algoritma her giriş değerinin belli bir sınıfa ait olup olmadığına bakarak kural için değerler oluşturur. Girilen değer bir sınıfa ait olup olmadığına ağdaki ağırlıkların işaretlerine bakarak karar verilir. Bu yöntemle her sınıf için bir çoğunluk oyu kuralı oluşturulmuştur. Bu kaba bir kural çıkartma algoritması olup, başarı oranı düşüktür.

Towell ve Shavlik (1993) SUBSET ve MofN adlı iki algoritma geliştirdiler. SUBSET algoritması belirli nöronları aktive eden ağırlıkları incelemektedir. MofN algoritması SUBSET'e göre daha net ve anlaşılır kurallar çıkarmaktadır (Hruschkaa ve Ebecken, 2006).

Alexander ve Mozer (1995) aktivasyon fonksiyonlarının Boolean davranışına yakın davranışlar gösterdiğini varsayan ağırlıklara dayalı bir kural çıkarım metodu geliştirmişlerdir.

Narazaki ve ark. (1996) YSA'ya dağıtılmış bilginin tekrar organize edilmesi ve bulanık sınıflandırma kuralları çıkarmak için yöntem önermişlerdir. Bu yöntem YSA'nın öğrendiği fonksiyonun analizine dayanmaktadır.

Sethi ve Yoo (1996) ağırlıklara dayalı kural çıkarma yöntemi geliştirmiştir.

Craven ve Shavlik (1996) TREPAN algoritmasını önerdiler. Bu algoritma YSA için belirli bir eğitim algoritması veya belirli bir ağ yapısına gerek duymadan, sınıflandırma ağaçları kullanarak kural çıkarmaktadır.

Lu ve ark. (1996) gizli katmandaki aktivasyon değerlerini kümeleyerek kural çıkarmak için bir yöntem önermişlerdir.

Weijters ve ark. (1997) BP-SOM adlı YSA'yı eğiten ve sınıflandırma kuralı çıkaran algoritma önermişlerdir. BP-SOM Kohonen ağını kullanarak kümeleme yapmaktadır.

Das ve Mozer (1998) ikili kodlanmış verilerle eğitilmiş yinelenen (recurrent) sinir ağından kural çıkarmak için bir yöntem önermişlerdir. Yazarlar bu yöntemin diğer sinir ağı algoritmaları için de geçerli olduğunu belirtmişlerdir.

Duch ve ark. (1998) ağırlıkları $\{-1,0,1\}$ kümesine ait olan bulanık sinir ağından kural çıkarmak için bir yöntem geliştirdiler. Bu çalışmada en az sayıda kural elde etmek için ağırlıkların çoğunun sıfır olmasını sağlayan bir yöntem önerdiler.

Ludermir (1998) Boole ağları için kural çıkarma yöntemi önermiştir.

Duch ve ark. (1999) ÇKP'ye gizli nöronlar ekleyerek yeni mantıksal kurallar çıkarma yöntemi önermişlerdir.

Keedwell ve ark. (2000) sinir ağının giriş değerlerinden kural çıkarmak için genetik algoritma kullanmışlardır.

Setiono ve Leow (2000) FERNN adlı sinir ağından kural çıkarmak için hızlı yöntem geliştirmişlerdir. Önerilen yöntem gizli katman nöronlarının bilgi üzerine etkisinin incelenmesine dayanmaktadır.

Palade ve ark. (2000) sinir ağından kural çıkarmak için aralık yayılmasına dayalı bir yöntem geliştirmişlerdir.

Garcez ve ark. (2000) ayırık girişli sinir ağından monoton olmayan kurallar çıkarmak için yöntem geliştirmişlerdir.

Snyders ve Omlin (2001) adaptif ve sabit biaslı sinir ağından kural çıkarmış ve sonuçları karşılaştırmışlar. Test için moleküler biyoloji verileri kullanılmıştır.

Görüldüğü üzere sınıflandırma ve kural çıkarma konusunda bir çok çalışma yapılmıştır. Bu çalışmalar tahmin konusunda yer yer başarılı olmalarına rağmen özellikle tıp gibi gerçek dünya problemlerinde arzu edilen teşhis başarısına ulaşamamıştır. Bu çalışmada bu amaçla iki yöntem önerilmiş ve teşhis başarısının yükseldiği gözlemlenmiştir.

1.4. Tezin Organizasyonu

Bu tez çalışmasının ana hatları aşağıdaki gibidir:

Birinci bölümde, tez çalışması hakkında genel bir bakış açısı verilmeye çalışılmıştır. Çalışmanın amacı ve çerçevesi ele alınmış, mevcut çalışmalara göre değerlendirilmiştir.

İkinci bölümde, önerilen hibrit bulanık sinir ağının altyapısını teşkil eden bulanık mantık, YSA ve BSA hakkında kısaca bilgi verilmiş, hibrit bulanık sinir ağı açıklanmış ve onun eğitim algoritması verilmiştir.

Üçüncü bölümde önerilen hibrit bulanık sinir ağıyla ilgili yapılan uygulamalar anlatılmış ve sonuçlar açıklanmıştır.

Dördüncü bölümde, optimizasyon teorisinin temelleri ve yapay bağışıklık sistemleri hakkında kısaca bilgi verilmiş, önerilen kural çıkartma algoritması açıklanmıştır.

Beşinci bölümde önerilen kural çıkarma algoritması ile ilgili uygulamalar anlatılmış ve sonuçlar açıklanmıştır.

Altıncı bölümde, çalışmanın sonuçları üzerine genel bir değerlendirme yapılmış ve çalışma ile ilgili öneriler verilmiştir.

2. HİBRİT SİNİR AĞI KULLANARAK SINIFLANDIRMA YAPILMASI

Kaynak araştırmasından da görüldüğü gibi büyük veri tabanları üzerinde sınıflandırma yapmak için bir çok yöntem önerilmiş ve değişik alanlarda uygulamalar yapılmıştır. Bazı yöntemler belirli alanlarda başarılı olsa da her alanda başarılı olan bir yöntem henüz bulunamamıştır. Bu çalışmada özellikle tıp alanında sınıflandırma başarısını yükselten bir sistem geliştirmek amaçlanmıştır. Bunun için tıp verileri incelenmiş ve veri tiplerinden yola çıkarak sınıflandırma yapmak için yeni bir sinir ağı türü önerilmiş ve onun eğitim algoritması oluşturulmuştur. Daha sonra kurallar tabanı oluşturulması için bu sinir ağının ürettiği fonksiyonu optimize eden yeni bir algoritma geliştirilmiştir. Sonuç olarak bu iki işlem herhangi bir hastalığı teşhis etmek için yeni bir model oluşturmuştur. Bu bölümde modelleme, hibrit bulanık sinir ağının altyapısı olan yapay sinir ağları, bulanık mantık, bulanık sinir ağları ve sistemlerin başarısını ölçmek için kullanılan k -kat çapraz doğrulama hakkında kısaca bilgi verilmiştir. Bu konularla ilgili detaylı bilgi almak için Baykal ve Beyan, 2004a, Baykal ve Beyan, 2004b, Öztemel 2003, Elmas, 2003a, Elmas, 2003b, Sağiroğlu ve ark., 2003, Ishibuchi, 1994 incelenebilir.

2.1. Matematiksel Modelleme

Genel anlamda matematiksel modelleme, fiziksel bir sistemin temelinde bulunan girdi-çıkı davranışını karakterize eden parametrelerin matematiksel terimlerle tanımlanmasıdır. Bir devre veya mikroişlemci gibi fiziksel bir sistemi açıklamak için, sistemi nicel veya nitel olarak temsil edebilen bir matematiksel formül kullanılmalıdır. İlgilenilen fiziksel sistemin, matematiksel formülle tanımlanmış haline de matematiksel model denir.

Bazen incelenecek olan sistemin matematiksel modeli olmamaktadır. Böyle durumlarda modelleme için diğer yaklaşımlar kullanılır.

İncelenen sistemin tüm özelliklerini gösteren verilerin analizine dayanan modelleme yaklaşımı veriden hareketli yaklaşımdır. Burada sistemin fiziksel davranışından elde edilen sınırlı bilgi ile sistemin parametreleri ve değişkenleri hakkında bilgi edinilerek model geliştirilmeye çalışılmaktadır. Son yıllarda bu tip modelleme için bir çok teknik geliştirilmiştir. Bu konuda en çok kullanılan teknik YSA olmakla beraber sıklıkla istatistiksel yöntemler de kullanılmaktadır. Veriden hareketli yaklaşımlar çeşitli disiplinler arası alanların da konusudur. Yöntemler temelde istatistik ve makine öğrenmesine dayalıdır.

Makine öğrenmesi yöntemleri, eldeki verilerle sistemin girdi ve çıktıları arasındaki bağıntıyı tahmin etmeye yönelik algoritmalarlardır. Makine öğrenmesi, bir bilgisayar bilimi olup, teorik temellere yönelen bir yapay zeka alt alanıdır (Baykal ve Beyan, 2004a).

Genel olarak veri terimi, işlenmemiş ham bir olgu anlamına gelmektedir. Veri herhangi bir anlam ve doğruluk değeri olmayan bilgi taşıyıcısı, bilginin temel parçası olarak kabul edilir. Veri, inceleme için toplanan malzeme anlamına da gelmektedir. Veriler soyut ve somut olmak üzere iki gruba ayrılır. Soyut veri, metinler, resimler, filmler, müzikler vs.'dir. Somut veri ise genellikle sayısal yapıdadır (Baykal ve Beyan, 2004a).

Dört tip veri analizi yöntemi vardır. Bunlar sınıflandırma, ilişkilendirme, kümeleme veya gruplama ve sayısal kestirimdir. Sınıflandırma, sınıfı belli olan örneklerle dayanarak görülmemiş örneklerin ait olduğu sınıfı bulmaktır. Örneğin ait olduğu sınıf önceden belli ise bu tip öğrenme yöntemlerine danışmanlı öğrenme denir. İlişkilendirme, özellikler arasındaki ilişkileri tanımlamaktır. Gruplama, birbirine yakın olan nesneleri yada örnekleri kümelemektir. Bu yöntemde örneğin ait olduğu sınıf önceden belli olmadığına göre bu tip öğrenme yöntemlerine danışmansız öğrenme denir. Sayısal kestirimde çıktı bir sınıf değil, gerçel bir sayısal değerdir.

Veriler arasındaki ilişkiyi, geliştirdiği çok değişkenli regresyon ve sınıflandırma yöntemleri ile ilk ortaya koyan istatistiktir. 1960-1970'lerde yeni teknikler ortaya çıkmaya başlamıştır. Bunlar arasında örüntü tanıma, sınıflandırma

analizi, insan beyni ve algılamasını taklit etmeye yönelik yapay sinir ağları ve bulanık mantık gibi teknikler, genetik algoritmalar, karar ağaçları ve destekleyici algoritma sayılabilir.

İstatistikte dört tip veri söz konusudur. Bunlar nominal, ordinal, aralık ve oran (gerçek değerli) verileridir. Makine öğrenmede ise genel olarak iki veri tipi: Nominal (sınıflar) ve gerçek değerli veriler hakkında değerlendirme yapılır.

Nominal veriler kullanılarak oluşturulan modeller sınıflar ve gruplardır. Sınıflandırma veri noktalarının sınıflarını bulmak olarak ele alınabilir. Sınıflandırma işleminde bir sınıf içindeki noktaların birbirlerine olabildiğince yakın ve sınıfların birbirinden uzak olması istenir. Gruplama, verileri önceden belirlenmiş bir sınıfa atamadan, veri grupları yada alt kümelerine ayırma işlemidir.

Veriden hareketli yaklaşımlar finans, müşteri kaynakları yönetimi, tıp, mühendislik gibi pek çok alanda uygulama imkanı bulmuşlardır. Günümüzde en sık kullanılan yöntemler, K -ortalamalar, bulanık C -ortalamalar, ÇKP, LVQ, Bayes sınıflandırma, karar ağaçları, destek vektör makinalarıdır. Yalnız bu yöntemler ayrı ayrı arzu edilen başarıya ulaşamamaktadır. Bu nedenle günümüzde birden fazla paradigmanın birleştirilmesi ile oluşturulan hibrid yaklaşımlarla daha etkin modelleme işlemleri yapılmaya çalışılmaktadır.

Bulanık kümeler yada bulanık mantığı ve buna karşılık gelen matematiksel çatıyı kullanan statik yada dinamik sistemler bulanık sistemler olarak tanımlanır. Bazı sistemler basit ve kesin matematiksel formül ve eşitliklerle açıklanamayacak kadar belirsizlik ve bulanıklık içerirler. Klasik matematik ve bulanık mantık beraber kullanıldığında, bu tip sistemler için alternatif bir matematiksel modelleme imkanı sağlayabilmektedir. Böyle durumlarda, güven aralığı ve bulanık üyelik fonksiyonları yaklaşık değer ölçümü için kullanılabilir ve bu şekilde bulanık sistem modelleme kavramı ortaya çıkmış olur.

Genel olarak bulanık matematiği bir şekilde kullanan her sistem bulanık sistem olarak kabul edilebilir. Bulanık sistemler tam bulanık sistemler ve hibrid bulanık sistemler olarak iki gruba bölünebilir. Tam bulanık sistemler bütünüyle bulanık matematik zemininde üretilmiş sistemlerdir. Hibrid sistemler bulanık matematiğin bulanık olmayan diğer tekniklerle karıştırılmış şeklini kullanır.

Bulanık model kurmak için genel bilgi kaynağı öncül bilgi ve veridir. Bulanık modellemede de bilgiyi kullanan doğrudan yaklaşım ve veriden hareketli yaklaşım olmak üzere iki yaklaşımdan söz edilir. Doğrudan yaklaşıma bilgi mühendisliği de denmektedir. Süreç tasarımcıları, alanının uzmanlarından elde edilen öncül bilgiyi kullanarak bulanık uzman sistemler oluşturabilir. Veriden hareketli yaklaşım bilgiyi bulma yaklaşımı olarak da tanınmaktadır. Verilerden bulanık model kurmaya dayanan yaklaşım, bulanık mantık ve yaklaşık akıl yürütmeyi temel almakla beraber, aslında sinir ağları, veri analizi ve klasik sistem tanımlamalarından esinlenen fikirlere dayanmaktadır.

Tıbbi tanıdaki karmaşıklık ve belirsizlik, insan organizmasının müstesnalığı tanısal sürecin öğrenimi, öğretimi ve uygulanmasını zorlaştırmaktadır. Bulanık mantık yöntemleri belirsizliğin belli tiplerini modellemedeki başarısından dolayı yaygın bir şekilde çeşitli tıbbi alanlarda da uygulama imkanı kazanmıştır. Karmaşık, doğrusal olmayan, bulanık ve hatta çatışan ilişkiselliklerin bulunduğu durumlardaki doğruya en yakın sonucu bulma yeteneği bulanık mantığa, diğer kurala dayalı sistemlere göre avantaj kazandırmaktadır.

Genel olarak ayırmak gerekirse tıpta kullanılan sistemler dört ana sınıfta toplanabilir. Bunlar tanı amaçlı, öngörü amaçlı, denetim amaçlı ve karar destek sistemleridir. Karar destek sistemleri herhangi bir problem karşısında karar verirken kullanıcıya yön gösterecek şekilde bilgiler üreten sistemlerdir. Denetleyici sistemlerin çeşitli tipleri bulunmaktadır. Bunlar temel denetleyici sistemler, kurala dayalı açık ve kapalı döngü sistemleri, kendi kendine öğrenen sistemler, modele dayalı ve uyum sağlayan sistemler, hibrid sistemler ve hiyerarşik ve gözetimli sistemler olarak sıralanabilir (Baykal ve Beyan, 2004a).

2.2. Bulanık Mantık ve Yapay Sinir Ağı

Yapay sinir ağları ve bulanık teknolojiler birbirlerini tamamlayan iki teknolojidir. Sinir ağları verilerden yola çıkarak öğrenebilme özelliğine sahiptir. Fakat sinir ağlarıyla sunulan bilgiyi anlamak ve analiz etmek zordur. Tersine, bulanık sistemler sözel terimler ve “Eğer - ise” kuralları kullandıkları için kolayca anlaşılabilir ama, öğrenme algoritmaları yoktur (Baykal ve Beyan, 2004a).

Bulanık mantık ve yapay sinir ağlarının her birinin kendisine özgü yetenekleri bulunmaktadır. Örneğin yapay sinir ağları öğrenme, örnekleri tanımlamada başarılı iken, karar alma konusunda başarılı değildir. Bulanık mantık ise karar almada çok başarı sonuçlar üretirken, bu süreçteki kural oluşturmaya kendiliğinden yapamaz (Elmas, 2003a).


2.2.1. Yapay sinir ağları

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece, günümüz bilgisayarlarının algoritmik hesaplama yöntemlerinden farklı bir bilim dalı olarak “yapay sinir ağları” ortaya çıkmıştır (Karlık, 1994).

İnsan sinir sistemi, içerden veya dışardan algıladıkları uyarıları elektriksel sinyallere dönüştüren ve beyne bilgi ileten alıcı sinirler, iletilen elektriksel sinyalleri yorumlayan ve uygun bir karar üreten beynin merkezi ve üretilen bu elektriksel

darbeleri uygun tepkilere dönüştüren tepki sinirlerinden oluşur. Merkezi sinir ağının temel işlem elemanı, sinir hücresidir. Şekil 2.1’de bir nöronun yapısı verilmiştir.

Sinir hücresi, hücre çekirdeğini saran bir hücre gövdesinden oluşur. Hücre gövdesinden çıkan ve akson olarak adlandırılan uzantılar, diğer hücelere bağlanan çok sayıda dallara ayrılır. Aksonlar, hücre gövdesinden dışarı diğer nöronlara sinyalleri taşıyan uzantılardır. Bu uzantılar dallar üzerinden diğer hücelere bağlanarak (eşleşerek) bir hücreden diğerine bilgi aktarır. Eşleşen bağ, diğer hücrenin bilgi alıcı uzantısı olan dendrit ile sonlanır. Dendritler, diğer hücelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Aksonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücelere için dendritleri oluşturan yollardır. Akson-dendrit bağlantı elemanı sinaps olarak isimlendirilir. Sinaps’a gelen ve dendritler tarafından alınan bilgiler genellikle elektriksel darbelerdir. Belirli bir sürede bir hücreye gelen girişlerin değerleri toplamı, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak isimlendirilir ve bu etkiyi sinaps belirler (Gültekin, 2002).



Şekil 2.1 Biyolojik Sinir Hücresi

İnsan beyninin yaklaşık 10^{11} sinir hücresinden ve $6 \cdot 10^{13}$ sinaps bağlantısından oluştuğu düşünülürse, son derece karmaşık ve etkin bir yapıya sahip olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşal bilgileri son derecede hızlı değerlendirilebilmektedir (Haykin 1994, Zurada 1992). Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneđi nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağıtılmış bir bilgi işleme sistemi olarak tanımlanabilir (Karna ve Bren, 1989).

Yapay Sinir Ağları (YSA), beyindeki sinirlerin çalışmasını taklit ederek sistemlere öğrenme, genelleme yapma, hatırlama, gibi yetenekleri kazandırmayı amaçlayan bilgi işleme metodudur (Öztemel, 2003). Bir YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur. YSA'nın en önemli özelliklerinden birisi de onun öğrenme becerisinin olmasıdır. YSA'lar öğrenme algoritmaları ile öğrenme sürecinden geçtikten sonra, bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneđine sahip olurlar (Altun, 2007).

Beynin fizyolojisi göz önüne alınarak bir bilgi işleme modeli olarak karşımıza çıkan YSA'nın literatürde 100'den fazla modeli mevcuttur (Simpson, 1990). Bu modelleri geliştiren bilim adamları beyin düşünme, hatırlama ve problem çözme gibi özelliklerini bilgisayara aktarmaya çalışmışlardır.

YSA mühendislik alanında (imalat sanayii, askeri proje uygulamaları, endüstriyel ürün tasarımı, bilgi yönetimi), tıp alanında (tıbbi görüntü işleme, tanı koyma, organ morfasyonlarının belirlenmesi, protez tasarımı), tarımsal alanda, hayvancılıkta, askeri alanda, uzay ve havacılık sanayinde, yüzey modellemede kullanılmıştır (Sağırođlu ve ark, 2003).

YSA'nın çok farklı problemlerin çözümlenmesinde kolaylıkla kullanılabileceđinin anlaşılmasıyla konuya ilgi artmış ve çok farklı alanlarda çalışmalar yapılmıştır. Kısaca, YSA'lar "veri işlemede yeni yaklaşımlar" sunmuşlardır. YSA, "yerel bir hafıza yapısı tanımlayan ve birbirleri ile çeşitli şekillerde bağlantılı olan veri işleme elemanlarının dağıtılmış veriyi geliştirebildikleri paralel bir yapıdır". Genel olarak matematiksel modelleri

oluşturulamayan veya matematiksel modelleri çok zor tanımlanabilen problemlerin çözümü için kullanılır (Sağıroğlu ve ark, 2003).

YSA insan beyninin bazı organizasyon ilkelerine benzeyen özellikleri kullanmaktadırlar. Genel olarak YSA model seçimi ve sınıflandırılması, işlev tahmini, en uygun değeri bulma ve veri sınıflandırılması gibi işlerde başarılıdır.


Bir çok YSA tipi bulunmakla birlikte bazılarının kullanımı diğerlerinden daha yaygındır. En çok kullanılan YSA, Geri Yayılımlı YSA' dır. Bu tip yapay sinir ağı tahmin ve sınıflandırma işlemlerinde çok iyi sonuçlar vermektedir.

2.2.1.1. Yapay sinir ağının öğeleri

YSA'nın temel birimi nöron ya da düğüm olarak adlandırılan yapay bir sinirdir. Bir yapay sinir, biyolojik sinirlere göre daha basit olmasına karşın, biyolojik sinirlerin 4 temel işlevini taklit eder. Şekil 2.2'de yapay bir sinir (düğüm) hücresinin modeli gösterilmiştir.

Girişler x_i sembolüyle gösterilmiştir. Bu girişlerin her biri uygun ağırlık w_{ij} ile çarpılır ve sonuçlar toplanır. Bulunan toplam eşik değeri θ_j ile toplanır ve sonucu oluşturmak için aktivasyon fonksiyonu ile işlem yapılır ve y_j çıkışı alınır.

Tüm yapay sinir ağları bu temel yapıdan türetilmiştir. Bu yapıdaki farklılıklar yapay sinir ağlarının farklı sınıflandırılmalarını sağlar. Bir yapay sinirin öğrenme yeteneği, seçilen öğrenme algoritması içinde ağırlıkların uygun bir şekilde ayarlanmasına bağlıdır (Elmas, 2003a).



Şekil 2.2 Yapay bir sinir hücresi modeli (Elmas, 2003a).

Bir YSA aşağıdaki öğelerden oluşmaktadır:

1. **Girişler:** Girişler $(x_1, x_2, \dots, x_n)$ çevreden aldığı bilgiyi sinire getirir. Girişler, kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir.
2. **Ağırlıklar:** Ağırlıklar $(w_1, w_2, \dots, w_i)$, yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılardır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bu ağırlığın değerinin büyük olması o girişin yapay sinire güçlü bağlanması yada önemli olması, küçük olması zayıf bağlanması yada önemli olmaması anlamına gelmektedir.
3. **Toplama İşlemi:** Birleştirme işlemi olarak da adlandırılan toplama işlemi, sinirde her bir ağırlığın ait olduğu girişle çarpımının toplamalarını nöronun

θ_j eşik değeri ile toplayarak elde ettiği v_i değerini aktivasyon işlemine gönderir.

4. Etkinleştirme fonksiyonu: Transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonu toplama işleminin sonucunu, işleminden geçirip çıkışa iletir. Etkinleştirme fonksiyonu genellikle doğrusal olmayan bir f işlemidir.
5. Çıkış işlemi: Çıkış $y_i = f(v_i)$ aktivasyon fonksiyonu sonucunun dış dünyaya veya diğer sinirlere gönderildiği yerdir. Bir sınırın bir tek çıkışı vardır. Sinirin çıkışı kendinden sonra gelen herhangi bir sayıdaki diğer sinirlere giriş olabilir.

Nöron davranışını belirleyen önemli etmenlerden biri nöronun aktivasyon fonksiyonudur. Biyolojik nöronlarda, toplam belli bir değeri aştığında nöronun kısa süreli bir darbe gönderdiği bilinmektedir. Bu davranışa benzer bir davranış yapay nöronlarla da elde etmek için aktivasyon fonksiyonları kullanılır. Eğer uygulanan aktivasyon fonksiyonu lineer olursa, ağırlık işlemsel yapısı da lineer özellik gösterir. Sigmoid fonksiyonu sadece pozitif çıkış değerleri üretir. Hiperbolik tanjant fonksiyonu hem pozitif hem de negatif çıkış değerleri üretir. Hangi fonksiyonun kullanılacağı probleme bağlıdır ve deneme yanılma yoluyla tespit edilebilir. YSA’larda en çok kullanılan aktivasyon fonksiyonları Çizelge 2.1’de verilmiştir.

Ara (gizli) katmanları olmayan, sadece giriş ve çıkış katmanı olan ağlar, karmaşık işlevleri hesaplama yeteneğinden yoksundur. Bu nedenle karmaşık hesaplamalar için oluşturulan ağlarda en az bir ara katman olmalıdır.

Gizli nöronların (düğümlerin) sayısı ağırlık en iyi çalışabileceği bir sayıda seçilmelidir. Eğer gizli nöron sayısı çok artırılırsa, istenen sonuç değerinin üzerine çıkmış olur. Bu durumda ağda genelleşme sorunu ortaya çıkacaktır. Bir nöronun çıkışı diğer bir nörona giriş olarak bağlanır. Nöron, bir çok nörondan giriş alır fakat diğer nöronlara aktarılan tek çıkış üretir (Elmas, 2003a), ama sonradan bu çıkış çoğaltılarak bir çok nörona giriş olarak verilebilir.

Çizelge 2.1 Yaygın kullanılan etkinleştirme fonksiyonları (Öztemel, 2003, Çetin, 2003a)

Doğrusal Fonksiyon	$f(x) = x$
Basamak Fonksiyonu	$f(x) = \begin{cases} 1 & , \quad v \geq \theta \\ 0 & , \quad v < \theta \end{cases}$
Parçalı Doğrusal Fonksiyon	$f(x) = \begin{cases} 0 & , \quad x \leq -1/2\alpha \\ \alpha x + 1/2 & , \quad x < 1/2 \\ 1 & , \quad x \geq 1/2\alpha \end{cases}$
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
Hiperbolik Tanjant	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$
Çoklu-kuadratik	$f(x) = \frac{\sqrt{r^2 + (x - c)^2}}{r}$
Gauss	$f(x) = e^{-\frac{(x-c)^2}{r^2}}$

2.2.1.2. Yapay sinir ağlarında öğrenme

Yapay sinir ağ mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Yapay sinir ağlarının ileri beslemeli ve geri beslemeli olmak üzere iki temel mimarisi vardır.


İleri beslemeli bir ağda düğümler katmanlar üzerinde bulunur. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan ara katmandaki nöronlara iletir. Bilgi, ara ve çıkış katmanında işlenerek ağ çıkışına

iletilir. Girişler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilirken bir katmandaki çıkışlar bir sonraki katmana giriş olarak verilir (Rumelhart ve McClelland, 1986). Bir düğüm genellikle kendinden sonraki herhangi bir düğüme bağlanabilirken bazen kendisine de bağlanmaktadır. Son katmanda üretilen değerler ağın çıkışıdır. Herhangi bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur. Ağ statik yapıları bir fonksiyondur.

Geri beslemeli bir sinir ağı, en az bir nöron çıkışının kendisine veya diğer nöronlara giriş olarak verildiği ve geri beslemenin, bir gecikme elemanı üzerinden yapıldığı ağıdır. Geri besleme, bir katmandaki nöronlar arasında olduğu gibi katmanlar arasındaki nöronlar arasında da olabilir (Haykin, 1994). Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir ve herhangi bir andaki çıkış hem o andaki hem de önceki girişlerine bağlıdır.

Ağların eğitimi için kullanılan öğrenme kuralları genellikle danışmanlı öğrenme ve danışmansız öğrenme olmak üzere iki öğrenme yöntemi başlığı altında toplanabilir. Öğrenme yöntemleri Şekil 2.3’de verilmiştir.

Danışmanlı öğrenme kuralları, arzu edilen ağ çıkışının elde edilebilmesi için, çıkış hatasının düşürülmesinde ağırlıkların uyarlanabilir hale getirilmesini gerektirir. Danışmanlı öğrenmede her giriş değeri için istenen çıkış belli olmaktadır ve sisteme tanıtılır. Sonra yapay sinir ağının giriş-çıkış ilişkisini gerçekleştirene kadar ağırlıklar aşama-aşama ayarlar. Bu öğrenme yönteminde gerçek çıkış istenen çıkışla kıyaslanır. Başlangıçta rasgele atanan ağırlıklar ağ tarafından öyle ayarlanır ki, bir sonraki döngüde gerçek çıkış istenen çıkışa yaklaşmış olsun. Bu öğrenme yöntemi, bütün işlem elemanlarının hatalarını en aza indirmeye çalışır. Hata kabul edilebilir derecede küçülene kadar ağırlıklar devamlı olarak değiştirilir. Öğrenme aşaması tamamlandıktan sonra ağ kullanılmaya başlandığında, bulunan ağırlıkların değeri sabit olarak kalır ve bir daha değiştirilemez.



Şekil 2.3 Öğrenme yöntemleri (internet: SUZEP, <http://farabi.selcuk.edu.tr/egitim/ysa>, son erişim: Aralık 2007)

Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri yayılım algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.

Danışmansız öğrenmede bir danışman veya öğretmen, sinir ağına girişin hangi veri parçası sınıfına ait olduğunu veya ağın nerede iyi sonuç vereceğini söylemez. Ağ veriyi üyeleri birbirine benzer olan öbeklere yol gösterilmeksizin ayırır. Danışmansız öğrenme danışmanlı öğrenmeye göre çok daha hızlıdır. Ayrıca matematik algoritmaları da daha basittir (Elmas, 2003a).

Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir (Sağıroğlu ve ark, 2003).

Bir çok YSA yapısı mevcuttur. Çok Katmanlı Perseptron (ÇKP), RTN, LVQ, SOM, ART, Hopfield Ağları, Elman Ağları, Jordan Ağları ve Kohonen Ağlar bunlara örnek olarak verilebilir.

ÇKP bir giriş katmanı, bir veya birden fazla ara katman ve bir çıkış katmanından oluşan ileri beslemeli bir YSA tipidir. Giriş katmanındaki nöronlar, giriş sinyallerini ara katmandaki nöronlara dağıtır. Ara katmandaki nöronlar giriş katmanından gelen girişler bağlantı ağırlıklarıyla çarpıldıktan sonra toplanır ve bir aktivasyon fonksiyonundan geçirilerek çıkış katmanına aktarılır. Çıkış katmanındaki nöronlar ara katman elemanları gibi davranarak ağ çıkış değerini hesaplar. Çıkış değeri ile beklenen sonuç değeri arasındaki fark kabul edilebilir bir hata değerinden fazlaysa, bağlantı ağırlıkları güncelenir hesaplamalar yeniden yapılır.

Uygulamalarda en çok kullanılan öğrenme algoritması Geri Yayılım Algoritmasıdır. Anlaşılması kolay ve matematiksel olarak kolayca ispatlanabilir olmasından dolayı en çok tercih edilen öğrenme algoritmasıdır (Rumelhart, McClelland, 1986). Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri Yayılım Algoritması, katmanlar arasında mevcut olan ağırlıklı bağlantıların, ağ çıkışında oluşan hataya bağlı olarak optimize edilmesini amaçlar. Giriş ve ilgili çıkış vektörü ağı eğitmek için kullanılmaktadır. Giriş vektörü ağı ilk katmanına verildikten sonra aradaki gizli katmanlardan geçerek en sondaki çıkış katmanına ağırlıklar yardımı ile ulaşır.

Algoritmanın çalışması aşağıdaki gibidir (Fausett, 1994):

Adım 0. Ağırlıklar ve eşikler atanır (Rasgele küçük gerçel sayılar ata).

Adım 1. Durdurma kriterleri yanlış olduğu sürece Adım 2-9 çalıştırılır.

Adım 2. Her eğitim verisi için Adım 3-8 çalıştırılır.

Adım 3. Her x_i ($i=1,2,...,n$) giriş nöronuna eğitim verisi atanır.

Adım 4. Gizli katmandaki her z_{tj} ($j=1,2,...,p$) nöronu için giriş değerlerinin ağırlıklı toplamı hesaplanır:

$$zt_j = \sum_{i=1}^n x_i v_{ij} + \theta_j$$

Burada, v_{ij} giriş katmanının i . nöronu ile gizli katmanın j . nöronu arasındaki ağırlık, θ_j ise gizli katmanın j . nöronu için eşik değeridir.

Gizli katmandaki nöronların çıkışını bulmak için aktivasyon fonksiyonu zt_j 'ye uygulanır:

$$z_j = f(zt_j)$$

ve bulunan sonuç bir sonraki katmana gönderilir.

Adım 5. Çıkış katmanının her y_k ($k=1,2,\dots,m$) nöronu için giriş değerlerinin ağırlıklı toplamı hesaplanır:

$$yt_k = \sum_{j=1}^p z_j w_{jk} + \xi_k$$

Burada, w_{jk} gizli katmanın j . nöronu ile çıkış katmanının k . nöronu arasındaki ağırlık, ξ_k ise çıkış katmanının k . nöronu için eşik değeridir.

Gizli katmandaki nöronların çıkışını bulmak için aktivasyon fonksiyonu yt_k 'ya uygulanır:

$$y_k = f(yt_k)$$

Adım 6. Çıkış katmanının her y_k ($k=1,2,\dots,m$) nöronu için beklenen t_k değeri ile hesaplanan y_k değeri karşılaştırılır ve hata bulunur:

$$\delta_k = (t_k - y_k) f'(y t_k)$$

Ağırlıklardaki ve eşikteki değişim aşağıdaki gibi hesaplanır:

$$\Delta w_{jk} = \alpha \delta_k z_j$$

$$\Delta \xi_k = \alpha \delta_k$$

Burada, α eğitim hızıdır.

Adım 7. Gizli katmanın her z_j ($j=1,2,\dots,p$) nöronu için ağırlıklardaki ve eşikteki değişim aşağıdaki gibi hesaplanır:

$$\delta t_j = \sum_{k=1}^m \delta_k w_{jk}$$

$$\delta_j = \delta t_j f'(z t_j)$$

$$\Delta v_{ij} = \alpha \delta_j x_i$$

$$\Delta \theta_j = \alpha \delta_j$$

Adım 8. Çıkış katmanının her y_k ($k=1,2,\dots,m$) nöronu için ağırlıklar ve eşik güncellenir:

$$w_{jk} = w_{jk} + \Delta w_{jk}$$

$$\xi_k = \xi_k + \Delta \xi_k$$

Gizli katmanın her z_j ($j=1,2,\dots,p$) nöronu için ağırlıklar ve eşik güncellenir:

$$v_{jk} = v_{jk} + \Delta v_{jk}$$

$$\theta_k = \theta_k + \Delta \theta_k$$

Adım 9. Durdurma kriterlerine bakılır.

2.2.2. Bulanık mantık

Bulanık mantığın yaygın olarak kullanıldığı temel alanlar kontrol, görüntü işleme, sinyal işleme, denetleyici sistemler, uzman sistemler, veritabanları, veri madenciliği olarak sıralanabilir.

Bulanık mantık kesin akıl yürütme yerine yaklaşık akıl yürütme kullanmaktadır. Tam ve kesin olmayan bilgilere dayanarak tutarlı ve doğru kararlar vermeyi sağlayan düşünme ve karar verme mekanizması bulanık mantık olarak adlandırılır (Allahverdi, 2002).

Geleneksel küme teorisinde kullanılan küme kavramı bir nesnenin bir kümenin elemanı olması yada olmaması gibi iki seçenekli bir mantığa dayanmaktadır. Bulanık mantıkta ise nitelikleri iki üyelik fonksiyonuyla (elemandır veya elemanı değildir) ifade edildiği klasik kümeler yerine, dereceli üyelik fonksiyonuyla ifade edildiği bulanık kümeler tanımlanır.

Bulanık mantık belirsiz durumları doğal dilde ifade etmemizi sağlar. Örneğin hava durumu klasik mantıkla net ifade edilemezken, bulanık mantıkla daha gerçekçi bir şekilde ifade edilir. Bulanık mantık için matematiğin gerçek dünyaya uygulanması denebilir (Elmas, 2003b).

Bulanık kümelerde üyelik dereceleri arasındaki geçiş yumuşak ve sürekli bir şekilde olmaktadır. Bulanık kümelerde öğelerin bu kümelere aitliği kısmi olabilmektedir. Klasik kümelerdeki karakteristik fonksiyon, $\mu_A : E \rightarrow \{0,1\}$, bulanık kümelerde yerini $\mu_A : E \rightarrow [0,1]$ olarak gösterilen üyelik fonksiyonuna bırakır.

Bulanık kümelerde, söz konusu evrenin elemanlarının bir A bulanık kümesine ait olma derecelerini temsil etmek amacıyla üyelik fonksiyonları belirlenir. Bulanık kümeler, üyelik fonksiyonları ile tanımlanırlar. Bu fonksiyonlar, elemanlara $[0,1]$ kapalı aralığında gerçel değerler atayarak elemanların A bulanık kümesi ile temsil edilen kavrama ne derece uygun olduklarını veya A bulanık kümesi ile temsil edilen özellikleri ne derecede taşıdıklarını gösterirler (Allahverdi, 2002).

X evrensel kümesinde tanımlanan, A bulanık kümesi için üyelik fonksiyonu aşağıdaki gibi tanımlanır:

$$\mu_A : X \rightarrow [0,1]$$

Üyelik fonksiyonu grafiğinde x ekseni üyeleri gösterirken, y ekseni de üyelik derecelerini gösterir. Çok sayıda üyelik fonksiyonu tipi olmakla beraber pratikte en fazla kullanılanlar üçgen, yamuk, çan eğrisi, Gauss ve sigmoid fonksiyonlarıdır.

Yamuk üyelik fonksiyonu dört parametre ile tanımlanır:

$$\mu_A(x; a, b, c, d) = \begin{cases} \frac{x-a}{b-a} & , \quad a \leq x \leq b \\ \frac{d-x}{d-c} & , \quad c \leq x \leq d \\ 1 & , \quad b \leq x \leq c \\ 0 & , \quad x > d, x < a \end{cases}$$

Üçgen üyelik fonksiyonu üç parametre ile tanımlanır:

$$\mu_A(x; a, b, c) = \begin{cases} \frac{x-a}{b-a} & , \quad a \leq x \leq b \\ \frac{c-x}{c-b} & , \quad b \leq x \leq c \\ 0 & , \quad x > c, x < a \end{cases}$$

Üçgen üyelik fonksiyonu yamuk üyelik fonksiyonunun özel bir durumudur.

Gauss üyelik fonksiyonu iki parametre ile tanımlanır:

$$\mu_A(x; m, \sigma) = e^{\frac{-(x-m)^2}{2\sigma^2}}$$

Bu fonksiyonda m fonksiyon merkezini ve σ da genişliğini ifade eder. σ değerini değiştirerek, fonksiyonun biçimini değiştirebiliriz. Eğer σ küçük olursa, üyelik fonksiyonu daha dar olurken, bu değer büyüdükçe üyelik fonksiyonu gittikçe yayvanlaşacaktır.

Çan şekilli üyelik fonksiyonu üç parametre ile tanımlanır:

$$\mu_A(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^b}$$

Sigmoid üyelik fonksiyonu iki parametre ile tanımlanır:

$$\mu_A(x; a, b) = \frac{1}{1 + e^{-a(x-b)}}$$

S üyelik fonksiyonu iki parametre ile tanımlanan düzgün bir üyelik fonksiyonudur. Bu fonksiyonun adı şeklinin S harfine benzemesinden gelmektedir:

$$\mu_A(x; a, b) = \begin{cases} 0 & , \quad x \leq a \\ 2\left(\frac{x-a}{b-a}\right)^2 & , \quad a \leq x \leq \frac{a+b}{2} \\ 1 - 2\left(\frac{x-b}{b-a}\right)^2 & , \quad \frac{a+b}{2} \leq x \leq b \\ 1 & , \quad x \geq b \end{cases}$$

Diğer bir üyelik fonksiyonu da Π tip üyelik fonksiyonudur. İki tip Π üyelik fonksiyonu vardır. İlki iki parametre ve ikincisi dört parametre ile tanımlanır:

$$\Pi_1 = \mu_A(x; a, b) = \frac{1}{1 + \left(\frac{x-a}{b}\right)^2}$$


$$\Pi_2 = \mu_A(x; lw, lp, rp, rw) = \begin{cases} \frac{lw}{lp + lw - x} & , \quad x \leq lp \\ \frac{rw}{x - rp + rw} & , \quad x > rp \\ 1 & , \quad lp \leq x \leq rp \end{cases}$$

A bulanık kümesinde tam üyeliğe sahip yani $\mu_A(x) = 1$ olan elemanların oluşturduğu bölgeye üyelik fonksiyonunun çekirdeği denir (Şekil 2.4).

A bulanık kümesinde sıfır olmayan üyeliğe sahip olan elemanların oluşturduğu bölgeye üyelik fonksiyonunun desteği denir (Şekil 2.4).

A bulanık kümesinde $0 < \mu_A(x) < 1$ üyeliğe sahip elemanların oluşturduğu bölgeye üyelik fonksiyonunun sınırları denir (Şekil 2.4).

A bulanık kümesinde üyelik derecesi 0.5'e eşit olan noktaya geçiş noktası denir (Şekil 2.4).



Şekil 2.4 Bir bulanık kümenin çekirdeği, desteği ve sınırları

Bir bulanık küme işlemi sonucunda bulanık kümenin kesin sayı haline dönüştürülmesi gerekebilir. Bunun için durulaştırma yapılmaktadır. İyi bir durulaştırma stratejisi seçmek için sistematik bir işlem yoktur ve bundan dolayı uygulamanın özelliklerini dikkate alan bir yöntem seçilmesi gerekir.

Matematiksel olarak, bulanıklaştırma, R gerçel sayılar alanı, F bulanık kümeler alanı olmak üzere

$$\text{Bulanıklaştırma}(R) \rightarrow F$$

ile gösterilirse bunun tersi durulaştırma olarak tanımlanır. Bu işlem bulanık bir kümeyi sayısal değerlere çevirir. Durulaştırma

$$\text{Durulaştırma}(F) \rightarrow R$$

olarak gösterilebilir. Durulaştırma yöntemlerinde genel olarak aşağıdaki özellikler gözlemlenmektedir (Baykal ve Beyan, 2004b).

1. Durulaştırma esnasında daima kesin bir sayısal değer hesaplanır. Bu durulaştırmanın tanımı gereğidir. Bazen, iki bulanık küme aynı durulaştırılmış değeri verebilir. Ayrıca, durulaştırılmış değer daima orijinal bulanık kümenin desteği üzerinde olduğu kabul edilir.

2. Üyelik fonksiyonu durulaştırılmış değeri belirler. Bulanık kümenin monoton olarak daraltılması normal bir bulanık kümenin normalini verir. Benzer şekilde monoton genişletme işlemi bulanık küme normalinden itibaren durulaştırılmış bir değeri verir.

3. İki üçgen bulanık sayının işleme sokulup durulaştırılmasından elde edilen değer daima bireysel olarak durulaştırılıp işleme sokulmasında elde edilen değerlerin arasında yer alır. A_f, B_f ; bulanık kümeler ve T de t -norm olmak üzere

$$C_f = T(A_f, B_f)$$

ise

$$\text{Durulařtırma}(A_f) \leq \text{Durulařtırma}(C_f) \leq \text{Durulařtırma}(B_f)$$

Bu durum S norm olmak üzere

$$C_f = S(A_f, B_f)$$

řeklinde ifade edilir.

30'dan fazla durulařtırma yöntemi vardır. Bunların sıklıkla kullanılanları üyelik ilkesi, sentroid yöntemi, ağırlıklı ortalama yöntemi, ortalama en büyük üyelik, toplamların merkezi, en büyük alanın merkezi, en büyük ilk veya son üyelik derecesidir. Dört durulařtırma yöntemi sıklıkla kullanılmaktadır. Bunlar, en büyüklerin ortası, ağırlık merkezi yöntemi, ortalamaların merkezi ve alan merkezi yöntemidir.

1. En Büyüklerin ortası: En büyüklerin ortası stratejisi üyelik fonksiyonlarının en büyüğe ulařtığı tüm denetim etkinliklerinin ortalama deęerlerini temsil eden bir denetim etkinlięi üretir. Ayrık bir evren varlığında denetim etkinlięi z_j üyelik fonksiyonunun en büyüğe ulařtığı denetim etkinlięi, k bu řekilde denetim etkinliklerinin sayısı olmak üzere;

$$z_0 = \sum_{j=1}^k \frac{z_j}{k}$$

olarak açıklanabilir.

2. Ağırlık Merkezi Yöntemi (Sentroid Yöntemi): Yaygın olarak kullanılan ağırlık merkezi stratejisi bulanık C kümesinin olabilirlik daęılımının çekim noktasını

üretir. Çıktının niceleme sayısı n olduğunda, C , z çıkış boyutunda tanımlanan bir bulanık kümedir.

$$z_0 = \frac{\sum_{j=1}^n \mu_c(z_j) * z_j}{\sum_{j=1}^n \mu_c(z_j)}$$

3. Ortalama Merkezi: Bir bulanık kümenin değeri;

$$\sum_{i=EK_j(j \in M)}^h \mu(x_i) = \sum_{i=h}^{\mu} \mu(x_i)$$

$$M = \{i | \mu_i = EB\{\mu_1, \dots, \mu_n\}\} \quad \bar{x} = x_h$$

4. İki bölümlü alan yöntemi: Bu yöntemde çıktı bulanık kümesi en azından iki tane dışbükey alt bulanık kümeyi içeriyorsa dışbükey bulanık kümelerin en büyük alanlısının ağırlık merkezi durulaştırma işleminde kullanılır. İki bölümlü alan yöntemi, aynı alanlı iki bölgeye ayıran bir etkinlik (Z_0) üretir.

$$\alpha = EK\{z | z \in W\}$$

$$\beta = EB\{z | z \in W\}$$

olmak üzere,

$$\int_{\alpha}^{z_0} \mu_c(z) dz = \int_{z_0}^{\beta} \mu_c(z) dz$$

olarak hesaplanır (Baykal ve Beyan, 2004b).

Bulanık mantıkta değil ($\bar{}$), ve ($\wedge$), veya ($\vee$) ve içerme ($\Rightarrow$) gibi çeşitli işlemler kullanılmaktadır. Bununla beraber bu işlemlerin anlamını açıklayan farklı tanımlamalar bulunmaktadır. Eğer Lukasiewicz'in tanımını izlersek, $a, b \in [0,1]$ olmak üzere şu şekilde tanımlanırlar (Baykal ve Beyan, 2004b):

$$\text{Değil: } \bar{a} = 1 - a$$

$$\text{Evet: } a \wedge b = EK(a, b)$$

$$\text{Veya: } a \vee b = EB(a, b)$$

$$\text{İçerme: } a \Rightarrow b = EK(1, 1 + b - a)$$

Bulanık kümelerde çok kullanılan iki tip işlem bulunmaktadır. Bunlar T -norm ve S -normdur. Literatürde değişik parametrelerle pek çok T -norm ve S -norm işlemleri kullanılmıştır. T -norm klasik mantıktaki VE işleminin, S -norm ise VEYA işleminin karşılığıdır.

Tanım 2.1. (T -norm)

$T : [0,1] \times [0,1] \rightarrow [0,1]$ ve $\forall x, y, z, x', y' \in [0,1]$ olmak üzere aşağıdaki dört şartı sağlayan T işlemine t -norm denir.

1. Sınır koşulu :

$$T(0,0) = 0, \quad T(x,1) = x$$

2. Değişme özelliği:

$$T(x, y) = T(y, x)$$

3. Monotonluk özelliği

$$(x \leq x', y \leq y') \rightarrow T(x, y) \leq T(x', y')$$

4. Birleşme özelliği

$$T(T(x, y), z) = T(x, T(y, z))$$

Çizelge 2.2’de en çok kullanılan T -normlar görülmektedir.

Çizelge 2.2 Temel T -normlar

İŞLEM	TANIM
En küçük	$EK(a, b) = EK\{a, b\}$
Lukasiewicz (Sınırlandırılmış)	$L_{ve}(a, b) = EB\{a + b - 1, 0\}$
Olasılıkçı (Cebirsel)	$P_{ve}(a, b) = ab$
Zayıf	$ZAYIF(a, b) = \begin{cases} EK\{a, b\} & , \quad EB\{a, b\} = 1 \\ 0 & , \quad EB\{a, b\} \neq 1 \end{cases}$
Hamacher	$H_{ve}\gamma(a, b) = \frac{ab}{\gamma + (1 - \gamma)(a + b - ab)} \quad , \quad \gamma \geq 0$
Dubois ve Prade	$D_{ve}\alpha(a, b) = \frac{ab}{E\{a, b, \alpha\}} \quad , \quad \alpha \in (0, 1)$
Yager	$Y_{vep}(a, b) = 1 - EK\left\{1, \left[(1 - a)^p + (1 - b)^p\right]^{1/p}\right\} \quad , \quad p > 0$

Tanım 2.2. (S -norm)

$S : [0, 1] \times [0, 1] \rightarrow [0, 1]$ ve $\forall x, y, z, x', y' \in [0, 1]$ olmak üzere aşağıdaki dört şartı sağlayan S işlemine S -norm denir.

1. Sınır koşulu :

$$S(1, 1) = 1 \quad , \quad S(x, 0) = x$$

2. Değişme özelliği:

$$S(x, y) = S(y, x)$$

3. Monotonluk özelliği

$$(x \leq x', y \leq y') \rightarrow S(x, y) \leq S(x', y')$$

4. Birleşme özelliği

$$S(S(x, y), z) = S(x, S(y, z))$$

Çizelge 2.3'de en çok kullanılan s -normlar görülmektedir.

Çizelge 2.3 Temel s-normlar

İŞLEM	TANIM
En büyük	$EB(a,b) = EB\{a,b\}$
Lukasiewicz (Sınırlandırılmış)	$L_{VEYA}(a,b) = Ek\{a+b,1\}$
Olasılıkçı (Cebirsel)	$P_{VEYA}(a,b) = a+b-ab$
Güçlü	$GÜÇLÜ(a,b) = \begin{cases} EB\{a,b\} & , \quad EK\{a,b\}=0 \\ 1 & , \quad EK\{a,b\}\neq 0 \end{cases}$
Yager	$Y_{VEYAp}(a,b) = EK\{1, (a^p + b^p)^{1/p}\}, p>0$

2.2.3. Bulanık sinir ağıları

Bulanık mantık bir çok alanda başarıyla uygulanmaktadır. Bulanık mantığın uygulanmasında dilsel giriş değerleri üyelik fonksiyonları ile kullanılıyor. Bulanık mantığa dayalı bir sistemde parametrelerin bulanık mantık uzmanlarınca belirlenmesi gerekir. Bu parametrelerin belirlenmesi bazı geliştirme algoritmaları ve deneme yanılma yöntemleri ile yapılır. Bunun dışında sistemi iyi bilen bir uzmanın ilk kural tabanını oluşturması gerekir

Bulanık Sinir Ağı (BSA), YSA'nın öğrenme yeteneği, en uygunu bulma ve bağlantılı yapılar gibi, bulanık mantığın insan gibi karar verme ve uzman bilgisi sağlama kolaylığı gibi üstünlüklerinin birleştirilmesi fikrine dayanmaktadır (Elmas, 2003b).

BSA bulanık sinyalleri işleyen ve/veya bulanık ağırlıkları olan sinir ağıdır. Yani eğer bulanık sinir ağı inceliyorsak giriş değerlerinin ve/veya ağırlıkların bulanık değerlerle belirtilmesi gerekmektedir.

Bu yaklaşımda, bulanık mantık kavramları, klasik sinir ağlarının bilgi sunum yeteneklerini zenginleştirmek için kullanılmaktadır. Bu da sinir ağlarının girdi, ağırlıklar, bileşke işlemleri, aktivasyon fonksiyonları ve çıktı gibi düzeylerinde bulanık kavramların kullanılması ile sağlanabilir.

Standart matematiksel modeller kullanan sinirler, t -norm ve s -norm işlemleri kullanan bulanık sinirlere dönüşür. Bu ağlar bulanık girdiler alıp, öğretim için klasik geri yayılım algoritmasının analogunu geliştirmektedir (Baykal ve Beyan, 2004a). Bir BSA'da bütün girişler, çıkışlar ve ağırlıklar gerçel sayılar olmak üzere $[0,1]$ arasında alınmalıdır (Elmas, 2003b).

Bulanık sinir ağının işleme birimine bulanık sinir hücresi denir. Bulanık sinir hücrelerine örnek olarak “ve” (eb-ek) , “veya” (eb-ek) , “veya” (eb-çarpım), içleme-veya, Kwan ve Cai, Kwan ve Cai'nin EB, Kwan ve Cai'nin EK verilebilir.

En yaygın kullanılan bulanık sinir hücresi “ve” ‘dir. Bu nöronda önce x_i girişleri ile w_{ij} ağırlıkları arasında S -norm kullanılır.

$$d_{ij} = S(x_i, w_{ij})$$

d_{ij} girdilerinden çıktı üretmek için T -norm işlemi uygulanır:

$$y_j = T_{i=1}^n d_{ij} = T_{i=1}^n (S(x_i, w_{ij}))$$

BSA'nın 4 tipi vardır (Fuller, 1995). Bu tipler Çizelge 2.4'de görülmektedir.

Çizelge 2.4 Bulanık Sinir Ağı Tipleri

Bulanık Sinir Ağı	Ağırlıklar	Girişler	Çıkışlar
Tip1 (BSA ₁)	Kesin	Bulanık	Kesin
Tip2 (BSA ₂)	Kesin	Bulanık	Bulanık
Tip3 (BSA ₃)	Bulanık	Bulanık	Bulanık
Tip4 (BSA ₄)	Bulanık	Kesin	Bulanık

BSA₁ ağı sınıflandırma problemleri için kullanılır (Ishibuchi ve ark., 1992, Lee ve Wang, 1994). BSA₂, BSA₃, BSA₄ ağları ise bulanık Eğer-O Halde kurallarını gerçekleştirmek için kullanılır (Ishibuchi, 1994).

BSA₃ tipi bir ağı eğitilmesi için aşağıdaki yöntem izlenir (Aliev ve Aliev, 2001). Ağı genel çıkışı aşağıdaki gibidir:

$$Y_l = f \left[\sum_{i=1}^m \tilde{K}_j \tilde{Z}_{ij} \right]$$

Burada, $\tilde{Z}_{ij}$ girişe $\tilde{X}_l = (\tilde{X}_{l1}, \tilde{X}_{l2}, \dots, \tilde{X}_{ln})$ bulanık vektörü girdiği zaman j . nöronun bulanık çıkışı, $\tilde{K}_j$ ara katmanın j . nöronu ile çıkış nöronu arasındaki bulanık ağırlıktır. f aktivasyon fonksiyonudur. $\tilde{Z}_{ij}$ aşağıdaki gibi tanımlanır:

$$\tilde{Z}_{ij} = f \left[\sum_{i=1}^n X_{li} W_{ij} \right]$$

Burada, $\tilde{W}_{ij}$ giriş katmanının i . nöronu ile gizli katmanın j . nöronu arasındaki bulanık ağırlıktır.

Beklenen çıkışla hesaplanan çıkış arasındaki hata aşağıdaki gibidir:

$$\tilde{E} = \frac{1}{2} \sum_{i=1}^n (\tilde{Y}_i - \tilde{Y}_i^*)^2$$

Burada, $\tilde{Y}_i^*$ beklenen bulanık çıkış değeridir. $\tilde{K}_j$ bulanık ağırlıkları aşağıdaki gibi güncellenecektir:

$$\tilde{K}_j(q+1) = \tilde{K}_j(q) + \alpha \Delta \tilde{K}_j(q)$$

$$\Delta \tilde{K}_j(q) = \frac{\partial \tilde{E}}{\partial \tilde{K}_j}$$

$$\frac{\partial \tilde{E}}{\partial \tilde{K}_j} = \sum_{i=1}^n (\tilde{Y}_i - \tilde{Y}_i^*) (\tilde{Y}_i) (1 - \tilde{Y}_i) \tilde{Z}_{ij}$$

Burada, α eğitim hızıdır. $\tilde{W}_{ij}$ ağırlıkları aşağıdaki gibi güncellenecektir:

$$\tilde{W}_{ij}(q+1) = \tilde{W}_{ij}(q) + \alpha \Delta \tilde{W}_{ij}(q)$$

$$\frac{\partial \tilde{E}}{\partial \tilde{W}_{ij}} = \sum_{i=1}^n (\tilde{Y}_i - \tilde{Y}_i^*) (\tilde{Y}_i) (1 - \tilde{Y}_i) \tilde{K}_j \frac{\partial \tilde{Z}_{ij}}{\partial \tilde{W}_{ij}}$$

$$\frac{\partial \tilde{Z}_{ij}}{\partial \tilde{W}_{ij}} = (\tilde{Z}_{ij}) (1 - \tilde{Z}_{ij}) \tilde{X}_{ji}$$

2.3. Başarım Ölçümü

Oluşturulan bir sistemin başarısının ölçülmesi gerekmektedir. Sonuçların test edilmesi için kullanılan en yaygın yöntemlerden biri k -kat çapraz doğrulama yöntemidir. k -kat çapraz doğrulama yönteminde A veri kümesi rastgele olarak k sayıda $A_1, A_2, \dots, A_k$ alt kümelerine bölünür. Bu A_i kümelerinin eleman sayılarının yaklaşık olarak aynı olması gerekmektedir. Sınıflandırma modelinin k kez eğitilmesi ve test edilmesi gerekir. Eğitim ve test işlemi aşağıdaki gibi yapılmaktadır:

- 1- İlk altküme seçilir, $l=1$.
- 2- l . alt küme hariç diğerleri birleştirilerek eğitim kümesi oluşturulur.

$$E_l = \bigcup_{\substack{i=1 \\ i \neq l}}^k A_i \quad (2.1)$$

- 3- Oluşturulan E_l kümesi ile sınıflandırıcının eğitimi yapılır.
- 4- Geride kalan A_l kümeyle test yapılır ve başarısı b_l elde edilir.
- 5- $l=l+1$
- 6- $l \leq k$ ise Adım 2-5 tekrar edilir.
- 7- Genel başarı hesaplanır:

$$b = \frac{\sum_{i=1}^k b_i}{k} \quad (2.2)$$

Görüldüğü gibi her seferinde oluşan k alt kümeden $(k-1)$ tanesiyle eğitim, diğer kümeyle test yapılır ve elde edilen sonuçların aritmetik ortalaması bulunur. Bulunan ortalama değer, sistemin başarısı olarak kabul edilir.

Deneyisel çalışmalar göstermiştir ki, k -kat çapraz doğrulama yönteminde k için optimum değer 10'dur (Breiman ve ark., 1984, Kohavi, 1995).

Sistemin başarısı aşağıdaki gibi ölçülmektedir:

$$b = \frac{ds}{vs} \quad (2.3)$$

Burada, ds doğru sınıflandırılan veri sayısı, vs toplam veri sayısıdır.


2.4. Hibrit Bulanık Sinir Ağı

Daha önce de bahsedildiği gibi gerçek dünya problemlerinde genellikle gerçel ve ayrık veriler birarada kullanılmaktadır. Dolayısıyla tek başına ikili veya gerçel kodlama verileri tam yansıtamamaktadır. Bu nedenle bu çalışmada iki tip kodlama yapılmış, buna uygun olarak sınıflandırma için hibrit bir sinir ağı geliştirilmiştir ve bu ağıın eğitim algoritması sunulmuştur.


Önerilen hibrid sinir ağı BSA₁ tipi bir bulanık sinir ağıyla ÇKP'nin birleşiminden oluşmaktadır. Hibrid Sinir Ağıının mimarisi Şekil 2.5'de gösterilmektedir. Ağıın eğitilmesi için geri yayılım algoritması kullanılmıştır. İlk aşamada kesin veriler ikili olarak kodlanıyor ve bulanıklaşacak veriler bulanıklaştırılıyor. İkinci aşamada kesin veriler YSA1'e, bulanık veriler BSA'ya giriş olarak verilir ve sonuçlar elde edilir. Üçüncü aşamada elde edilen bu iki sonuç YSA2'ye giriş olarak verilir ve hibrid ağıın sonucu elde edilir. Çıkan sonuç beklenen sonuçla karşılaştırılır ve geri yayılım algoritmasının ağırlık güncelleme yöntemi

kullanılarak ağıın ağırlıkları güncellenir. Hibrid Sinir Ağıının yapısı Şekil 2.6'da gösterilmektedir. Sistemin eğitilmesi için aşağıdaki algoritma kullanılmaktadır:

- Adım 0. Ağırlıkları ve eşikleri atanır.
- Adım 1. Kesin veriler ikili olarak kodlanır.
- Adım 2. Bulanıklaşacak veriler bulanıklaştırılır.
- Adım 3. Durdurma kriterleri yanlış olduğu sürece Adım 4-9 çalıştırılır.
- Adım 4. Her eğitim verisi için Adım 5-8 çalıştırılır.
- Adım 5. Bulanık veriler BSA'ya giriş olarak verilir ve sonuç elde edilir.
- Adım 6. Kesin veriler YSA1'e giriş olarak verilir ve sonuç elde edilir.
- Adım 7. 5. ve 6. adımda elde edilen sonuçlar YSA2'ye giriş olarak verilir ve sonuç elde edilir.
- Adım 8. Hesaplanan değer beklenen değerden farklıysa, ağırlıklar güncellenir.
- Adım 9. Durdurma kriterlerine bakılır.



Şekil 2.5 Hibrid Sinir Ağıının Mimarisi



Şekil 2.6 Hibrid Sinir Ağının Yapısı

Bu çalışmada bulanıklaştırma yöntemi olarak, çok yaygın kullanılan üçgen ve yamuk bulanıklaştırıcı, etkinleştirme fonksiyonu olarak sigmoid tercih edilmektedir.

Bu sinir ağı için çıkış nöronunun fonksiyonunu oluşturalım. Bunun için ilk önce YSA1'e bakmamız gerekmektedir. YSA1'de gizli katman nöronları için ağırlıklı toplamlar aşağıdaki gibi olacaktır:

$$ty_j = \sum_{i=1}^n w_{ij}x_i, \quad j=1,2,\dots,k \quad (2.4)$$

Burada, k YSA1'in gizli katmanındaki nöron sayısı, n YSA1'in giriş vektörünün eleman sayısıdır. Buradan gizli katman nöronlarının çıkışı aşağıdaki gibi belirlenmektedir:

$$y_j = \frac{1}{1 + e^{-ty_j + \theta_j}}, \quad j=1,2,\dots,k \quad (2.5)$$

(2.5)'de (2.4)'ü yazarsak

$$y_j = \frac{1}{1 + e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \quad (2.6)$$

bulunur.

YSA1'in çıkış katman nöronu için ağırlıklı toplam aşağıdaki gibi olacaktır:

$$tz = \sum_{j=1}^k v_j y_j \quad (2.7)$$

(2.6)' yı (2.7)'de yazarsak

$$tz = \sum_{j=1}^k \left(v_j \frac{1}{1 + e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \right) \quad (2.8)$$

bulunur.

YSA1'in çıkışı aşağıdaki gibidir:

$$z = \frac{1}{1 + e^{-tz + \xi}} \quad (2.9)$$

(2.8)'i (2.9)'da yazarsak YSA1'in çıkış nöronu için aşağıdaki gibi bir fonksiyon elde ederiz.

$$z = \left(1 + e^{-\sum_{j=1}^k \left(v_j \frac{1}{1 + e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \right) + \xi} \right)^{-1} \quad (2.10)$$

(2.4) - (2.10) formüllerini BSA için uygularsak BSA'nın çıkışı için aşağıdaki fonksiyonu elde ederiz.

$$zb = \left(1 + e^{-\sum_{j=1}^l \left(vb_j \frac{1}{1 + e^{-\sum_{i=1}^m wb_{ij}xb_i + \theta b_j}} \right) + \xi b} \right)^{-1} \quad (2.11)$$

Burada, m BSA'nın giriş vektörünün eleman sayısı, l ise gizli katmandaki nöron sayısıdır.

z ve zb değerleri YSA2'nin giriş vektörünü oluşturmaktadır. Buradan YSA2'nin çıkış vektörünün ağırlıklı toplamı aşağıdaki gibi olur

$$tf = ww_1 z + ww_2 zb \quad (2.12)$$

Genel çıkış ise aşağıdaki gibi olacaktır:

$$C = \frac{1}{1 + e^{-tf + \zeta}} \quad (2.13)$$

(2.12) formülünü (2.13)'de uygularsak

$$C = \frac{1}{1 + e^{-(ww_1 z + ww_2 zb) + \zeta}} \quad (2.14)$$

(2.14)'te (2.10) ve (2.11)'i yazarsak ağın genel çıkışı için aşağıdaki fonksiyonu buluruz:

$$C = \left[\begin{array}{c} 1+e \left[-ww_1 \left(\frac{-\sum_{j=1}^k v_j^* \frac{1}{1+e \left(\frac{-\sum_{i=1}^n w_{ij}x_i + \theta_j}{1+e} \right)} + \xi \right)}{1+e} \right)^{-1} + ww_2 \left(\frac{-\sum_{j=1}^l vb_j^* \frac{1}{1+e \left(\frac{-\sum_{i=1}^m w_{bj}x_i + \theta b_j}{1+e} \right)} + \xi b}{1+e} \right)^{-1} + \zeta \right]^{-1} \end{array} \right] \quad (2.15)$$

2.4.1. Verilerin kodlanması

Uygulama için öncelikle verilerin kodlanması gerekmektedir. Genellikle kodlama için normalizasyon yöntemi kullanılarak veriler $[0, 1]$ aralığına çekilmekte, yada aralıklara bölünerek 0 ve 1 olarak ikili kodlanmaktadır. Bu çalışmada yeni bir kodlama yöntemi kullanılmakta, ayrık ve gerçel verilerin kullanılması için farklı yöntemler uygulanmaktadır. Kullanılan kodlama yöntemi aşağıda detaylı anlatılmaktadır.

Veritabanındaki nitelikler kesin ve bulanıklaşacak olarak ikiye ayrılmış ve ayrı ayrı kodlanmıştır. Kesin nitelikler ikili katarlar olarak kodlanmıştır. Kodlama için aşağıdaki yöntem uygulanmıştır.

Veri N sayıda kesin niteliğe sahip olsun. Her $A_n \{n=1,2,\dots,N\}$ niteliği m_n sayıda $\{a_1, a_2, \dots, a_{m_n}\}$ biçimli alt katarla bölünür ve $\{b_{n1}, b_{n2}, \dots, b_{nm_n}\}$ olarak kodlanır. Eğer A_n niteliği a_i ($i=1,2,\dots,m_n$) alt katarına aitse, b_{nj} aşağıdaki gibi tanımlanır:

$$b_{nj} = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad j = 1, 2, \dots, m_n \quad (2.16)$$

Kesin niteliklerin kodlanmış hali

$$X = \bigcup_{n=1}^N \bigcup_{i=1}^{m_n} b_{ni} \quad (2.17)$$

şeklinde olur. X vektörünün uzunluğu:

$$m = \sum_{n=1}^N m_n \quad (2.18)$$

olarak bulunur.

Bulanıklaşacak verilerin kodlanması için aşağıdaki yöntem uygulanmıştır. Veri K sayıda bulanıklaşacak niteliğe sahip olsun. Her verinin $L_k \{k=1,2,\dots,K\}$ niteliği t_k sayıda $\{l_1, l_2, \dots, l_{t_k}\}$ bulanık değere sahiptir. Bulanıklaşacak niteliklerin kodlanmış hali

$$XB = \bigcup_{k=1}^K \bigcup_{i=1}^{t_k} l_i \quad (2.19)$$

şeklinde olur. XB vektörünün uzunluğu:

$$t = \sum_{k=1}^K t_k \quad (2.20)$$

olarak bulunur. Sonuç olarak hibrit bulanık sinir ağının genel girişi

$$Y = X \cup XB = \left(\bigcup_{n=1}^N \bigcup_{i=1}^{m_n} b_{ni} \right) \cup \left(\bigcup_{k=1}^K \bigcup_{i=1}^{t_k} l_i \right) \quad (2.21)$$

olur. Girişlerin toplam uzunluğu için aşağıdaki formül elde edilir:

$$uz = \sum_{n=1}^N m_n + \sum_{k=1}^K t_k \quad (2.22)$$

2.5. Bölüm Değerlendirmesi

Bu bölümde öncelikle sınıflandırma için önerilen hibrit bulanık sinir ağının temellerini oluşturan yapay sinir ağı, bulanık mantık, bulanık sinir ağı ve sınıflandırma performansının ölçülmesi için kullanılan k -kat çapraz doğrulama hakkında kısaca bilgi verilmektedir. Daha sonra önerilen hibrit bulanık sinir ağı açıklanmaktadır.

Önerilen hibrid sinir ağı BSA₁ tipi bir bulanık sinir ağıyla ÇKP'nin birleşiminden oluşmaktadır. Ağın eğitilmesi için Geri Yayılım Algoritması kullanılmaktadır. İlk aşamada kesin veriler ikili olarak kodlanır ve gerçel değerli veriler bulanıklaştırılır. İkinci aşamada kesin veriler YSA1'e, bulanık veriler BSA'ya giriş olarak verilir ve sonuçlar elde edilir. Üçüncü aşamada elde edilen bu iki sonuç YSA2'ye giriş olarak verilir ve hibrid ağın sonucu elde edilir. Çıkan sonuç beklenen sonuçla karşılaştırılır ve Geri Yayılım Algoritmasının ağırlık güncelleme yöntemi kullanarak ağın ağırlıkları güncellenir. Sistemin başarısı için verilerin kodlanması önemli olmaktadır. Bu nedenle verilerin kodlanması ayrı bir bölümde detaylı olarak açıklanmaktadır. Bir sonraki bölümde iki hibrit bulanık sinir ağı uygulaması hakkında bilgi verilmektedir.

3. HİBRİT BULANIK SİNİR AĞI İÇİN DENEYSEL SONUÇLAR VE ANALİZ

Bu bölümde, bir önceki bölümde önerilen hibrit bulanık sinir ağı iki farklı probleme uygulanmakta ve performansına bakılmaktadır. Kullanılan problemler Cleveland Kalp Hastalıkları ve Hepatit Hastalığı veri kümeleridir. Veriler UCI Machine Learning Repository'den (internet: UCI Machine Learning Repository, <http://www.ics.uci.edu/~mlearn/MLRepository.html>, son erişim: Ocak, 2007) alınmıştır. Uygulama programları Matlab 7.04 SP3 kullanılarak kodlanmıştır (Lisans No: 307471 Öğr. Gör. İsmail SARITAŞ'ın bilgisayarı kullanılmıştır.).

3.1. Cleveland Kalp Hastalıkları Veri Kümesinde Uygulama

Uygulama için kullanılan ilk veri kümesi Cleveland Kalp Hastalıkları veri kümesidir. Bu veri kümesi Robert Detrano tarafından oluşturulmuştur. Veri kümesinin oluşturulmasındaki amaç, hastaya yapılmış çok sayıdaki tıbbi test sonuçlarını hastanın kalp hastası olup olmadığını belirlemek için kullanmaktır. Bu veri kümesi kalp hastalığı teşhisinde kullanılabilecek 76 test sonucunun en önemli 13'ünün kullanılması ile oluşturulmuş 303 örnek içermektedir. Örneklerden 165'i hasta, 138'i sağlıklı sınıfa aittir. Veri kümesindeki örneklerin 13 niteliği şu şekilde verilmiştir:

1- Yaş

2- Cinsiyet

- 3- Göğüs Ağrı Tipi (typical angina, atypical angina, non-anginal, asymptomatic)
- 4- Dinlenme kan basıncı (mm Hg)
- 5- Serum kolesterol (mg/dl)
- 6- Açlık kan şekeri > 120 mg/dl
- 7- Dinlenme elektrokardiyografi (Normal, ST-T wave abnormality, show left ventricular hypertrophy by Estes' criteria)
- 8- Thalach: Elde edilen maksimum nabız
- 9- Anjine sebep olan egzersiz (1 = evet, 0 = hayır)
- 10- Oldpeak: Dinlenmeye kıyasla egzersizle ortaya çıkan ST depresyonu
- 11- Eğim: Egzersiz ST segment tepesinin eğimi: (yukarı, düz, aşağı)
- 12- ca: Floroskopiyle renklendirilen ana damarların sayısı (0-3)
- 13- thal: 3=normal; 6=kalıcı kusur; 7=düzelebilir kusur

Sonuçlar 0 ve 1 olarak kodlanmıştır. “0” kişinin hasta, “1” sağlıklı olduğu anlamına gelmektedir. Çizelge 3.1’de niteliklerin aldığı değerler (değer aralıkları) görülmektedir.

Çizelge 3.1 Cleveland Kalp Hastalıkları veri kümesi için niteliklerin değerleri ve aralıkları

Nitelik	Aralık
Yaş	29 - 77
Cinsiyet	Erkek, kadın
Göğüs Ağrı Tipi	anjin, asympt, notang, abnang
Dinlenme kan basıncı	94 - 200
Serum kolesterol	126 - 564
Açlık kan şekeri > 120	1, 0
Dinlenme elektrokardiyografi	hyper, norm, abn
Elde edilen maksimum nabız	71 – 202
Anjine sebep olan egzersiz	1, 0
Dinlenmeye kıyasla egzersizle ortaya çıkan ST depresyonu	0 – 6.2
Egzersiz ST segment tepesinin eğimi	aşağı, düz, yukarı
Floroskopiyle renklendirilen ana damarların sayısı	0 – 3
thal	kalıcı kusur, norm, düzelebilir kusur

Her kesin nitelik değeri Çizelge 3.2 kullanılarak ikili olarak kodlanmıştır. İkili katarın uzunluğu niteliğin kaç farklı değer alabildiğine göre değişmektedir. Katarın her biti niteliğin hangi alt kümeye ait olduğuna göre “0” veya “1” olmaktadır. Örnek olarak, Göğüs Ağrı Tipi 4 bitten oluşmaktadır ve eğer Göğüs Ağrı Tipi =asympt, o zaman “Göğüs Ağrı Tipi” niteliği (0,1,0,0) olarak kodlanmaktadır.

Çizelge 3.2 Cleveland Kalp Hastalıkları veri kümesindeki kesin verilerin kodlanması

Nitelik	Girişlerin Sayısı	Alt kümeler
Cinsiyet	2	{erkek}, {kadın}
Göğüs Ağrı Tipi	4	{anjin}, {asympt}, {notang} , {abnang}
Açlık kan şekeri > 120	2	{1}, {0}
Dinlenme elektrokardiyografi	3	{hyper}, {norm}, {abn}
Anjine sebep olan egzersiz	2	{1}, {0}
Egzersiz ST segment tepesinin eğimi	3	{aşağı}, {yukarı}, {düz}
Floroskopiyle renklendirilen ana damarların sayısı	4	{0}, {1}, {2}, {3}
Thal	3	{kalıcı kusur}, {norm}, {düzelebilir kusur}

Çizelge 3.2’de gösterilen kodlama yöntemiyle YSA1 için 23 ikili giriş oluşmuştur. Yapılan denemeler sonucu, en başarılı hibrit ağ yapısındaki YSA1 kısmının bir gizli katmana sahip olduğu ve gizli katmandaki nöron sayısının altı olduğu gözlemlenmiştir.

Bulanık nitelikler için uzman doktorlara danışılarak üyelik fonksiyonları üretilmiştir. Bulanık nitelikler Çizelge 3.3’te görülen değerleri almaktadır.


Çizelge 3.3 Cleveland Kalp Hastalıkları veri kümesindeki bulanıklaşacak verilerin
Sinir ağı girişi için kodlanması

Nitelik	Girişlerin Sayısı	Alt kümeler
Yaş	3	{Genç}, {Orta yaşlı}, {Yaşlı}
Dinlenme kan basıncı	3	{Düşük}, {Orta}, {Yüksek}
Serum kolesterol	3	{Düşük}, {Orta}, {Yüksek}
Elde edilen maksimum nabız	3	{Düşük}, {Orta}, {Yüksek}
Dinlenmeye kıyasla egzersizle ortaya çıkan ST depresyonu	3	{Az}, {Orta}, {Yüksek}

Yaş niteliği için tespit edilen üyelik fonksiyonları (3.1)-(3.3)'de görülmektedir.

$$Y_{\text{genç}}(x) = \begin{cases} 1 & , \quad x \leq 20 \\ 2 - \frac{x}{20} & , \quad 20 < x < 40 \\ 0 & , \quad x \geq 40 \end{cases} \quad (3.1)$$

$$Y_{\text{orta}}(x) = \begin{cases} 0 & , \quad x \leq 35, \quad x \geq 55 \\ \frac{x}{10} - 3,5 & , \quad 35 < x \leq 45 \\ 5,5 - \frac{x}{10} & , \quad 45 < x < 55 \end{cases} \quad (3.2)$$



Şekil 3.1 Yaş niteliği için üyelik dereceleri


$$Y_{yasli}(x) = \begin{cases} 0 & , \quad x \leq 50 \\ \frac{x}{10} - 5 & , \quad 50 < x < 60 \\ 1 & , \quad x \geq 60 \end{cases} \quad (3.3)$$

Dinlenme kan basıncı niteliği için tespit edilen üyelik fonksiyonları (3.4)-(3.6)'de görülmektedir.

$$KB_{dusuk} = \begin{cases} 1 & , \quad x \leq 100 \\ 11 - \frac{x}{10} & , \quad 100 < x < 110 \\ 0 & , \quad x \geq 110 \end{cases} \quad (3.4)$$

$$KB_{orta} = \begin{cases} 0 & , \quad x \leq 100, \quad x \geq 130 \\ \frac{x}{20} - 5 & , \quad 100 < x \leq 120 \\ 13 - \frac{x}{10} & , \quad 120 < x < 130 \end{cases} \quad (3.5)$$

$$KB_{yukse} = \begin{cases} 0 & , \quad x \leq 120 \\ \frac{x}{10} - 12 & , \quad 120 < x < 130 \\ 1 & , \quad x \geq 130 \end{cases} \quad (3.6)$$




Şekil 3.2 Dinlenme kan basıncı niteliği için üyelik dereceleri

Serum kolesterol niteliği için tespit edilen üyelik fonksiyonları (3.7) - (3.9)'da görülmektedir.

$$SK_{dusuk} = \begin{cases} 1 & , \quad x \leq 190 \\ \frac{220-x}{30} & , \quad 190 < x < 220 \\ 0 & , \quad x \geq 220 \end{cases} \quad (3.7)$$

$$SK_{orta} = \begin{cases} 0 & , \quad x \leq 190, \quad x \geq 250 \\ \frac{x-190}{30} & , \quad 190 < x \leq 220 \\ \frac{250-x}{30} & , \quad 220 < x < 250 \end{cases} \quad (3.8)$$

$$SK_{yukse} = \begin{cases} 0 & , \quad x \leq 240 \\ \frac{x}{10} - 24 & , \quad 240 < x < 250 \\ 1 & , \quad x \geq 250 \end{cases} \quad (3.9)$$




Şekil 3.3 Serum kolesterol niteliği için üyelik dereceleri

Elde edilen maksimum nabız niteliği için tespit edilen üyelik fonksiyonları (3.10)-(3.12)'de görülmektedir.

$$MN_{dusuk} = \begin{cases} 1 & , \quad x \leq 80 \\ \frac{110 - x}{30} & , \quad 80 < x < 110 \\ 0 & , \quad x \geq 110 \end{cases} \quad (3.10)$$

$$MN_{orta} = \begin{cases} 0 & , \quad x \leq 110, \quad x \geq 150 \\ \frac{x - 100}{25} & , \quad 100 < x \leq 125 \\ 6 - \frac{x}{25} & , \quad 120 < x < 150 \end{cases} \quad (3.11)$$



Şekil 3.4 Elde edilen maksimum nabız niteliği için üyelik dereceleri


$$MN_{yüksek} = \begin{cases} 0 & , \quad x \leq 140 \\ \frac{x}{20} - 7 & , \quad 140 < x < 160 \\ 1 & , \quad x \geq 160 \end{cases} \quad (3.12)$$

ST depresyonu niteliği için tespit edilen üyelik fonksiyonları (3.13)-(3.15)'de görülmektedir.

$$STD_{az} = \begin{cases} 1 & , \quad x \leq 0,5 \\ 2 - 2x & , \quad 0,5 < x < 1 \\ 0 & , \quad x \geq 1 \end{cases} \quad (3.13)$$

$$STD_{orta} = \begin{cases} 0 & , \quad x \leq 0,5, \quad x \geq 2 \\ x - 0,5 & , \quad 0,5 < x \leq 1,5 \\ 4 - 2x & , \quad 1,5 < x < 2 \end{cases} \quad (3.14)$$


$$STD_{yüksek} = \begin{cases} 0 & , \quad x \leq 1,5 \\ \frac{2x}{3} - 1 & , \quad 1,5 < x < 3 \\ 1 & , \quad x \geq 3 \end{cases} \quad (3.15)$$



Şekil 3.5 ST depresyonu niteliği için üyelik dereceleri

Bu şekilde bulanıklaştırılmış verilerle BSA için 15 giriş oluşturulmaktadır. Yapılan denemeler sonucu, en başarılı hibrit ağ yapısındaki BSA kısmının bir gizli katmana sahip olduğu ve gizli katmandaki nöron sayısının dört olduğu gözlemlenmiştir. YSA1'den ve BSA'dan çıkan sonuçlar bir nöronda birleşerek sistemin genel çıkışını üretmektedir. Bu veri kümesi iki sınıftan oluştuğu için çıkış katmanı bir nörondan oluşmaktadır. Sistemin eğitimi için Bölüm 2.4'te açıklanan algoritma kullanılmıştır.

Sistemin başarısını test etmek amacıyla iki farklı yöntem kullanılmıştır. Önce verilerin bir kısmı eğitim verisi, geri kalanı test verisi olarak seçilmiş ve sistemin başarısı tespit edilmiştir. Bunun için verilerin rastgele 212 adedi (tüm verilerin %70'i) eğitim için seçilmiş, geri kalan 91 (tüm verilerin %30'u) adediyle de test yapılmıştır. Eğitim sonucunda test kümesinde bulunan 91 veriden 84'ü doğru teşhis edilmiştir ki, bu da test verilerinin %92.3'ünü oluşturmaktadır. Oluşan hata grafiği Şekil 3.6'da görülmektedir.



Şekil 3.6 Cleveland Kalp Hastalıkları veri kümesi 212 eğitim + 91 test sonucu oluşan hata fonksiyonu

Çizelge 3.4 Cleveland Kalp Hastalıkları veri kümesi için önerilen yöntem ve diğer algoritmaların sınıflandırma başarıları (“eğitim”+”test” yöntemi)
(internet: Benchmark datasets used for classification: Comparison of results, <http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	92.3	
LDA	84.5	Weiss
25-NN, stand, Euclid	83.6±0.5	WD/KG
C-MLP2LN	82.5	RA
FSM	82.2	Rafał Adamczak
MLP+backprop	81.3	Weiss
CART	80.8	Weiss

Cleveland Kalp Hastalıkları veri kümesinde yapılan sınıflandırma sonuçlarının bu şekilde değerlendirilmesi sonucu 80.8% ile 84.5% arasında değiştiği rapor edilmektedir (internet: Benchmark datasets used for classification: comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008). Çizelge 3.4’te sistemin Cleveland Kalp Hastalıkları veri kümesi için başarısı diğer yöntemlerle karşılaştırılmalı olarak görülmektedir.

Sistemin başarısını test etmek için kullanılan ikinci yöntem 10 kez çapraz doğrulama tekniğidir. Bunun için veriler rastgele bir şekilde 10 gruba ayrılmıştır. Oluşan Eğitim-Test kümelerinin yedi adedinde 273 eğitim, 30 test verisi, üçünde ise 272 eğitim, 31 test verisi bulunmaktadır.

Sistemin 10 kez çalışması sonucunda %92.08 başarı elde edilmiştir. Çizelge 3.5’de kümelere göre test başarısı dağılımı gösterilmektedir.

Çizelge 3.5 Cleveland Kalp Hastalıkları veri kümesi için kümelere göre doğruluk oranları

No	Doğru sınıflandırılmış eleman sayısı	Test Kümesindeki Eleman Sayısı	Başarı %
1	28	30	93.33
2	29	31	93.55
3	26	30	86.67
4	26	30	86.67
5	28	31	90.32
6	29	30	96.67
7	29	31	93.55
8	28	30	93.33
9	27	30	90
10	29	30	96.67
Toplam:	279	303	92.08

Cleveland Kalp Hastalıkları veri kümesinde yapılan sınıflandırma sonuçlarının bu şekilde değerlendirilmesi sonucu 46.2% ile 90% arasında değiştiği rapor edilmektedir (internet: Benchmark datasets used for classification: Comparison of results, <http://www.fizyka.umk.pl/kmk/projects/datasets.html>; son erişim: Mart, 2008). Çizelge 3.6’da sistemin Cleveland Kalp Hastalıkları veri kümesi için başarısı diğer yöntemlerle karşılaştırmalı olarak görülmektedir.

Çizelge 3.6. Cleveland Kalp Hastalıkları veri kümesi için önerilen yöntem ve diğer algoritmaların sınıflandırma başarıları (10 kez çapraz doğrulama)
(internet: Benchmark datasets used for classification: Comparison of results, <http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	92.08	
IncNet	90	Norbert Jankowski
28-NN, stand, Euclid, 7 features	85.1±0.5	WD/KG
LDA	84.5	Ster & Dobnikar
Fisher discriminant analysis	84.2	Ster & Dobnikar
k=7, Euclid, std	84.2±6.6	WD, GhostMiner
16-NN, stand, Euclid	84±0.6	WD/KG
FSM, 82.4-84% on test only	84.0	Rafał Adamczak
k=1:10, Manhattan, std	83.8±5.3	WD, GhostMiner
Naive Bayes	82.5-83.4	Rafał; Ster, Dobnikar
SNB	83.1	Ster & Dobnikar
LVQ	82.9	Ster & Dobnikar
GTO DT (5xCV)	82.5	Bennet and Blue
kNN, k=19, Eculidean	82.1±0.8	Karol Grudziński
k=7, Manhattan, std	81.8±10.0	WD, GhostMiner
SVM (5xCV)	81.5	Bennet and Blue
kNN (k=1 raw data)	81.5	Ster & Dobnikar
MLP+BP (standarized)	81.3	Ster, Dobnikar, Rafał Adamczak
CART	80.8	Ster & Dobnikar
RBF (Tooldiag, standarized)	79.1	Rafał Adamczak
Gaussian EM, 60 units	78.6	Stensmo & Sejnowski
ASR	78.4	Ster & Dobnikar
C4.5 (5xCV)	77.8	Bennet and Blue
IB1c (WEKA)	77.6	Rafał Adamczak

QDA	75.4	Ster & Dobnikar
LFC	75.1	Ster & Dobnikar
ASI	74.4	Ster & Dobnikar
K* (WEKA)	74.2	Rafał Adamczak
OC1 DT (5xCV)	71.7	Bennet and Blue
1 R (WEKA)	71.0	Rafał Adamczak
T2 (WEKA)	69.0	Rafał Adamczak
FOIL (WEKA)	66.4	Rafał Adamczak
InductH (WEKA)	61.3	Rafał Adamczak
C4.5 rules	53.8±5.9	Zarndt
IB1-4 (WEKA)	46.2	Rafał Adamczak

Çizelge 3.4 ve Çizelge 3.6'dan görüldüğü gibi önerilen hibrit bulanık sinir ağı algoritması Cleveland Kalp Hastalıkları veri kümesinde en başarılı sınıflandırma yöntemidir.

3.2. Hepatit Veri Kümesinde Uygulama

Uygulama için kullanılan ikinci veri kümesi ise Hepatit veri kümesidir. Bu veri kümesi Bojan Cestnik tarafından oluşturulmuştur. Veri kümesini oluşturmaktaki amaç bu hastalığa sahip insanların yaşamaya devam edip edemeyeceğini araştırmaktır. Bu veri kümesi hepatit testlerinden 19'unun kullanılması ile oluşturulmuş 155 örnekten oluşur. Örneklerden 32'si ölmüş, 123'ü yaşamına devam etmiştir. Veri kümesindeki örneklerin 19 niteliği şu şekilde verilmiştir:

- 1- Yaş
- 2- Cinsiyeti

- 3- Steroid
- 4- Antiviral
- 5- Halsizlik
- 6- Kırıklık
- 7- İştahsızlık
- 8- Karaciğer büyümesi
- 9- Karaciğer sertleşmesi
- 10- Dalak palpablı
- 11- Deri üzerinde örümceğe benzer ben
- 12- Asit
- 13- Varis
- 14- Bilirubin
- 15- Alkalen fosfataz
- 16- SGOT
- 17- Albumin
- 18- Pro-time
- 19- Histoloji

Sonuçlar 0 ve 1 olarak kodlanmıştır. 0 kişinin yaşamına devam ettiği, 1 öldüğü anlamına gelmektedir. Çizelge 3.7’de niteliklerin aldığı değerler (değer aralıkları) görülmektedir.

Çizelge 3.7 Hepatit veri kümesi için niteliklerin değerleri ve aralıkları

Nitelik	Aralık
Yaş	7 -78
Cinsiyet	Erkek , Kadın
Steroid	Evet, Hayır
Antiviral	Evet, Hayır
Halsizlik	Evet, Hayır
Kırıklık	Evet, Hayır
İştahsızlık	Evet, Hayır
Karaciğer büyümesi	Evet, Hayır
Karaciğer sertleşmesi	Evet, Hayır
Dalak palpablı	Evet, Hayır
Deri üzerinde örümceğe benzer ben	Evet, Hayır
Asit	Evet, Hayır
Varis	Evet, Hayır
Bilirubin	0.3 - 8
Alkalen fosfataz	26 – 295
SGOT	14 – 648
Albumin	2.1 – 6.4
Pro-time	0 – 100
Histoloji	Evet , Hayır

Çizelge 3.8 Hepatit veri kümesindeki kesin verilerin kodlanması

Nitelik	Aralık
Cinsiyet	{Erkek} , {Kadın}
Steroid	{Hayır}, {Evet}
Antiviral	{Hayır}, {Evet}
Halsizlik	{Hayır}, {Evet}
Kırıklık	{Hayır}, {Evet}
İştahsızlık	{Hayır}, {Evet}
Karaciğer büyümesi	{Hayır}, {Evet}
Karaciğer sertleşmesi	{Hayır}, {Evet}
Dalak palpablı	{Hayır}, {Evet}
Deri üzerinde örümceğe benzer ben	{Hayır}, {Evet}
Asit	{Hayır}, {Evet}
Varis	{Hayır}, {Evet}
Histoloji	{Hayır}, {Evet}

Her kesin nitelik değeri Çizelge 3.8 kullanılarak ikili olarak kodlanmıştır. Evet'ler {0,1}, Hayırlar {1,0}, Erkek {1,0}, Kadın {0,1} olarak kodlanmıştır.

Çizelge 3.8'de görülen kodlama yöntemiyle YSA1 için 26 ikili giriş oluşturulmuştur. Yapılan denemeler sonucu, en başarılı hibrit ağ yapısındaki YSA1 kısmının bir gizli katmana sahip olduğu ve gizli katmandaki nöron sayısının dört olduğu gözlemlenmiştir.

Bulanık nitelikler için uzman doktorlara danışılarak üyelik fonksiyonları üretilmiştir. Bulanık nitelikler Çizelge 3.9'da görülen değerleri almaktadır.

Çizelge 3.9 Hepatit veri kümesindeki bulanıklaşacak verilerin sınır ağı girişi için kodlanması


Nitelik	Girişlerin Sayısı	Alt kümeler
Yaş	3	{Genç}, {Orta yaşlı}, {Yaşlı}
Bilirubin	3	{Düşük}, {Orta}, {Yüksek}
Alkalen fosfataz	2	{Normal}, {Yüksek}
SGOT	2	{Normal}, {Yüksek}
Albumin	3	{ Düşük }, {Orta}, {Yüksek}
Pro-time	3	{ Az }, { Yüksek }, {Çok Yüksek}

Yaş niteliği için tespit edilen üyelik fonksiyonları (3.16)-(3.18)'de görülmektedir.

$$Y_{genc}(x) = \begin{cases} 1 & , \quad x \leq 20 \\ 2 - \frac{x}{20} & , \quad 20 < x < 40 \\ 0 & , \quad x \geq 40 \end{cases} \quad (3.16)$$

$$Y_{orta}(x) = \begin{cases} 0 & , \quad x \leq 35, \quad x \geq 55 \\ \frac{x}{10} - 3,5 & , \quad 35 < x \leq 45 \\ 5,5 - \frac{x}{10} & , \quad 45 < x < 55 \end{cases} \quad (3.17)$$

$$Y_{yasl\acute{i}}(x) = \begin{cases} 0 & , \quad x \leq 50 \\ \frac{x}{10} - 5 & , \quad 50 < x < 60 \\ 1 & , \quad x \geq 60 \end{cases} \quad (3.18)$$




Şekil 3.7 Yaş niteliği için üyelik dereceleri

Bilirubin niteliği için tespit edilen üyelik fonksiyonları (3.19)-(3.21)'de görülmektedir.

$$B_{dusuk} = \begin{cases} 1 & , \quad x \leq 0.2 \\ 2-5x & , \quad 0.2 < x < 0.4 \\ 0 & , \quad x \geq 0.4 \end{cases} \quad (3.19)$$

$$B_{orta} = \begin{cases} 0 & , \quad x \leq 0.2, \quad x \geq 2 \\ 5x-1 & , \quad 0.2 < x \leq 0.4 \\ 1 & , \quad 0.4 < x \leq 1.8 \\ 10-5x & , \quad 1.8 < x \leq 2 \end{cases} \quad (3.20)$$

$$B_{yukse} = \begin{cases} 0 & , \quad x \leq 1.8 \\ 5x-9 & , \quad 1.8 < x < 2 \\ 1 & , \quad x \geq 2 \end{cases} \quad (3.21)$$




Şekil 3.8 Bilirubin niteliği için üyelik dereceleri

Alkalen fosfataz niteliği için tespit edilen üyelik fonksiyonları (3.22)-(3.23)'de görülmektedir.

$$AF_{normal} = \begin{cases} 1 & , \quad x \leq 80 \\ 5 - \frac{x}{20} & , \quad 80 < x < 100 \\ 0 & , \quad x \geq 100 \end{cases} \quad (3.22)$$

$$AF_{yukse} = \begin{cases} 0 & , \quad x \leq 80 \\ \frac{x}{20} - 4 & , \quad 80 < x < 100 \\ 1 & , \quad x \geq 100 \end{cases} \quad (3.23)$$




Şekil 3.9 Alkalen fosfataz niteliği için üyelik dereceleri

SGOT niteliği için tespit edilen üyelik fonksiyonları (3.24)-(3.25)'de görülmektedir.

$$SG_{normal} = \begin{cases} 1 & , \quad x \leq 30 \\ 4 - \frac{x}{10} & , \quad 30 < x < 40 \\ 0 & , \quad x \geq 40 \end{cases} \quad (3.24)$$

$$SG_{yüksek} = \begin{cases} 0 & , \quad x \leq 30 \\ \frac{x}{10} - 3 & , \quad 30 < x < 40 \\ 1 & , \quad x \geq 40 \end{cases} \quad (3.25)$$




Şekil 3.10 SGOT niteliği için üyelik dereceleri

Albumin niteliği için tespit edilen üyelik fonksiyonları (3.26)-(3.28)'de görülmektedir.

$$A_{dusuk} = \begin{cases} 1 & , \quad x \leq 3,5 \\ 8 - 2x & , \quad 3,5 < x < 4 \\ 1 & , \quad x \geq 4 \end{cases} \quad (3.26)$$

$$A_{normal} = \begin{cases} 0 & , \quad x \leq 3,5, \quad x \geq 5,7 \\ 2x-7 & , \quad 3,5 < x \leq 4 \\ 1 & , \quad 4 < x \leq 5,2 \\ 11,4-2x & , \quad 5,2 < x < 5,7 \end{cases} \quad (3.27)$$

$$A_{yüksek} = \begin{cases} 0 & , \quad x \leq 5 \\ \frac{10x-50}{7} & , \quad 5 < x < 5,7 \\ 1 & , \quad x \geq 5,7 \end{cases} \quad (3.28)$$



Şekil 3.11 Albumin niteliği için üyelik dereceleri

Pro-time niteliği için tespit edilen üyelik fonksiyonları (3.29)-(3.31)'de görülmektedir.

$$P_{normal} = \begin{cases} 1 & , \quad x \leq 10 \\ \frac{18-x}{8} & , \quad 10 < x < 18 \\ 0 & , \quad x \geq 18 \end{cases} \quad (3.29)$$


$$P_{yüksek} = \begin{cases} 0 & , \quad x \leq 15, \quad x \geq 45 \\ \frac{x}{15} - 1 & , \quad 15 < x \leq 30 \\ 3 - \frac{x}{15} & , \quad 30 < x < 45 \end{cases} \quad (3.30)$$

$$P_{çokyüksek} = \begin{cases} 0 & , \quad x \leq 20 \\ \frac{x-20}{30} & , \quad 20 < x < 50 \\ 1 & , \quad x \geq 50 \end{cases} \quad (3.31)$$

verilerin rastgele 103 adedi eğitim için seçilmiş, geri kalan 52 adedi ile de test yapılmıştır. Eğitim sonucunda test kümesinde bulunan 52 veriden 49'u doğru teşhis edilmiştir ki, bu da test verilerinin %94.2'sini oluşturmaktadır.

Oluşan hata grafiği Şekil 3.13'de görülmektedir.

Hepatitu veri kümesinde yapılan sınıflandırma çalışmalarının sonuçlarının bu şekilde değerlendirilmesi sonucu başarı oranlarının 82.1% ile 90.3% arasında değiştiği rapor edilmektedir (internet: Benchmark datasets used for classification: Comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008). Çizelge 3.10'da sistemin Hepatit veri kümesi için başarısı diğer yöntemlerle karşılaştırmalı olarak görülmektedir.



Şekil 3.13 Hepatit veri kümesi 103 eğitim + 52 test sonucu oluşan hata fonksiyonu

Çizelge 3.10 Hepatit veri kümesi için önerilen yöntem ve diğer algoritmaların sınıflandırma başarıları (“eğitim”+”test” yöntemi)
(internet: Benchmark datasets used for classification: comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	94,2	
21-NN, stand Manhattan	90.3	Karol Grudziński
FSM	90	Rafał Adamczak
14-NN,stand. Euclid	89.0	Karol Grudziński
LDA	86.4	Weiss & K
CART (decision tree)	82.7	Weiss & K
MLP+backprop	82.1	Weiss & K

Sistemin başarısını test etmek amacıyla kullanılan ikinci yöntem, 10 kez çapraz doğrulama tekniğidir. Bunun için veriler rasgele bir şekilde 10 gruba ayrılmıştır. Oluşan Eğitim-Test kümelerinin beş adedinde 140 eğitim, 15 test verisi, diğer beşinde ise 139 eğitim, 16 test verisi bulunmaktadır.

Sistemin 10 kez çalışması sonucunda %94.19 başarı elde edilmiştir. Çizelge 3.11’de kümelere göre test başarısı dağılımı gösterilmektedir.

Çizelge 3.11 Hepatit veri kümesi için kümelere göre doğruluk oranları

No	Doğru sınıflandırılmış eleman sayısı	Test Kümesindeki Eleman Sayısı	Başarı %
1	14	15	93.33
2	16	16	100
3	14	15	93.33
4	15	15	100
5	14	16	87.5
6	16	16	100
7	16	16	100
8	14	15	93.33
9	14	16	87.5
10	13	15	86.67
Toplam:	146	155	94.19

Hepatit veri kümesinde yapılan sınıflandırma çalışmalarının başarı oranlarının 77.4% ile 92.9% arasında değiştiği rapor edilmektedir (internet: Benchmark datasets used for classification: Comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008). Çizelge 3.12’de sistemin Hepatit veri kümesi için başarısı diğer yöntemlerle karşılaştırmalı olarak görülmektedir.

Çizelge 3.12 Hepatit veri kümesi için önerilen yöntem ve diğer algoritmaların sınıflandırma başarıları
(internet: Benchmark datasets used for classification: comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	94,19	
Weighted 9-NN	92.9	Karol Grudziński
18-NN, stand. Manhattan	90.2±0.7	Karol Grudziński
FSM with rotations	89.7±?	Rafał Adamczak
15-NN, stand. Euclidean	89.0±0.5	Karol Grudziński
VSS 4 neurons, 5 it	86.5±8.8	WD/MK, train 97.1
FSM without rotations	88.5	Rafał Adamczak
LDA, linear discriminant analysis	86.4	Stern & Dobnikar
Naive Bayes and Semi-NB	86.3	Stern & Dobnikar
IncNet	86.0	Norbert Jankowski
QDA, quadratic discriminant analysis	85.8	Stern & Dobnikar
1-NN	85.3±5.4	Stern & Dobnikar, std added by WD
VSS 2 neurons, 5 it	85.1±7.4	WD/MK, train 95.0
ASR	85.0	Stern & Dobnikar
Fisher discriminant analysis	84.5	Stern & Dobnikar
LVQ	83.2	Stern & Dobnikar
CART (decision tree)	82.7	Stern & Dobnikar
MLP with BP	82.1	Stern & Dobnikar
ASI	82.0	Stern & Dobnikar
LFC	81.9	Stern & Dobnikar
RBF (Tooldiag)	79.0	Rafał Adamczak
MLP+BP (Tooldiag)	77.4	Rafał Adamczak

Çizelge 3.10 ve Çizelge 3.12'den görüldüğü gibi önerilen hibrit bulanık sinir ağı algoritması Hepatit veri kümesinde en başarılı sınıflandırma yöntemidir.

3.3. Bölüm Değerlendirilmesi

Bu bölümde, bir önceki bölümde önerilen hibrit bulanık sinir ağı Cleveland Kalp Hastalıkları ve Hepatit Hastalığı veri kümelerine uygulanmakta ve başarısına bakılmaktadır. Burada verilerin %70'i ile eğitim, geri kalan %30'u ile test yapılmaktadır. Bu işlemin sonucu olarak Cleveland Kalp Hastalıkları veri kümesinde %92.3, Hepatit veri kümesinde %94.2 sınıflandırma başarısı elde edilmiştir. Daha sonra sistemin performansı 10-kez çapraz doğrulama kullanılarak test edilmiştir. Bunun için veri kümesi 10 parçaya bölünmüş, bunların dokuzuyla eğitim, geri kalan biriyle test yapılmıştır. Bu işlem dönüşümlü olarak 10 kez tekrar etmiştir. Elde edilen sonuçların aritmetik ortalaması hesaplanarak sistemin genel başarısı bulunmuştur. Bu işlemin sonucu olarak Cleveland Kalp Hastalıkları veri kümesinde %92.08, Hepatit veri kümesinde %94.19 sınıflandırma başarısı elde edilmiştir. Elde edilen oranlar literatürle karşılaştırıldığında önerilen hibrit bulanık sinir ağının sınıflandırma konusunda başarılı olduğu dolayısıyla daha doğru teşhis koyduğu görülmektedir.

4. SİNİR AĞLARINDAN KURAL ÇIKARTILMASI

Yapay Sinir Ağları bir çok alanda veri madenciliği problemlerini çözmek için başarıyla uygulanmıştır. Ancak bu tip ağların elde ettiği bilgiler genellikle insanlar için anlaşılabilir olmamaktadır. Bu durum veri madenciliği uygulamalarında önemli sorundur (Kaufman ve Rousseeuw, 1990). Bu nedenle, YSA'dan kural çıkarmak için bir çok yöntem geliştirilmiştir. Bu tezde bu amaçla sinir ağının oluşturduğu fonksiyonun optimizasyonu yapılarak kurallar oluşturulmaktadır. Optimizasyon yapmak için öncelikle optimizasyon yöntemleri araştırılmaktadır. Optimizasyonu yapılacak fonksiyonun bir çok optimum noktası olduğu için sezgisel algoritma kullanılması gerekliliği doğmaktadır. Denemeler sonucu bu problem için yapay bağışıklığın daha başarılı olduğu görülmektedir. Bu nedenle bir yapay bağışıklık algoritması olan Opt-aiNET kullanılması uygun görülmektedir.

Bu bölümde optimizasyon teorisi ve bu tezde optimizasyon için kullanılan yapay bağışıklık sistemleri hakkında kısa bilgi verilmiştir. Bu konularla ilgili detaylı bilgi almak için Sundaram, 1996, Akşit ve ark., 1996, de Castro ve Von Zuben, 1999 incelenebilir.

4.1. Optimizasyon Probleminin Matematiksel Temelleri

Optimizasyon, gerçel bir fonksiyonu maksimize veya minimize etme probleminin çözümünü, izin verilen bir küme dahilindeki gerçel veya tamsayı değerlerini sistematik bir şekilde kullanarak arama işlemidir (internet: Optimizasyon, <http://tr.wikipedia.org/wiki/Optimizasyon>, son erişim: 19.06.2007).

Optimizasyon probleminin üç bileşeni vardır:

- 1- Minimize veya maksimize etmek istediğimiz bir objektif fonksiyonu.
- 2- Objektif fonksiyonunun değişkenler kümesi.
- 3- Gereken değerleri bulup, diğerlerinin elenmesini sağlayacak sınırlar kümesi.

Aşağıda optimizasyon teorisinin matematiksel temelleri verilmektedir. Bölüm 4.3'te bu temeller kullanılarak bazı matematiksel çıkarımlar yapılacaktır. (Detaylı bilgi için Sundaram, 1996'ya bakabilirsiniz.)

Tanım 4.1. (açık küre).

$x \in R^n$ olsun. x merkezli r yarıçaplı $B(x, r)$ açık küresi aşağıdaki gibi tanımlanmaktadır:

$$B(x, r) = \{y \in R^n \mid d(x, y) < r\}.$$

Yani, $B(x, r)$, R^n 'de tanımlı olan ve x 'den uzaklıkları r 'den kesin küçük olan noktaların kümesidir.

Tanım 4.2. (kapalı küre).

$x \in R^n$ olsun. x merkezli r yarıçaplı $\bar{B}(x, r)$ kapalı küresi aşağıdaki gibi tanımlanmaktadır:

$$\bar{B}(x, r) = \{y \in R^n \mid d(x, y) \leq r\}.$$

Yani, $\bar{B}(x, r)$, R^n 'de tanımlı olan ve x 'den uzaklıkları r 'den küçük veya eşit olan noktaların kümesidir.

Tanım 4.3. (açık küme).

$S \subset R^n$ olsun. Eğer $\forall x \in S$ için $B(x, r) \subset S$ olacak şekilde $r > 0$ varsa, S 'ye açık küme denir.

Tanım 4.4. (kapalı küme).

$S \subset R^n$ olsun. S 'nin tümleyeni $S^c = \{x \in R^n \mid x \notin S\}$ açık küme ise S 'ye kapalı küme denir.

Tanım 4.5. (sınırlı küme).

$S \subset R^n$ olsun. Eğer $S \subset B(0, r)$ olacak şekilde $r > 0$ varsa, S 'ye sınırlı küme denir.

Tanım 4.6. (kompakt küme).

$S \subset R^n$ olsun. Eğer $x_k \in S$ olan $\forall \{x_k\}$ dizisinin, $x_{m(k)} \rightarrow x$ olacak şekilde $\{x_{m(k)}\}$ alt dizisi ve $x \in S$ noktası varsa, S 'ye kompakt küme denir.

Teorem 4.1. (Heine-Borel Teoremi)

$S \subset R^n$ kümesinin kompakt olması için gerek ve yeter şart S 'nin kapalı ve sınırlı olmasıdır.

Tanım 4.7. (dışbükey küme).

$S \subset R^n$ olsun. Eğer $\forall x, y \in S$ ve $0 < \lambda < 1$ için $\lambda x + (1 - \lambda)y \in S$ ise S 'ye dışbükey küme denir.

Optimizasyon problemi $f : R^n \rightarrow R$ fonksiyonunun verilen $D \subset R^n$ de maxsimize veya minimize edilmesidir. Burada f fonksiyonu objektif fonksiyonu, D sınırlama kümesi'dir. Bu problem aşağıdaki gibi ifade edilir:

$$\max\{f(x) \mid x \in D\} \quad (4.1)$$

ve

$$\min\{f(x) \mid x \in D\} \quad (4.2)$$

(4.1)'e maximizasyon problemi, (4.2)'ye minimizasyon problemi denir. (4.1) probleminin çözümü $a \in D$, $\forall y \in D$ için aşağıdaki eşitsizliği sağlamaktadır:

$$f(a) \geq f(y)$$

Bu problem için, f fonksiyonu a noktasında D kümesinde en büyük değere ulaşıyor denir. a noktasına ise F 'in D kümesindeki maksimize edicisi denir.

Benzer şekilde, (4.2) probleminin çözümü $b \in D$, $\forall y \in D$ için aşağıdaki eşitsizliği sağlamaktadır:

$$f(b) \leq f(y)$$

Bu problem için, f fonksiyonu b noktasında D kümesinde en küçük değere ulaşıyor denir. b noktasına ise F 'in D kümesindeki minimize edicisi denir.

Tanım 4.8.

$D \subset R^n$ ve $f : D \rightarrow R$ olsun.

1. Eğer $x^* \in D$ noktası için

$$f(x^*) \leq f(x), \quad \forall x \in D \cap B(x^*, \delta)$$

olacak şekilde $\delta > 0$ varsa, bu x^* noktasına lokal minimize edici denir.

2. Eğer $x^* \in D$ noktası için

$$f(x^*) \leq f(x), \quad \forall x \in D$$

ise, bu x^* noktasına global minimize edici denir.

Bu tanımdaki “ $\leq$ ” işaretini “ $<$ ” ile değiştirirsek, x^* noktasına

1. kesin lokal minimize edici
2. kesin global minimize edici

denir.

Teorem 4.2. (Weierstrass Teoremi)

$D \subset R^n$ kompakt küme ve $f : D \rightarrow R$ D 'de tanımlı sürekli fonksiyon olsun. f fonksiyonunun D 'de maksimumu ve minimumu vardır. Yani, $\forall x \in D$ için

$$f(z_1) \geq f(x) \geq f(z_2)$$

olacak şekilde $z_1, z_2 \in D$ vardır.

Lemma 4.1.

Eğer $f : D \rightarrow R$ fonksiyonu D 'de sürekli ve D kümesi kompaktsa, o zaman $f(D)$ kümesi de kompaktır.

Tanım 4.9.

$D \subset R^n$ dışbükey küme ve $f : D \rightarrow R$ bir fonksiyon olsun. f 'nin subgrafı ve epigrafı aşağıdaki gibi tanımlanmaktadır.

$$sub(f) = \{(x, y) \in D \times R \mid f(x) \geq y\}$$

$$epi(f) = \{(x, y) \in D \times R \mid f(x) \leq y\}$$

Tanım 4.10.

$D \subset R^n$ dışbükey bir küme ve $f : D \rightarrow R$ bir fonksiyon olsun. $sub(f)$ dışbükey kümeysse, f fonksiyonuna D 'de içbükey fonksiyon, $epi(f)$ dışbükeyse, f fonksiyonuna D 'de dışbükey fonksiyon denir.

Teorem 4.3. (Sundaram, 1996)

$f : D \rightarrow R$ fonksiyonunun D dışbükey kümesinde içbükey olması için gerek ve yeter şart $\forall x, y \in D$ ve $\lambda \in (0,1)$ için aşağıdaki koşulun sağlanmasıdır.

$$f[\lambda x + (1 - \lambda)y] \geq \lambda f(x) + (1 - \lambda)f(y)$$

$f : D \rightarrow R$ fonksiyonunun D 'de dışbükey olması için gerek ve yeter şart $\forall x, y \in D$ ve $\lambda \in (0,1)$ için aşağıdaki koşulun sağlanmasıdır.

$$f[\lambda x + (1 - \lambda)y] \leq \lambda f(x) + (1 - \lambda)f(y)$$

Tanım 4.11.

a) $f : D \rightarrow R$ D dışbükey kümesinde tanımlı içbükey fonksiyon olsun.

Eğer $\forall x, y \in D | x \neq y$ ve $\lambda \in (0,1)$ için

$$f[\lambda x + (1 - \lambda)y] > \lambda f(x) + (1 - \lambda)f(y)$$

ise f fonksiyonuna kesin içbükey fonksiyon denir.

b) $f : D \rightarrow R$ D dışbükey kümesinde tanımlı dışbükey fonksiyon olsun.

Eğer $\forall x, y \in D | x \neq y$ ve $\lambda \in (0,1)$ için

$$f[\lambda x + (1 - \lambda)y] < \lambda f(x) + (1 - \lambda)f(y)$$

ise f fonksiyonuna kesin dışbükey fonksiyon denir.

Teorem 4.4. (Sundaram, 1996)

$f : D \rightarrow R$ fonksiyonunun D dışbükey kümesinde içbükey olması için gerek ve yeter şart $(-f)$ fonksiyonunun dışbükey olmasıdır. f fonksiyonunun kesin içbükey olması için gerek ve yeter şart $(-f)$ fonksiyonunun kesin dışbükey olmasıdır.

Teorem 4.5. (Sundaram, 1996)

$f : D \rightarrow R$ içbükey bir fonksiyon olsun. D dışbükey kümesi açıksa, f fonksiyonu D 'de süreklidir. Eğer D açık değilse, f fonksiyonu D 'nin içinde süreklidir.

Tanım 4.12.

$f : D \rightarrow R$ ve $D \subset R^n$ olsun. Eğer D dışbükey ve f fonksiyonu içbükey ise maksimizasyon problemine dışbükey maksimizasyon problemi denir. Eğer D dışbükey ve f fonksiyonu dışbükey ise minimizasyon problemine dışbükey minimizasyon problemi denir. Bir optimizasyon problemi ya dışbükey maksimizasyon ya da dışbükey minimizasyon problemi ise dışbükey optimizasyon problemi denir.

Tanım 4.13.

$f(x)$ fonksiyonunun, x ile ilgili herhangi bir sınırlamanın olmadığı optimizasyonu problemine kısıtlamasız (sınırlamasız) optimizasyon, x ile ilgili sınırlamaların bulunduğu optimizasyon problemine ise kısıtlamalı (sınırlamalı) optimizasyon denir.

Tanım 4.14.

$f(x)$ fonksiyonu ve kısıtlama fonksiyonları doğrusal ise bu optimizasyon problemine lineer programlama problemi, bu fonksiyonlardan her hangi biri lineer değilse, lineer olmayan optimizasyon problemi denir.

Tanım 4.15.

Değişkenleri negatif olmayan tamsayı değerler alan bir lineer programlama problemine tamsayı programlama problemi, değilse tamsayı olmayan programlama problemi denir.

Tanım 4.16.

Ayrık parametrelerin optimal olarak düzenlenmesi, gruplanması, sıraya konulması veya seçilmesi problemine ayrık optimizasyon problemi denir. Değişkenlerin alacağı değerler gerçel değerler ise bu tür problemlere sürekli optimizasyon problemi denir.

Günümüzde klasik optimizasyon yöntemlerinin kullanımı zorlaşmıştır. Genellikle amaç fonksiyonunun birkaç optimum noktası bulunmaktadır. Bu da sezgisel veya evrimsel algoritmalarından birinin kullanımını zorunlu hale getirmektedir (Joshi ve Moudgalya, 2004).

Sezgisel algoritmalar, herhangi bir amacı gerçekleştirmek veya hedefe varmak için çeşitli alternatif hareketlerden etkili olanlara karar vermek amacı ile tanımlanan kriterler veya bilgisayar metotlarıdır. Bu algoritmalar, çözüm uzayında optimum çözüme yakınsaması ispat edilemeyen algoritmalar olarak da adlandırılır. Bu tür algoritmalar yakınsama özelliğine sahiptir, ama kesin çözümü garanti edemezler ve sadece kesin çözüm yakınındaki bir çözümü garanti ederler (Karaboğa, 2004).

Evrimsel hesaplama bilgisayar yazılım algoritmalarında evrimi taklit ederek çalışan evrimsel optimizasyon yöntemlerini içermektedir. Bütün evrimsel algoritmalarda bireylerden oluşan bir toplum, çevresel etkilerle doğal seçim ve bu şekilde toplumda uygun olanların büyümesi kavramları yer alır.

Evrimsel algoritmalar global, paralel araştırma ve optimizasyon yöntemleri olup, doğal seçim ilkeleri üzerine kurulmaktadır. Genel olarak yeni çözümler üretmek için seçim ve rasgele varyasyon kullanan her “popülasyon temelli tekrarlayıcı yaklaşım” evrimsel algoritma olarak kabul edilmektedir. Evrimsel teknikler arama yada optimizasyon teknikleri olarak görülebilirler. Her soyut görev bir problem çözme olarak düşünülerek çözülebilir, yada potansiyel çözümler

uzayında araştırma olarak algılanabilir. En iyi çözümü aradığımız için bu da optimizasyon süreci olarak da düşünülebilir (Baykal ve Beyan, 2004a).

Bir problemi çözmede kullanılacak herhangi bir evrimsel algoritma aşağıdaki beş elemana ihtiyaç duymaktadır (Karaboğa, 2004):

- Problem için çözümlerin genetik temsili,
- Çözümlerin başlangıç popülasyonunu oluşturacak bir yöntem,
- Çözümleri uygunluk açısından değerlendirmeye tabi tutacak değerlendirme fonksiyonu yani çevre,
- Genetik kompozisyonu değiştirecek operatörler,
- Kontrol parametrelerinin değerleri (popülasyon büyüklüğü, operatörleri uygulama ihtimalleri vs.).

Evrimsel algoritma tek bir bireyle (çözümle) değil, bireylerin popülasyonu $P(t)$ ile ilgilenir. Her birey mevcut problem için muhtemel bir çözümü temsil eder ve bir veri yapısı S olarak tanımlanır. Her birey uygunluk ölçüt değerini belirlemek amacıyla değerlendirilir ve daha uygun bireyleri seçmek suretiyle yeni popülasyon $P(t+1)$ oluşturulur (seçme adımı). Yeni popülasyonun bazı bireyleri yeni çözümler oluşturmak için bazı operatörler vasıtasıyla transformasyona tabi tutulurlar (değiştirme adımı) (Karaboğa, 2004).

4.2. Yapay Bağışıklık Sistemleri

Son birkaç on yıl içerisinde bilgisayar bilimiyle uğraşanlar, sıklıkla, doğada hali hazırda işler durumda olan yapıları ele almaya ve soyut olarak gerçekleştirmeye başlamışlardır. Bunun arkasında yatan en önemli sebep, bu yapılara ait mekanizmaların yüksek düzeyde optimize sistemler olmasıdır. Bu yüksek

optimizasyon, doğanın milyonlarca yıllık evriminin sonucunda oluşmuş kararlı hallerin bir sonucudur.

Bilgisayar biliminde veya mühendislikte doğadan örnekler kullanılsa da, bunlar her zaman doğanın o sistemi kullandığı biçimde gerçekleşmeyebilir. Bu alanlarda çalışan bilimciler doğadaki biyolojik sistemlerin modellenmesinden çok, geleneksel yöntemlerin baş edemediği problemleri çözmekte kullanmak üzere, bu yapıları modellemeye çalışırlar.

Biyolojik sistemlerden esinlenerek yapılan modellemeler, aslının kabaca sadeleştirilmiş hali sayılabilecek bir matematiksel modelidir. Buna bir uçak yapmak için kuştan esinlenmeyi veya kurşun geçirmez yelek için örümcek ağlarından esinlenmeyi örnek gösterebiliriz.

İnsan bağışıklık sistemi virüs, bakteri gibi neredeyse sınırsız sayıda olan yabancı saldırganlara karşı doğal, hızlı ve etkili cevap verme yeteneğine sahip karmaşık bir ağ yapısı olarak tanımlanabilir. Bağışıklık sistemi örüntü tanıma, öğrenme, hafıza edinme, farklılıkların genelleştirilmesi, gürültü toleransı, genelleme ve optimizasyon gibi pek çok işlemi yerine getirme kabiliyetine sahip hücrelerden meydana gelir. Bağışıklık sistemini daha iyi anlamak ve mühendislik problemlerinin çözümünde kullanabilmek için bu biyolojik prensiplere dayanan yeni hesaplama teknikleri geliştirilmektedir. Bu amaçla insan bağışıklık sisteminden esinlenerek yapay bağışıklık sistemleri tanımlanmıştır. Çalışmada yapay bağışıklık sistemleri kullanıldığı için kısaca bu konuya göz atalım.

4.2.1. Bağışıklık sistemi


İnsan bağışıklık sistemi, dışarıdan gelebilecek saldırılara karşı vücudu koruma yeteneğine sahip kuvvetli bir savunma mekanizmasıdır. Bu mekanizmanın esas öğeleri beyaz kan hücreleri yani akyuvarlardır. Bağışıklık sistemi doğal ve edinilmiş olmak üzere ikiye ayrılır. Şekil 4.1’de görüldüğü gibi doğal bağışıklık

sisteminin elemanları granükloitler ve makrofajlar iken adaptif bağışıklık sisteminin elemanları lenfositlerdir.

Bağışıklık bilimi genel anlamda kendi kalıtsal yapısına yabancılık özelliği taşıyan özel maddeleri ayırt edebilme yeteneğindeki canlıların, bu özel maddelere karşı gösterdiği reaksiyonların tümünü inceleyen bir bilim dalıdır.

En basit yapıları canlılarda bile kendinden olanı tanıma, yabancıyı ayırt edebilme özelliği mevcuttur. Evrimsel açıdan en gelişmiş canlı olan insan kendi yapısına yabancı olan maddeleri tanıyabilme ve onlarla baş edebilme özelliklerine sahiptir. Bu sayede mikroplar başta olmak üzere yabancı ve zararlı olabilecek maddelere karşı kendisini savunur. Genelde antijen olarak tanımladığımız bu maddelerin organizmaya girmesi ile başlayan ve birbiri ile ilişkili birçok biyolojik reaksiyonun meydana geldiği bağışık yanıt olayında, birçok sistem, organ ve hücre görev alır. Bağışıklık olaylarında rolü olan organ ve hücrelere bağışıklık sistemi adı verilir.

Canlıların kendi kalıtsal yapısına yabancı olan maddelere (antijenlere) karşı gösterdiği reaksiyonlara bağışık yanıt adı verilir.



Şekil 4.1 Bağışıklık Sisteminin Sınıflandırılması ve Temel elemanları (de Castro, ve Timmis, 2002)


Bağıışıklık bilimi ile ilgili ilk bilgilerimiz çok eskilere dayanmaktadır. Eski çağlardan beri kişilerin farklı dirençte oldukları fark edilerek, salgınlarda bazı kişilerin ölmesine karşın, bazılarının hiç hastalanmadığı veya hastalığı çok hafif geçirdiğı, kızamık, çiçek gibi hastalıkların ikinci kez geçirilmediğı (ömür boyu korunma) bu konudaki ilk gözlemler olmaktadır.

Bağıışıklık bilimi tarihi ile ilgili olayların başında Türklerin de yer aldığını görölmektedir. 1721 yılında İstanbul'da İngiliz Büyükelçisi'nin eşi Leydi Montagu, İngiltere'ye yazdığı mektuplarda, Türkiye'de hafif çiçekli insandan sağlıklı insana aktarılarak uygulanan çiçek aşısından söz etmektedir. Ayrıca İstanbul'da çalışan İtalyan hekim E. Timoni de 1713'te bir toplantıda Türkiye'de 40 yıldan beri bu aşının uygulandığını belirtmektedir.

Bundan sonraki olay yine çiçek aşısı ile ilgilidir. İnek sağan kadınların ellerinde çıkan inek çiçeğı yaraları sayesinde asıl çiçek hastalığından korunduklarını fark eden İngiliz hekim Edward Jenner, 1798'de bu olaydan yararlanarak çiçek aşısı uygulamasını başlatmıştır. İlk kez aşılama terimini kullanmıştır. Daha sonra yüzyıllık bir sessiz dönem geçmiş ve 1880'li yıllarda Fransız hekim Louis Pasteur hayvanlar için şarbon ve kolera, insan ve hayvanlar için ise kuduz aşısını geliştirerek bu konuda önemli hizmetler vermiştir. Bunu izleyen yıllarda da pek çok enfeksiyon hastalığı için başarılı aşı çalışmaları yapılmıştır (Akşit ve ark., 1996).

4.2.1.1. İnsan bağıışıklık sisteminin yapısı

Bağıışıklık sisteminin düzenleme ve koruma mekanizmalarının çeşitli seviyelerde yer aldığı çok katmanlı bir mimarisi olduğu söylenebilir. Bu katmanlar Şekil 4.2'de gösterilmiştir. Sırası ile bu katmanların açıklamaları aşağıdaki gibidir :



Şekil 4.2 Bağışıklık Sisteminin Çok Katmanlı Mimarisi (de Castro, ve Timmis, 2002)


- Fiziksel Engeller: Derimiz zararlı olsun yada olmasın yabancı maddelere karşı vücudumuzu korumak için kalkan gibi çalışır. Solunum sistemimiz de dış yüzey ile temasta olan organların mukoza kaplı kısımları sayesinde dışardan gelecek muhtemel tehlikelere karşı vücut savunmasına yardımcı olur.
- Biyokimyasal Engeller: Vücudun salgıladığı tükürük, ter, göz yaşı gibi sıvılar yıkıcı enzimler içerirler. Mide asitleri ise yeme ve içme ile vücuda giren mikroorganizmaları öldürürler. Vücudun sıcaklığı ve pH değeri bazı saldırganlar için elverişsiz hayat şartları sunar.
- Doğal ve edinilmiş bağışıklık sistemi: Bağışıklık sistemini oluşturan iki önemli kavramdır. Doğal bağışıklık sistemi her insanın doğduğunda sahip olduğu tanımlama ve savunma bilgisidir. Bu bilgiler uzun bir evrimleşmenin sonucudurlar ve kalıtsal olarak yeni doğana aktarılırlar. Bu sayede bağışıklık sistemimiz ilk karşılaşmada bile pek çok patojeni yok edebilecek güçtedir. Doğal bağışıklık sisteminin önemli parçalarından biri, özel bir protein sınıfı

olan “tamamlayıcı sistem”dir. Tamamlayıcı sisteme ait moleküller, antikor moleküllerinin (patojen türü tanımlama ve işaretlemeye kullanılırlar) görevlerine yardımcı olurlar. Doğal bağışıklık sistemi, *B*-lenfositlerin olgunlaştığı lenf düğümü ve dalakta bulunan özel bölgeler olan jermal merkezlerde kodlanan bir grup örüntü tanıma almaçı üzerine kuruludur. Bu almaçlar, mikrobik patojenlerin, üzerlerinde bulundurdıkları özel moleküler örüntülerin tanımlanmasını sağlarlar. Bu örüntüler sadece patojenlere özeldir ve asla taşıyıcı beden dahilinde üretilmezler. Bu patojenlerin örüntü tanımlayıcı almaçlarca belirlenmesi bir dizi zincirleme kimyasal tepkimeye sebep olur. Bu tepkimeler patojenin varlığının tespit edildiğine dair sinyalleri taşır. Bağışıklık sisteminin tanımlamaya ait parçalarının kesinlikle bedendeki diğer hücrelerden ve moleküllerden ayrı bir yapıda olması gerekir. Aksi takdirde bedenin kendine ait hücreleriyle, patojenleri birbirinden ayırt edemez. Bu yapının sonucu olarak, doğal bağışıklık, kendine has olan ile olmayana ayırt edebilir. Başka bir deyişle savunduğu bedene ait olanla olmayana ayırt edebilir. Doğuştan bağışıklığın en önemli işlevlerinden biri de yardımcı-uyarı işaretleri üretmesidir. Bu işaretler, edinilmiş bağışıklık sistemine ait *T*-lenfositlerin etkinleşmesinde önemli rol oynar. Edinilmiş bağışıklık, beden dahilinde, ikizlemeyle özel olarak iki tür hücre üzerine dağıtılmış antijen almaçlarını kullanırlar. Söz edilen hücreler, *B*-lenfosit ve *T*-lenfosit hücreleridir. Bu hücreler üzerinde bulunan antijen almaçları rastgele süreçlerle üretilirler; ve bunun sonucu olarak, “edinilmiş bağışıklık” tepkisinin tasarımı, seçimsel ikizleme yoluyla çoğaltılmış, küçük farklılıklarla kendilerine özgü özellikler gösteren almaçlara sahip lenfositlere dayanır. Bu bağışıklık mekanizması sayesinde beden daha önce hiç karşılaşmamış olduğu patojenlere karşı da kendini savunabilme yeteneğini kazanır.

4.2.1.2. Bağışıklık hücreleri

Bağışıklık sistemi, kemik iliğinde üretilen ve çoğunlukla orada olgunlaşan, çok çeşitli hücrelerin bileşiminden oluşur. Kemik iliğinden yola çıkıp, kan dolaşımına, lenflere ve dokulara dağılırlar. Bir kısmı genel savunma amaçlıyken, diğer kısmı çok özel bir patojenle savaşmak üzere özelleşmektedir. Etkin bir savunma için bu hücrelerin sürekli birlikte çalışmaları gerekmektedir. Şekil 4.3’de, bağışıklık sistemini oluşturan hücreler ve salgılar yapısal olarak gruplanmaktadır.

Organizmaya girdiğinde, kendisine karşı bir bağışık yanıt oluşmasına yol açan ve bu cevap sonucunda oluşan ürün ile özgül olarak birleşebilen maddelere antijen denir. Antijenler "Ag" şeklinde gösterilirler. İmmünojen sözcüğü de antijen ile eş anlamlı olarak kullanılır. Oluşan ürüne ise antikor denir.



Şekil 4.3 Antikor'un Yapısı (de Castro, ve Timmis, 2002)

Bağıışıklık sisteminin temel hücresi lenfositlerdir. Lenfositlerde kalıtsal olarak bağıışık yanıt ile ilgili ürünleri sentezleme yeteneğı vardır. Nasıl çeşitli hormon ve enzimleri yapan ve salgılayan özel hücreler varsa, lenfositler de antijenle uyarıldıklarında immünglobülin (antikor) ve diğere bağıışık yanıt maddelerini sentezlerler. Immünglobülinler kısaltma olarak "Ig" şeklinde gösterilirler.

Lenfositler bağıışıklık sisteminin çok önemli hücreleridir. Kemik iliğindeki kök hücrelerde gelişirler ve merkezi lenfoid organlarda (Timus veya kemik iliğı) olgunlaşırlar. Kan yoluyla periferik lenfoid doku ve organlara giderek özel bölgelerine yerleşirler. Erişkin bir insanda yaklaşık 10^{12} (~ 1 trilyon) lenfosit bulunur ve her gün 10^9 (~ 1 milyar) lenfosit yapılarak kana verilir. Kandaki lökositlerin %20-30'unu lenfositler oluşturur. Lenfositler 8-12 mikron çapında, iri çekirdekli, dar sitoplazmalı hücrelerdir.

Görünümleri birbirine çok benzeyen ve ışık mikroskopunda ayırt edilemeyen farklı iki lenfosit tipi vardır. *B* ve *T* lenfositleri olarak tanımlanan bu hücrelerin olgunlaşmaları, işlevleri ve antijen yapıları birbirinden farklıdır. Ancak aralarında yakın bir işbirliğı bulunmaktadır.

B-lenfositler antikora dayalı (hüморal) bağıışıklıktan sorumlu hücrelerdir. Kandaki lenfositlerin %25'i, dalaktakilerin %50'si *B*-lenfosittir. *B*-lenfositler sentezledikleri immünglobulin moleküllerini hücre yüzeylerinde zarda taşırlar.

Bir *B*-lenfosit sadece tek bir çeşit antijene bağlanabilen yüzey immünglobulin reseptör taşır. Bu nedenle bağıışıklık sisteminde, zaman içinde karşılaşma ihtimali olan on binlerce çeşit antijene karşı özgül reseptör taşıyan on binlerce *B*-lenfosit çeşidi hazır durumda bulunmaktadır.

Organizmaya antijen girdiğinde, yüzeyinde bu antijene özgül reseptör taşıyan *B*-lenfositleri bulur ve uyarır. Uyarılan *B*-lenfositler başkalaşıma uğrar ve plazma hücresine dönüşürler. Plazma hücresi de uyaran antijene özgül olan çok miktarda antikor (immünglobulin) sentezler. Plazma hücresinin çoğalma yeteneğı yoktur ve ömrü kısadır (~ 2-3 gün). Ancak bir dakikada yaklaşık 20 bin antikor molekölü sentezleyebildiğı gösterilmiştir.

Uyarılan *B*-lenfositlerinden bir kısmı ise bellek hücresi haline gelir. Bellek *B*-lenfositleri uzun ömürlüdür (bazen bir ömür boyu) ve aynı antijenle tekrar karşılaştıklarında hızla çoğalarak daha hızlı ve güçlü antikor yanıtı oluştururlar.

T-lenfositler hücresel tipte bağışık yanıttan sorumludur. Kemik iliğinde yapılan *T*-öncü hücreler timusta olgun *T*-lenfosit haline gelirler. Bu olgunlaşma sırasında *T*-lenfosit yüzeyinde pek çok reseptör yerleşir. *T*-hücre yüzeyinde yüzey immünglobulin bulunmaz. Bunun yerine antijenleri özgül olarak tanıyan "*T*-hücre reseptörü = TCR" bulunur. Bir *T*-lenfosit sadece tek bir çeşit antijen için TCR taşır ve *B*-lenfositlerinde olduğu gibi bağışıklık sisteminde zaman içinde karşılaşma ihtimali olan on binlerce çeşit antijene yanıt verebilecek on binlerce çeşit *T*-lenfosit bulunur.

Organizmaya antijen girdiğinde yüzeyinde bu antijene özgül reseptör taşıyan *T*-lenfositleri bulur ve uyarır. Uyarılan *T*-lenfositler başkalaşıma uğrar ve sonuçta o antijene duyarlı *T*-lenfositler oluşur.

T-lenfositler bağışıklık sisteminin en önemli hücreleridir ve doğrudan antikora bağımlı olmayan ve hücrelerin yönettiği ve katıldığı özgül bağışıklığı oluştururlar. Bağışık yanıttaki rolleri açısından *T*-hücre topluluğunun homojen (tek tip) olmadığı ve yapı ve işlev özelliği farklı olan alt grupların bulunduğu bilinmektedir.

T lenfositleri uzun ömürlüdür. Bellek *T* lenfositleri ise antijeni tanımış olan çok uzun ömürlü ve antijenle tekrar karşılaştığında çok hızlı ve güçlü bağışık yanıt oluşturan hücrelerdir.

Antikorların nasıl sentezlendiği konusunda bugüne kadar ileri sürülen hipotezler (varsayımlar) şunlardır:

Yan Zincirler Teorisi: 1897'de P.Ehrlich tarafından ileri sürülmüştür. Ancak geçerliliği kalmamış olup, sadece tarihi değeri vardır. Bu teoriye göre hücrelerde besin maddelerini yakalayabilmek için her besin maddesine uyan almaçlar (reseptörler) vardır. Antijenler, hücrelerdeki bu reseptörlere rastlantı olarak benzer yapıda ise onlarla birleşirler. Ancak bu birleşme reseptörün görevini bozar. Hücrenin beslenmesi bozulur ve hücre yaşamını sürdürebilmek için çok sayıda reseptör

yapmaya başlar, bunların fazlası dolaşıma geçer. Bunlara da antikor molekülleri denir.

Kalıp Teorisi (Direktif Teori): 1930'da F. Haurowitz tarafından ileri sürülmüştür. Bu teoriye göre, organizmaya giren antijenler Ig sentezlemekte olan hücrelere göç ederler ve Ig molekülleri antijeni bir kalıp gibi kullanarak ona uyacak şekilde aminoasid dizilişlerini şekillendirirler. Antijene uygun Ig sentezinin sürekli olması için de antijenin kısımları hücrede kalır ve böylece özgül antikorlar sentezlenmiş olur. Ancak son yıllarda yapılan çok duyarlı deneylere karşın Ig sentezleyen hücrelerde antijene rastlanmamıştır. Ayrıca immünglobülinler protein yapısında olduklarına göre bir kez sentezlendikten sonra yapılarının değişmesinin mümkün olmadığı bugün bilinmektedir. Bu nedenlerle teori desteğini kaybetmiştir.

Klonal Teori (Selektif Teori, Doğal Klon Seçimi): 1955'te Jerne, 1957'de Burnet tarafından ileri sürülmüştür. Günümüzde de destek görmektedir. Bu teoriye göre bağışık yanıt verme yeteneğindeki hücrelerden biri veya bir grubu, tek bir antijen veya benzer yapıdaki bir grup antijen determinantı ile birleşebilme ve cevap verebilme yeteneğindedir. Böylece canlılarda, her biri bir antijene yanıt verebilecek yetenekte, birbirinden farklı, çok sayıda lenfosit bulunduğu kabul edilmektedir. Organizmaya giren antijen kendisine uyan hücreyi (*B*-lenfosit) bulur, bağlanır ve onu uyarır. Sadece onu seçmiş olur. Uyarım sonucu lenfositler hızla çoğalmaya başlar. Böylece belli bir antijene karşı özgül antikor sentezleyebilen bir hücre kolonisi (klonu) meydana gelmiş olur.

4.2.1.3. Bağışıklık sisteminin vücudu koruma süreci


Bağışıklık sistemi vücudu dışardan gelen saldırılara karşı koruyan hücre ve moleküllerin karışık bir kümesinden oluşur. Vücudumuz bütün bağışıklık tepkilerinin nihai hedefi olan antijenin (Ag) tehdidine karşı edinilmiş bağışıklık sistemi

tarafından korunmaktadır. Antijenik tehdide karşı organizmada üç çeşit bağışık yanıt oluşabilir. Bunlar;

- Hümorale (=Sıvısal) bağışık yanıt
- Hücresele bağışık yanıt
- Bağışık yanıtsızlık (=İmmünolojik tolerans)

Bağışık yanıt sonuçları Şekil 4.4'te görölmektedir.

Hümorale bağışık yanıttan *B* lenfositler sorumludur. Hümorale bağışık yanıt sonucu oluşan özgül antikorlar kan ve doku sıvılarında vücut savunmasında rol alırlar. Antikorlar, kan serumu ile kişiden kişiye aktarılabılırler (Akşit ve ark., 1996).




Şekil 4.4 Bağışık Yanıt Sonuçları (Akşit ve ark., 1996)

Hücresel bağışık yanıtın *T*-lenfositler sorumludur. Ancak organizmada, yabancı antijenlerin ortadan kaldırılması veya zararsız hale getirilmesi için *T*-lenfositler yanında fagositik hücreler (makrofaj ve granülositler), doğal öldürücü hücreler (NK hücreleri) ve diğer bazı hücrelerin işbirliği, hücresel bağışık yanıt içinde değerlendirilir. Ayrıca antikorlar da zaman zaman hücresel bağışıklığa katkıda bulunurlar. (Örn. opsonizasyon, antikora bağımlı hücresel sitotoksikite gibi) (Akşit ve ark., 1996).

İmmünolojik olgunluğa erişmiş canlıların normalde bağışık yanıt vermek durumunda oldukları, yabancı, belli bir Ag'e karşı bağışık yanıt oluşturmamalarına bağışık yanıtızsızlık veya immünolojik hoşgörü (tolerans) denir (Akşit ve ark., 1996).

Şekil 4.5'de bu savunma mekanizmasının basitleştirilmiş gösterimi bulunmaktadır. Şekilde görülen bu adımların kısaca açıklaması aşağıda verildiği gibidir.



Şekil 4.5 Bağışıklık Sisteminin basit aktivasyon mekanizması (de Castro, ve Timmis, 2002)

Makrofajlar gibi antijen sunma yeteneğine sahip APC hücrelerinin yiyebilecekleri ve sindirebilecekleri antijenleri bulmak için vücutta dolaştığını ve bulduklarında ise onları antijenik peptitlerine ayırarak parçaladıklarını göstermektedir. (I) Bu peptitler MHC (major histocompatibility complex) moleküllerine bağlanır, APC hücre yüzeyi ile birleşerek MHC/Peptit kombinasyonunu oluştururlar. (II) *T*-hücreleri, farklı bir MHC/Peptit kombinasyonlarını tanımak için her biri aktif olan reseptör moleküllerine sahiptirler. (III) *T*-hücresi MHC/peptit kombinasyonu tanıdıktan sonra aktive olur ve parçalanarak lenfokinler ve ya kimyasal sinyaller salgılar. Bunlar diğer bağışıklık sistemi elemanlarını uyarır ve aktivasyona katılmasını sağlar. (IV) *T*-hücrelerinin tersine *B*-lenfositleri MHC moleküllerinin yardımı olmaksızın serbest durumdaki antijenleri tanıma yeteneğine sahip reseptörlere sahiptir. (V) *B*-hücrelerinin reseptörleri tarafından uyarı sinyali alındığında *B*-hücreleri plazma hücrelerine dönüşerek çok sayıda antikor molekülü salgırlar. (VI) Serbest kalan bu antikorlar patojenleri etkisiz hale getirmede kullanılır. (VII) Daha sonra bunlar enzimler veya temizleme hücreleri kullanılarak yok edilirler. Aktive olan bu *B* ve *T*-hücrelerinin bir kısmı değişerek hafıza hücrelerini oluştururlar. Bu hücreler organizma içinde dolaşmaya devam edecek ve gelecekte olabilecek aynı veya benzer antijene daha iyi bir bağışıklık cevabı üretmeyi garantileyeceklerdir. *B*-lenfositlerde antikor üretimi için kullanılan genler sürekli mutasyona ve düzenlemeye uğradığından, tekrar eden saldırılar karşısında antikor cevabı eskisine göre daha etkin ve net bir hal almaya başlar. Bu olaya duyarlılık olgunlaşması denir (de Castro ve Timmis 2002).

4.2.2. Yapay bağışıklık sistemleri

Son yıllarda biyolojiden esinlenerek geliştirilmiş sistemler hakkında yapılan çalışmalarda büyük bir miktarda artış gözlemlenmiştir. Bunların arasında yapay sinir ağları (YSA), evrimsel hesaplama, DNA hesaplama ve yapay bağışıklık sistemleri (YBS) sayılabilir. YBS, bağışıklık fonksiyonları, prensipleri ve modelleri

gözlemlenerek, teorik bağışıklıktan esinlenilerek geliştirilen adaptif sistemlerdir (de Castro ve Timmis 2002).


Bağışıklık sistemi uygulamalarının başlıca kullanım alanları örüntü tanıma, hata ve anormallik tespiti, veri analizleri (veri madenciliği, sınıflandırma vb.), etmen tabanlı sistemler, makine öğrenmesi, arama ve optimizasyon problemleri ve güvenlik ve bilgi sistemleridir.

Biyolojiden esinlenen diğer algoritmalarda olduğu gibi YBS’de de tasarım aşamasında aşağıdaki temel soruların cevaplarının verilmesi gerekmektedir.

- Sistemdeki elemanlar nasıl temsil edilecektir?
- Bireylerin çevre ve birbirleri ile olan ilişkilerini değerlendirmek için hangi değerlendirme mekanizmaları kullanılacaktır?
- Sistem dinamiğini yönetmek için adaptasyon prosedürlerinin belirlenmesi. Yani sistem davranışı zamanla neye göre değişecektir?

Yukarıdaki soruların cevaplanma süreçleri YBS oluşturulurken izlenmesi gereken katmanlı bir yapının aşamaları olarak da düşünülebilir. Şekil 4.6’da YBS için katmanlı yapı yaklaşımı görülmektedir.

Bu yapıya göre tasarım, bağışıklık hücre ve moleküllerin gösteriminde kullanılacak soyut modelin belirlenmesi ile başlar. 1979 yılında Perelson ve Oster’in sunduğu Şekil Uzayı en çok kabul gören ve en sık kullanılan yaklaşımdır. İkinci adım ise YBS elemanları arasındaki ilişkileri değerlendirmek için literatürde sunulan çeşitli ölçütlerden uygun olanını seçmektir. Örneğin iki eleman da ikili kodlanmış ise aralarındaki ilişki Hamming uzaklığı kullanılarak değerlendirilebilir. En son adımda ise sistemdeki dinamiği yönetmek için adaptasyon prosedürü olarak amaca uygun bir YBS algoritması seçilir.



Şekil 4.6 YBS' nin Katmanlı Yapısı (de Castro, ve Timmis, 2002)

4.2.2.1. Şekil uzayı


Bağışıklık elemanları arasındaki etkileşim pek çok fizikokimyasal olayı içerir. Mesela etkileşimdeki elemanlar arasında kovalent olmayan bağ, hidrojen bağı vb. bağların oluşması gibi. Bir antijenin bir antikor tarafından tanınması için, yüzeylerinin birbirlerini tamamlayacak şekilde bağlanmaları gerekir. Bu yüzden moleküller üzerinde geniş tamamlayıcı bölgelere ihtiyaç duyulur. Antijen ve antikorların birbirlerini tamamlamaları için gerekli olan şekil, elektrik dağılımları, uygun tamamlayıcı pozisyonları gibi özelliklerinin kümesine molekülün genelleştirilmiş şekli adı verilir.

Bir antikoru genelleştirilmiş şeklinin L tane parametre ile gösterilebildiğini varsayalım. Bu durumda L -boyutlu bir uzayda bir nokta, antijenin bağlanma özelliklerine göre bağışıklık hücrelerinin üzerindeki moleküler reseptörlerin antijene bağlandıkları alanların genelleştiriliş şeklini göstermiş olur ve şekil uzayı S olarak adlandırılır.

Antijen tanıma için gerekli olan tüm hücrelerin oluşturduğu sete, bağışıklık repertuarı denir. Vücudumuzun tüm antijenlerde korunabilmesi için bu repertuarın

tam olması gereklidir. Vücut, herhangi bir antijeni tanıyabilecek reseptör moleküllerini oluşturacak protein genlerine sahiptir ve bu genlerin farklı kombinasyonlarda dizilimi ile doğada bulunan hemen hemen tüm antijenleri tanıyabilir. Yani vücudumuzun bağışıklık repertuarı tamdır.

Bunu bir örnek ile açıklayalım. Mesela bir canlının N -boyutlu bir şekil uzayı olduğunu varsayalım. İlk başta da söylendiği gibi iki hücre birbirine bağlanırken aralarında pek çok fizikokimyasal olay meydana gelir. İşte varsayılan bu N -boyutlu şekil uzayında N tane eksen vardır ve her bir eksen, iki hücre arasında gerçekleşen fizikokimyasal etkileşimlerden birini temsil eder. Örneğin, bir A antijeni ile bir B Antikoru arasında iki çeşit fizikokimyasal etkileşim gerçekleşebilir kabulü yapılsın. Bu durumda her bir fizikokimyasal etkileşimi temsilen 2 eksen kullanılacağı için iki boyutlu bir şekil uzayı, A antijeni ile B ve C antikorumu göstermek için kullanılabilir. Şekil 4.7’de bu şekil uzayı gösterilmiştir.




Şekil 4.7 Şekil Uzayı Gösterimi (de Castro ve Von Zuben, 1999)

Şekil 4.7’de *A* antijeni, *B* ve *C* antikorları ve sahip oldukları fizikokimyasal özellikler gösterilmektedir. *A* antijeni ile *C* antikoru arasındaki uzaklık, *B* antikorundan fazla olduğu için, *A* antijeni ile *C* antikoru arasındaki etkileşimin şiddeti, *A* antijeni ile *B* antikoru arasındaki etkileşimin şiddetinden daha fazladır diye gösterim yorumlanır.

Bağıışıklık sisteminde antikorların yabancı maddeleri tanıyabilmeleri için bu antijenik yapılardan gelen uyarımların belirli bir eşik seviyesini aşması gerekmektedir. Bu özellik ise şekil uzayında tanıma çemberi adı verilen ve Şekil 4.8’de görülen başka bir modelleme ile ifade edilmiştir.

Şekil 4.8’de üç tane antikor ve antijenler iki boyutlu bir şekil uzayında gösterilmişlerdir. Her bir hücrenin tanıma çemberi *e* eşik seviyesi ile belirlenen *Ve* çemberidir. Şekilde *H1* tanıma çemberi içinde kalan iki antijeni, *H3* ise sadece bir antijeni tanır. *H2*’nin tanıma çemberinde herhangi bir antijen olmadığı için *H3* antijen tanınamamaktadır. Doğada mevcut olabilecek antijen türleri, protein dizilimleri ile belirlendiği için belirli bir çeşitlilikte bulunabilirler.



Şekil 4.8 Tanıma çemberi şekil uzayı gösterimi (de Castro ve Von Zuben, 1999)

Şekil 4.8'deki iki boyutlu şekil uzayında bulunabilecek tüm antijen türleri bir V hacmi ile ifade edilmiştir. Başka bir deyişle bulunabilecek tüm antijenler mutlaka bu hacim içerisinde gösterilirler. Yine aynı şekil uzayında bulunan her bir antikorun bir V_e tanıma hacmi olduğuna göre, şekil uzayında V hacmi içerisinde tüm noktaları kapsayacak biçimde bir antikor popülasyonu olduğunda bu antikor popülasyonu tüm antijenleri tanıyabilir yani repertuar tamdır denebilir.

4.2.2.2. Duyarlılık hesaplaması

Matematiksel olarak S şekil uzayındaki herhangi bir m molekülün genelleştirilmiş şekli L uzunluğunda bir nitelik katarı olarak gösterilebilir. Yani $m = \langle m_1, m_2, \dots, m_L \rangle$ katarı L boyutlu bir şekil uzayında bir noktadır. Bu katar tam sayılar, gerçel sayılar, bitler veya sembollerden oluşabilir. Bu niteliklerin türü YBS problemine göre seçilir. Bu tanımlamada önemli olan şey hangi ölçüt veya ölçütlerin niteliklerin etkileşim kalitesini yani duyarlılığını belirlemede kullanılacağıdır.

Duyarlılık genellikle bağışıklık birimlerinin birbirini tanıma kalitesini ifade eder. Çözülmesi beklenen problemin türüne göre duyarlılık hesabında kullanılacak yöntem belirlenebilir. Genellikle antijen ile antikor arasındaki uzaklığın hesaplanması kullanılır. Yukarıda da bahsedildiği gibi iki eleman birbirinden ne kadar uzak ise birbirlerini o kadar tamamlayacağı düşünülür. Elemanların gösterimine göre kullanılacak uzaklık ölçütü de değişir. Genellikle Öklid veya Manhattan uzaklığı kullanılır. Eğer antijenin ve antikorun ikili gösterimi söz konusu ise Hamming Uzaklığı kullanılır. Bu uzaklıkların formülize edilmiş halleri Çizelge 4.1'de gösterildiği gibidir. Çizelge 4.1'de antikorlar $Ab = \langle Ab_1, Ab_2, \dots, Ab_L \rangle$, antijenler $Ag = \langle Ag_1, Ag_2, \dots, Ag_L \rangle$ olarak kabul edilmiştir.

Çizelge 4.1 Duyarlılık ölçütü için kullanılabilecek uzaklıklar

Uzaklık Ölçütü	Formülü
Öklid Uzaklığı	$D = \sqrt{\sum_{i=1}^L (Ab_i - Ag_i)^2}$
Manhattan Uzaklığı	$D = \sqrt{\sum_{i=1}^L Ab_i - Ag_i }$
Hamming Uzaklığı	$D = \sum_{i=1}^L \delta, \quad \delta = \begin{cases} 1 & , \quad Ab_i \neq Ag_i \\ 0 & , \quad Ab_i = Ag_i \end{cases}$

4.2.2.3. Bağışıklık algoritmaları

YBS modellerini dört ana başlık altında toplayabiliriz (de Castro, ve Timmis, 2002).

- Kemik ilik Modeli (Bone marrow model): Bu model hücre ve moleküllerin repertuarlarının üretilmesi için kullanılırlar.
- Timmus Modeli (Thymus Model): Kendi/yabancı ayırımı yapabilme kabiliyetine sahip hücre ve moleküllerin repertuarlarının üretilmesi için kullanılırlar
- Klonal Seçme Algoritmaları (Clonal Selection Algorithms): Bağışıklık sistemi bileşenlerinin harici çevre ve antijenler ile olan etkileşimin nasıl olacağını kontrol eder.
- Bağışıklık Ağ Modelleri (Immune Network Models): Kendi yapılarını, dinamiklerini ve meta dinamiklerini içeren bağışıklık ağlarını modeller.

4.2.2.4. Bağışıklık ağ modelleri

Bağışıklık sistemi için ilk önerilen yapıda sistem yabancı bir mikroorganizma tarafından uyarılmadığı sürece pasif durumdadır ve sadece antijenik bir yapı tarafından uyarıldığında dinamik hale geçer. Ancak daha sonradan sunulan bağışıklık ağ teorine göre B hücre reseptörleri idiotop denilen bir yapıya sahiptir ve bu yapı sayesinde diğer serbest durumdaki antikorlar veya reseptörler tarafından tanınabilir. Bağışıklık sisteminin elemanlarının tanıma ve tanınabilme yeteneği ile sistemin sürekli dinamik bir yapıda kaldığı söylenebilir. Bağışıklık ağ modelleri ise klonal seçme prensibinden farklı olarak bağışıklık sisteminin her zaman dinamik olan bir yapısını modellerler. Klonal seçme prensibi sadece antijenik bir yapı tarafından uyarıldığı zaman dinamik duruma geçtiği düşünülen sistemi modeller.

Bu tezde bağışıklık ağ modeli için Opt-aiNET algoritması kullanılmaktadır. Opt-aiNET de Castro ve Timmis (2002) tarafından sunulmuş veri analizi, tanıma, sınıflandırma için kullanılabilinen ağ tabanlı bir yapay bağışıklık algoritmasıdır.

4.2.2.5. Opt-aiNET algoritması

Opt-aiNET algoritması 2002'de de Castro ve Timmis tarafından önerilmiştir. Algoritma aşağıdaki gibidir:

1. Başlangıç: Rasgele bir başlangıç popülasyonu (P) oluştur. Popülasyonun üyeleri antikorlar (Ab) olmaktadır.
2. Yerel arama: (c) koşulu sağlanana kadar a-c çalış:

- a. Klonal yayılma: Her antikorun uygunluk fonksiyonu bul. Her antikorun kopyalarından oluşan klon kümesini üret.
 - b. Duyarlılık olgunlaşma: Her klonu ebeveyn antikorun uygunluğuyla ters orantılı olarak mutasyona uğrat. Mutasyona uğramış her klon için en yüksek uygunluğa sahip antikoru seç ve seçilen antikorların ortalama uygunluğu bul.
 - c. Yerel yakınsama: Eğer popülasyonun ortalama uygunluğu bir önceki iterasyondan kayda değer biçimde değişmezse, bir sonraki adıma git, değilse, Adım 2'ye git.
3. Ağ etkileşimi: Ağdaki her antikor çifti için duyarlılığı bul.
 4. Ağ baskısı: Duyarlılığı önceden tespit edilen eşik değerinden küçük olan antikorları ele. Kalan antikorların sayısını belirle. Buna hafıza antikorları denir.
 5. MetaDinamik: Rasgele yeni antikorlar üret ve Adım 2'ye dön.

4.3. Hibrit Bulanık Sinir Ağından Kural Çıkarma

Bu bölümde hibrit bulanık sinir ağından kural çıkarabilmesi için gereken teorik yaklaşım işlenmektedir. 2.21'e göre hibrit bulanık sinir ağının giriş vektörü aşağıdaki gibidir:

$$Y = X \cup XB$$

(2.17) ve (2.18)' e göre

$$X = [x_1, x_2, \dots, x_m]$$

ve (2.16)'ya göre

$$x_i \in \{0,1\}, \quad i=1,2,\dots,m$$

olup, (2.19) ve (2.20)' ye göre

$$XB = [xb_1, xb_2, \dots, xb_t]$$

ve $xb_i, i=1,2,\dots,t$ üyelik dereceleri olduğu için

$$xb_i \in [0,1], \quad i=1,2,\dots,t$$

şeklindedir. Buradan hibrit bulanık sinir ağının girişi

$$Y = [y_1, y_2, \dots, y_m, y_{m+1}, \dots, y_{m+t}] \quad (4.1)$$

olur ve böylece

$$y_i \in \{0,1\} \quad i = 1, 2, \dots, m \quad (4.2)$$

$$y_i \in [0,1] \quad i = m+1, m+2, \dots, m+t$$

elde edilir.

Girişler kümesi ise aşağıdaki gibidir:

$$G = \{Y_1, Y_2, \dots, Y_N, \dots\} \quad (4.3)$$

Teorem 4.6.

G kapalı kümedir.

İspat:

G 'nin kapalı olması için tümleyeni G^c 'nin açık küme olması gerekir.

$$a = (a_1, a_2, \dots, a_m, \dots, a_{m+t}) \in G^c$$

olsun. G^c 'nin tanımına göre

$$a_i \in \begin{cases} (-\infty, 0) \cup (0, 1) \cup (1, +\infty) & , i = 1, \dots, m \\ (-\infty, 0) \cup (1, +\infty) & , i = m + 1, \dots, m + t \end{cases}$$

dir.

$$d_i^0 = d(a_i, 0) = |a_i - 0|, \quad i = 1, 2, \dots, m + t,$$

$$d_i^1 = d(a_i, 1) = |a_i - 1|, \quad i = 1, 2, \dots, m + t$$

ve

$$D^0 = \{d_1^0, d_2^0, \dots, d_{m+t}^0\}$$

$$D^1 = \{d_1^1, d_2^1, \dots, d_{m+t}^1\}$$

şeklindedir. Diğer taraftan,

$$b = \min(D^0)$$

$$c = \min(D^1)$$

olsun. Burada,

$$r = \frac{1}{2} \min(b, c)$$

olarak seçersek $B(a, r) \subset G^c$ olur. Bu da, G^c 'nin açık olduğu anlamına gelmektedir.

G^c açık olursa Tanım 4.4'e göre G kapalı kümedir.

Uyarı.

G 'nin açık küme olması gerekmez.

G 'nin açık küme olması için $\forall Y_i \in G$ için $B(Y_i, r) \subset G$ olacak şekilde $r > 0$ olması gerekir. Ama $Y_i = (1, \dots, 1)$ olursa bu şart sağlanamayacağı için G açık küme değildir.

Teorem 4.7.

G sınırlı kümedir.

İspat:

$r > 1$ seçersek $G \subset B(0, r)$ olacağı için G sınırlı bir kümedir.

Teorem 4.8.

G kompakt kümedir.

İspat:

Teorem 4.7'den göre G 'nin kapalı, Teorem 4.8'den ise sınırlı küme olduğu görülmektedir. O zaman Heine-Borel teoremine göre G kümesi kompakttır.

Uyarı

G kümesinin dışbükey olması gerekmez.

Örnek

$$a = (0, \dots, 0) \in G$$

ve

$$b = (1, \dots, 1) \in G$$

olsun. G 'nin dışbükey olması durumunda $\forall \lambda, 0 < \lambda < 1$ için

$$c = \lambda a + (1 - \lambda)b \in G$$

olması gerekir. a ve b 'nin tanımından

$$c = (1 - \lambda, \dots, 1 - \lambda)$$

$0 < \lambda < 1$ olduğu için $0 < 1 - \lambda < 1$ olmaktadır. İlk m elemanın 0 yada 1 olması gerektiği için G dışbükey değildir.

Teorem 4.9

(2.15) fonksiyonu G 'de bir optimizasyon problemidir.

İspat:

(2.15)'de

$$h = - \left[ww_1 \left(\frac{1}{1+e} \left(- \sum_{j=1}^k v_j \frac{1}{- \sum_{i=1}^n w_{ij} x_i + \theta_j} \right) + \xi \right)^{-1} + ww_2 \left(\frac{1}{1+e} \left(- \sum_{j=1}^l vb_j \frac{1}{- \sum_{i=1}^m wb_{ij} x_i + \theta b_j} \right) + \xi b \right)^{-1} \right] + \zeta$$

olsun. Bu durumda (2.15) aşağıdaki gibi olur:

$$C = \frac{1}{1+e^h}$$

$w_{ij} \in R$, $\theta_j \in R$, $i=1,2,\dots,n$, $j=1,2,\dots,k$ ve $x_i \in \{0,1\}$ olduğu için

$$-\sum_{i=1}^n w_{ij}x_i + \theta_j \in R$$

olur. Buradan da

$$e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j} \in (0, \infty)$$

ve

$$\frac{1}{1+e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \in (0, 1)$$

olur. $v_j \in R$, $\xi \in R$, $j=1,2,\dots,k$ olduğu için

$$-\sum_{j=1}^k \left(v_j \frac{1}{1+e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \right) + \xi \in R$$

ve

$$\left(1+e^{-\sum_{j=1}^k \left(v_j \frac{1}{1+e^{-\sum_{i=1}^n w_{ij}x_i + \theta_j}} \right) + \xi} \right)^{-1} \in (0, 1)$$

olur.

Diğer taraftan $wb_{ij} \in R$, $\theta b_j \in R$, $i=1,2,\dots,m$, $j=2,\dots,l$ ve $xb_i \in [0,1]$ olduğu için

$$-\sum_{i=1}^m wb_{ij}xb_i + \theta b_j \in R$$

olur. Buradan da

$$e^{-\sum_{i=1}^m wb_{ij}xb_i + \theta b_j} \in (0, \infty)$$

ve

$$\frac{1}{1 + e^{-\sum_{i=1}^m wb_{ij}xb_i + \theta b_j}} \in (0, 1)$$

olur. $vb_j \in R$, $\xi b \in R$, $j=1,2,\dots,l$ olduğu için

$$-\sum_{j=1}^l \left(vb_j \frac{1}{1 + e^{-\sum_{i=1}^m wb_{ij}xb_i + \theta b_j}} \right) + \xi b \in R$$

ve

$$\left(1+e^{-\sum_{j=1}^I \left(vb_j \frac{1}{1+e^{-\sum_{i=1}^m wh_{ij}xb_i+\theta b_j}} \right) + \zeta b} \right)^{-1} \in (0, 1)$$

olur. Son olarak, $ww_1, ww_2, \zeta \in R$ olduğundan $h \in R$ olur.

Burada $e^h \in (0, +\infty)$ olacağından dolayı

$$0 < C < 1$$

olur. Buradan da $C(Y)$ fonksiyonunun sup ve inf'e sahip olduğu ve sürekli olduğu görülüyor ki, bu da Weierstrass teoremine göre bu problemin bir optimizasyon problemi olduğu anlamına gelmektedir.

Hibrit bulanık sinir ağından kural çıkarmak için bulunan bu $C(Y)$ fonksiyonu optimize edilmiştir. Bu amaçla Opt-aiNET algoritması kullanılmıştır.

Optimizasyon sonucu üretilen vektörlerin kodu çözülerek kural tabanı oluşturulmuştur. Hibrid Sinir ağından kural çıkarmak için önerilen algoritma aşağıdaki gibidir:

Adım 0 Ağın eğitimi sonucu oluşan fonksiyon optimize edilir.

Adım 1 Optimizasyon sonucu bulunan çözüm kümelerin kodu çözülür.

Adım 2 Çözüm kümesinin ilk m sayıda elemanı kesin nitelikler, sonraki t elemanı bulanık nitelikler olarak iki alt kümeye bölünür.

Adım 2.1 Kesin nitelikleri belirten X alt kümesinin kodu

çözülür.

Adım. 2.1.1 X kümesi N parçaya bölünür. Her parça bir A_n niteliğini belirtmektedir ve m_n uzunluğundadır.

Adım 2.1.2 (2.16) formülüne göre kod çözülür.

Adım 2.1.3 Aynı niteliğin farklı değerlerini birleştirmek için “VEYA”, farklı nitelikleri birleştirmek için “VE” kullanılır.

Adım 2.2 Bulanık nitelikleri belirten XB alt kümesinin kodu çözülür.

Adım. 2.2.1 XB kümesi K parçaya bölünür. Her parça bir L_k niteliğini belirtmektedir ve t_k uzunluğundadır.

Adım 2.2.2 Durulaştırma yapılarak kod çözülür.

Adım 2.2.3 Farklı nitelikleri birleştirmek için “VE” kullanılır.

Adım 3. Adım 2.1.3 ve Adım 2.2.3’de bulunan alt kurallar “VE” ile birleştirilerek kural tabanı oluşturulur.

4.4. Bölüm Değerlendirmesi

Bu tezde YSA'dan kural çıkarmak için optimizasyon yöntemi kullanılmıştır. Bu bölümde optimizasyon teorisinin temelleri anlatılarak, son yıllarda karmaşık optimizasyon problemleri için uygulanan yapay bağışıklık yöntemleri ve tezde kullanılan Opt-aiNET algoritması hakkında kısaca bilgi verilmektedir. Ayrıca, optimizasyonu yapılan fonksiyonun özellikleri incelenerek ve bu problemin bir optimizasyon problemi olduğu ispatlanmaktadır. Daha sonra hibrit bulanık sinir ağından kural çıkarmak için önerilen yöntem açıklanmaktadır.


Bir sonraki bölümde hibrit bulanık sinir ağından kural çıkarmak için yapılan iki uygulama hakkında bilgi verilmektedir.

5. HİBRİT BULANIK SINIR AĞINDAN KURAL ÇIKARMA İÇİN DENEYSEL SONUÇLAR VE ANALİZ


Bu bölümde, bir önceki bölümde önerilen hibrit bulanık sinir ağından kural çıkarma yöntemi iki farklı probleme uygulanmış ve başarısı incelenmektedir. Kullanılan problemler üçüncü bölümdekilerle aynıdır. Uygulama programları Matlab R2006a kullanılarak kodlanmıştır.

5.1. Cleveland Kalp Hastalıkları Veri Kümesinde Uygulama

Cleveland Kalp Hastalıkları veri kümesi için sinir ağından kural çıkarmak amacıyla aynı sinir ağı tüm verilerle bir daha eğitilmiştir. Ağın YSA1 kısmı beş, BSA kısmı üç gizli nörondan oluşmaktadır. Bu değerler en iyi sonucu üretmek için deneysel olarak tespit edilmiştir. Kullanılan Hibrid Sinir Ağının yapısı Şekil 5.1’de gösterilmektedir Bu eğitim sonucunda ağ 303 veriden 300’ünü öğrenmiştir. Oluşan hata grafiği Şekil 5.2’de görülmektedir.



Şekil 5.1 Geliştirilen Hibrid Sinir Ağının Yapısı



Şekil 5.2 Cleveland Kalp Hastalıkları veri kümesi için tüm verilerle eğitim sonucu oluşan hata fonksiyonu

Eğitim yapıldıktan sonra hibrit sistemin ağırlıkları ve eşik değerleri için bulunan değerler Çizelge 5.1- 5.7’de görülmektedir.

Çizelge 5.1 BSA ağı için giriş katmanı ile ara katman arasındaki wb ağırlık matrisi

		BSA ara katman nöronları		
BSA giriş katmanı nöronları		1. nöron	2. nöron	3. nöron
	1. nöron	0,2689	0,1596	-1,8561
	2. nöron	2,8744	-2,4917	0,3744
	3. nöron	-0,8602	-1,9943	-3,8129
	4. nöron	0,411	3,065	3,4077
	5. nöron	2,7614	-2,0502	-0,3307
	6. nöron	2,5724	-2,0341	-0,5221
	7. nöron	6,6082	-3,2713	1,2243
	8. nöron	-0,4989	0,7885	0,1622
	9. nöron	-2,2649	-0,7132	-6,4203
	10. nöron	1,5348	-2,1046	-5,0577
	11. nöron	3,7132	-0,4102	-1,6888
	12. nöron	6,6779	-2,007	4,2841
	13. nöron	1,0251	0,599	1,7246
	14. nöron	5,0814	1,0877	5,5199
	15. nöron	-2,2536	1,9055	-6,2985

Çizelge 5.2 YSA1 ağı için giriş katmanı ile ara katman arasındaki w ağırlık matrisi

		YSA1 ara katman nöronları				
YSA1 giriş katmanı nöronları		1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
	1. nöron	-1,4596	0,9267	0,9267	1,3085	0,9267
	2. nöron	0,5441	-0,8447	-0,8447	-1,573	-0,8447
	3. nöron	-1,4725	-0,8954	-0,8954	0,1867	-0,8954
	4. nöron	1,8562	0,2917	0,2917	3,9706	0,2917
	5. nöron	-1,1334	-0,5904	-0,5904	-3,3342	-0,5904
	6. nöron	-0,1659	1,2762	1,2762	-1,0876	1,2762
	7. nöron	1,3428	0,3062	0,3062	-1,9719	0,3062
	8. nöron	-2,2583	-0,2241	-0,2241	1,7074	-0,2241
	9. nöron	-1,8813	0,7807	0,7807	-2,7095	0,7807
	10. nöron	0,2826	-0,8551	-0,8551	2,3038	-0,8551
	11. nöron	0,6832	0,1564	0,1564	0,1413	0,1564
	12. nöron	2,5308	-0,0298	-0,0298	-0,0305	-0,0298
	13. nöron	-3,4463	0,1119	0,1119	-0,234	0,1119
	14. nöron	2,2247	1,0189	1,0189	-5,7679	1,0189
	15. nöron	1,0401	-0,6199	-0,6199	7,2172	-0,6199
	16. nöron	-4,1804	-0,317	-0,317	-1,7138	-0,317
	17. nöron	-1,716	-3,9027	-3,9027	2,6233	-3,9027
	18. nöron	2,0063	-0,5209	-0,5209	-0,6866	-0,5209
	19. nöron	-1,4187	2,5942	2,5942	-4,004	2,5942
	20. nöron	0,2129	1,9115	1,9115	1,8029	1,9115
	21. nöron	-2,6383	-0,122	-0,122	-0,6311	-0,122
	22. nöron	-1,283	-1,6951	-1,6951	2,5359	-1,6951
	23. nöron	3,0058	1,8991	1,8991	-2,1692	1,8991

Çizelge 5.3 YSA1 ağı ara katman nöronlarının θ eşik değerleri vektörü

YSA1 ara katman nöronları				
1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
-1,9155	0,082	0,082	0,7355	0,082

Çizelge 5.4 YSA1 ağı için ara katman ile çıkış katmanı arasındaki v ağırlıklar vektörü

YSA1 ara katman nöronları				
1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
-6,3499	-3,0899	-3,0899	-7,0316	-3,0899

Çizelge 5.5 BSA ağı gizli katman nöronlarının θb eşik değerleri vektörü

BSA ara katman nöronları		
1. nöron	2. nöron	3. nöron
-4.9367	4.396	4.9426

Çizelge 5.6 BSA ağı için gizli katman ile çıkış katmanı arasındaki vb ağırlıklar Vektörü

BSA ara katman nöronları		
1. nöron	2. nöron	3. nöron
-7,2015	-2,3629	6,0705

Çizelge 5.7 YSA2 ağı için YSA1 ve BSA ağı çıkışları ile genel çıkış nöronu arasındaki w ağırlıklar vektörü

YSA2 nöronları	
1. nöron	2. nöron
1,5705	2,1486

YSA1 ağı için çıkış nöronunun eşik değeri $\zeta = 7,4756$, BSA ağı için çıkış nöronunun eşik değeri $\zeta b = 1,2642$ ve ağın genel çıkışı için eşik değeri ise $\zeta = -1,1718$ olarak bulunmuştur.

Eğitim işleminin sonucunda ağın genel çıkışı için (2.15)'i de kullanarak aşağıdaki gibi bir fonksiyon bulunmuştur.

$$C(Y) = \left[1 + e^{\left[-w w_1 \left(\frac{-\sum_{j=1}^5 v_j^* \frac{1}{-\sum_{i=1}^{23} w_{ji} x_i + \theta_j}}{1+e} \right) + \zeta \right] + w w_2 \left(\frac{-\sum_{j=1}^3 v b_j^* \frac{1}{-\sum_{i=1}^{15} w b_{ji} x b_i + \theta b_j}}{1+e} \right) + \zeta b} \right]^{-1} + \zeta \quad (5.1)$$

Bulunan $C(Y)$ fonksiyonu optimize edilmiştir. Optimizasyon için, Opt-aiNET algoritması kullanılmıştır. Optimizasyon sonucu $C(Y)$ fonksiyonunu 0 yapan antikörlerin kodu çözülerek “0” sınıfı, $C(Y)$ fonksiyonunu 1 yapan antikörlerin kodu çözülerek “1” sınıfı oluşturulmuştur. Çözüm antikörleri 23 ikili ve 15 gerçel sayıdan oluşmaktadır. Çözüm antikörlerinin kodunu çözüp anlaşılır hale getirmek

için Bölüm 4.3'te anlatılan yöntem uygulanmıştır. Sonuç olarak 0 sınıfı için 36, 1 sınıfı için 40 kural elde edilmiştir. Elde edilen kurallar Çizelge 5.8 ve Çizelge 5.9.'da görülmektedir.

Çizelge 5.8 Cleveland Kalp Hastalıkları veri tabanı Sınıf 0 için kurallar

No	Kurallar
1.	Eğer Yaş ≤ 68 & (Ağrı Tipi=asympt veya Ağrı Tipi=abnang) & Kan basıncı ≤ 147 & Kan Şekeri $>120=0$ & Nabız $\in [92, 175]$ & Egzersiz=1 & ST depr $\in [0.3, 3.5]$ & Eğim $\neq$ yukarı & Thal=Düzelebilir Kusur O Halde Sınıf 0
2.	Eğer Yaş ≤ 63 & Cinsiyet=Erkek & Ağrı Tipi=asympt & Kan basıncı ≤ 141 & Nabız $\in [86, 172]$ & ST depr ≤ 1.8 & Eğim $\neq$ aşağı & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0
3.	Eğer Yaş ≥ 50 & Kan basıncı ≥ 110 & Kolesterol ≥ 195 & Elektrokard=hyper & Nabız ≤ 180 & ST depr $\in [0.6, 3.2]$ & Eğim $\neq$ yukarı & (Damar Sayısı=1 veya Damar Sayısı=2) O Halde Sınıf 0
4.	Eğer Yaş ≤ 63 & Kan basıncı ≥ 110 & Kan Şekeri $>120=0$ & Nabız ≤ 183 & ST depr $\in [2.4, 6.2]$ & Eğim $\neq$ yukarı & Thal $\neq$ Düzelebilir Kusur O Zaman Sınıf 0
5.	Eğer Yaş ≤ 63 & Cinsiyet=Erkek & Ağrı Tipi=asympt & Kan basıncı ≥ 108 & Elektrokard=hyper & Nabız ≤ 174 & ST depr $\in [0.2, 3.7]$ & Eğim $\neq$ aşağı & Damar Sayısı=4 & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

6. Eğer Yaş ≤ 67 & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≥ 110 & Elektrokard=norm & Nabız $\in [77, 179]$ & ST depr $\in [0.8, 3.9]$ & Thal=Düzelebilir Kusur O Halde Sınıf 0
7. Eğer Yaş ≥ 48 & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≥ 110 & Kolesterol ≤ 224 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Nabız ≤ 177 & ST depr ≥ 1.6 & Damar Sayısı=0 & Thal=Düzelebilir Kusur O Zaman Sınıf 0
8. Eğer Yaş ≤ 68 & Ağrı Tipi $\neq$ anjin & Kan basıncı ≤ 145 & Kolesterol $\in [180, 246]$ & Kan Şekeri $>120=0$ & Elektrokard $\neq$ norm & Nabız $\in [75, 183]$ & ST depr ≤ 3 & (Damar Sayısı=1 veya Damar Sayısı=2) O Halde Sınıf 0
9. Eğer Yaş ≤ 67 & Ağrı Tipi=asympt & Kan basıncı ≤ 141 & Kan Şekeri $>120=1$ & Elektrokard $\neq$ abn & Nabız ≤ 176 & ST depr $\in [0.3, 3.6]$ & Egim $\neq$ yukarı & Damar Sayısı=4 O Halde Sınıf 0
10. Eğer Yaş ≥ 49 & Cinsiyet=Erkek & Kan basıncı ≤ 145 & Kolesterol ≥ 224 & Kan Şekeri $>120=0$ & Elektrokard=hyper & Nabız $\in [75, 177]$ & Egzersiz=0 & ST depr $\in [0.6, 3.7]$ O Halde Sınıf 0
11. Eğer Yaş ≤ 53 & Kan basıncı ≤ 145 & Kolesterol ≥ 205 & Kan Şekeri $>120=0$ & Elektrokard=norm & Nabız ≤ 173 & ST depr $\in [0.2, 3.2]$ & Damar Sayısı=4 & Thal $\neq$ norm O Halde Sınıf 0
12. Eğer Yaş $\in [37, 66]$ & Cinsiyet=Kadın & Ağrı Tipi $\neq$ notang & Kan basıncı ≥ 109 & Kolesterol ≥ 211 & Nabız $\in [75, 175]$ & ST depr $\in [0.2, 3.9]$ & Thal=Düzelebilir Kusur O Halde Sınıf 0

13. Eğer Yaş ≤ 68 & Cinsiyet=Erkek & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≤ 142 & Kolesterol ≥ 214 & Elektrokard $\neq$ abn & Nabız ≤ 173 & Egzersiz=1 & ST depr ≤ 2.3 & Eğim $\neq$ aşağı & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

14. Eğer Yaş ≤ 50 & Cinsiyet=Erkek & Kan basıncı ≤ 143 & Elektrokard=hyper & Nabız ≤ 182 & ST depr ≤ 1 & Eğim $\neq$ düz & (Damar Sayısı=0 veya Damar Sayısı=3) & Thal=Düzelebilir Kusur O Halde Sınıf 0

15. Eğer Yaş ≥ 50 & Ağrı Tipi=asympt & Kan basıncı ≥ 107 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Nabız $\in [85, 180]$ & ST depr ≥ 2 & Eğim=düz & Damar Sayısı=3 & Thal $\neq$ norm O Halde Sınıf 0

16. Eğer Yaş ≤ 69 & Cinsiyet=Erkek & (Ağrı Tipi=anjin veya Ağrı Tipi=notang) & Kan basıncı $\in [108, 144]$ & Kolesterol $\in [178, 232]$ & Elektrokard $\neq$ hyper & Nabız ≥ 131 & ST depr ≤ 3.3 & Eğim $\neq$ aşağı & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

17. Eğer Yaş $\in [39, 63]$ & Cinsiyet=Kadın & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≤ 124 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ hyper & Nabız $\in [72, 172]$ & Egzersiz=1 & ST depr ≤ 2 & Eğim=düz & Damar Sayısı=0 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

18. Eğer Yaş $\in [39, 68]$ & Cinsiyet=Erkek & Ağrı Tipi $\neq$ notang & Kan basıncı ≥ 104 & Kan Şekeri $>120=1$ & Nabız ≤ 176 & ST depr ≤ 4 & Eğim=düz & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

19. Eğer Yaş ≤ 63 & (Ağrı Tipi=anjin veya Ağrı Tipi=asympt) & Kan basıncı ≥ 112 & Nabız ≤ 182 & Egzersiz=1 & ST depr ≥ 1.8 & Eğim $\neq$ düz & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

20. Eğer Yaş ≤ 67 & Kan basıncı ≥ 107 & Kolesterol ≤ 216 & Elektrokard=hyper & Nabız $\in [90, 150]$ & Egzersiz=0 & ST depr $\in [0.3, 3.1]$ & Eğim $\neq$ aşağı & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

21. Eğer Yaş ≥ 48 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ abnang & Kan basıncı ≥ 109 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Nabız ≤ 153 & ST depr $\in [0.6, 3.4]$ & Eğim $\neq$ aşağı & Damar Sayısı=3 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

22. Eğer Yaş $\in [38, 68]$ & Cinsiyet=Erkek & Ağrı Tipi $\neq$ abnang & Kan basıncı ≥ 109 & Kan Şekeri $>120=1$ & Nabız ≤ 179 & Egzersiz=1 & ST depr ≤ 3.1 & Eğim $\neq$ aşağı & (Damar Sayısı=0 veya Damar Sayısı=2) & Thal=Düzelebilir Kusur O Halde Sınıf 0

23. Eğer Yaş ≥ 50 & Ağrı Tipi $\neq$ asympt & Kan basıncı ≥ 112 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Nabız ≤ 180 & Egzersiz=1 & ST depr ≥ 1.7 & Eğim=düz & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

24. Eğer Yaş ≤ 62 & Cinsiyet=Kadın & (Ağrı Tipi=anjin veya Ağrı Tipi=asympt) & Kan basıncı ≥ 110 & Nabız $\in [90, 150]$ & Egzersiz=1 & ST depr ≤ 1 & Eğim $\neq$ yukarı & (Damar Sayısı=0 veya Damar Sayısı=3) & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

25. Eğer Yaş ≥ 50 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ asympt & Kan basıncı ≥ 109 & Kolesterol ≥ 224 & Kan Şekeri $>120=0$ & Nabız $\in [77, 153]$ & ST depr ≤ 4 & Damar Sayısı=0 & Thal=Kalıcı Kusur O Halde Sınıf 0

26. Eğer Yaş ≤ 68 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ asympt & Kan basıncı ≥ 104 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Elektrokard $\neq$ norm & Nabız

≤ 144 & Egzersiz=0 & ST depr ≤ 2.2 & Eđim $\neq$ ařađı & Damar Sayısı=0 & Thal=norm O Halde Sınıf 0

27. Eđer Yař $\in [40, 67]$ & Cinsiyet=Kadın & (Ađrı Tipi=asympt veya Ađrı Tipi=abnang) & Kan basıncı ≥ 108 & Kan řekeri $>120=0$ & Nabız ≥ 130 & Egzersiz=1 & ST depr $\in [0.8, 3]$ & Eđim $\neq$ yukarı & Damar Sayısı=0 O Halde Sınıf 0

28. Eđer Yař ≥ 50 & Cinsiyet=Erkek & Ađrı Tipi=abnang & Kan basıncı ≤ 143 & Kan řekeri $>120=0$ & Nabız ≤ 179 & ST depr $\in [0.3, 2.3]$ & Eđim $\neq$ düz & Thal=Düzelebilir Kusur O Halde Sınıf 0

29. Eđer Yař ≤ 53 & Cinsiyet=Erkek & (Ađrı Tipi=asympt veya Ađrı Tipi=abnang) & Kan basıncı ≥ 112 & Kolesterol $\in [169, 230]$ & Kan řekeri $>120=0$ & Elektrokard $\neq$ hyper & Nabız ≥ 99 & ST depr ≤ 1 & Eđim=yukarı & Thal $\neq$ norm O Halde Sınıf 0

30. Eđer Yař ≥ 49 & Cinsiyet=Erkek & Ađrı Tipi $\neq$ asympt & Kan basıncı ≥ 110 & Kolesterol $\in [194, 242]$ & Kan řekeri $>120=0$ & Elektrokard $\neq$ norm & Nabız ≤ 180 & Egzersiz=0 & ST depr ≤ 3.5 & Eđim $\neq$ ařađı & (Damar Sayısı=1 veya Damar Sayısı=3) & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

31. Eđer Yař $\in [41, 67]$ & Kan basıncı ≥ 112 & Kolesterol $\in [203, 227]$ & Elektrokard=norm & Nabız ≤ 174 & ST depr ≤ 1 & Eđim $\neq$ ařađı & (Damar Sayısı=1 veya Damar Sayısı=3) & Thal=Düzelebilir Kusur O Halde Sınıf 0

32. Eđer Yař ≥ 45 & (Ađrı Tipi=asympt veya Ađrı Tipi=notang) & Kan basıncı ≥ 108 & Kolesterol ≤ 220 & Elektrokard $\neq$ norm & Nabız ≤ 176 & Egzersiz=0 & ST depr ≤ 1.9 & Damar Sayısı $\neq 0$ & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 0

33. Eğer Yaş ≤ 67 & (Ağrı Tipi=anjin veya Ağrı Tipi=abnang) & Kan basıncı ≤ 141 & Kan Şekeri $>120=1$ & Elektrokard=hyper & Nabız ≤ 177 & Egzersiz=0 & ST depr ≤ 3.9 & Eğim $\neq$ aşağı & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal=norm Zaman Sınıf 0

34. Eğer Yaş ≥ 46 & Cinsiyet=Erkek & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≤ 144 & Kan Şekeri $>120=0$ & Nabız $\in [72, 169]$ & ST depr ≤ 1.9 & Eğim $\neq$ düz & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

35. Eğer Yaş $\in [36, 67]$ & Ağrı Tipi $\neq$ abnang & Kan basıncı ≤ 147 & Kolesterol ≥ 211 & Kan Şekeri $>120=0$ & Elektrokard=norm & Nabız ≥ 95 & Egzersiz=1 & ST depr ≥ 2.2 & Eğim=düz & Damar Sayısı=3 & Thal=Düzelebilir Kusur O Halde Sınıf 0

36. Eğer Yaş ≤ 67 & Ağrı Tipi $\neq$ notang & Kan basıncı ≤ 120 & Elektrokard $\neq$ hyper & Nabız ≤ 178 & ST depr $\in [0.2, 3.5]$ & Eğim=düz & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 0

Çizelge 5.9 Cleveland Kalp Hastalıkları veri tabanı Sınıf 1 için kurallar

No	Kurallar
1.	Eğer Yaş $\in [37, 67]$ & Cinsiyet=Kadın & Ağrı Tipi $\neq$ asympt & Kan basıncı ≤ 145 & Elektrokard $\neq$ abn & Nabız ≤ 181 & ST depr ≤ 2.3 & Eğim $\neq$ düz & Damar Sayısı ≤ 1 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1
2.	Eğer Yaş ≥ 45 & Cinsiyet=Kadın & Ağrı Tipi $\neq$ anjin & Kan basıncı ≤ 147 & Nabız ≤ 170 & Egzersiz=0 & ST depr $\in [0.1, 3.4]$ & (Damar Sayısı=0 veya Damar Sayısı=2) O Halde Sınıf 1
3.	Eğer Yaş ≤ 69 & (Ağrı Tipi=anjin veya Ağrı Tipi=notang) & Kan basıncı ≥ 111 & Kolesterol ≤ 238 & Elektrokard $\neq$ abn & Nabız $\in [101, 180]$ & ST depr ≤ 2.5 & Eğim $\neq$ düz & Damar Sayısı ≤ 1 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1
4.	Eğer Yaş ≤ 66 & Cinsiyet=Erkek & Kan basıncı $\in [107, 142]$ & Nabız ≥ 124 & Egzersiz=0 & ST depr ≤ 3.1 & Eğim $\neq$ düz & Damar Sayısı=1 & Thal=norm O Halde Sınıf 1
5.	Eğer Yaş ≤ 66 & Cinsiyet=Kadın & Ağrı Tipi $\neq$ anjin & Kan basıncı $\in [105, 141]$ & Kolesterol ≤ 233 & Elektrokard $\neq$ hyper & Nabız ≥ 132 & Egzersiz=0 & ST depr ≤ 3.4 & Damar Sayısı $\neq 3$ & Thal=norm O Halde Sınıf 1

6. Eğer Yaş ≤ 65 & Cinsiyet=Erkek & Kan basıncı $\in [110, 143]$ & Elektrokard $\neq$ abn & Nabız ≤ 176 & Egzersiz=0 & ST depr $\in [0.1, 3.6]$ & Eğim $\neq$ düz & Damar Sayısı ≤ 1 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1
7. Eğer Yaş ≤ 48 & Ağrı Tipi $\neq$ anjin & Kan basıncı ≤ 144 & Kolesterol $\in [197, 244]$ & Nabız ≤ 179 & ST depr $\in [0.1, 3.2]$ & Damar Sayısı $\neq 3$ & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1
8. Eğer Yaş ≤ 68 & Cinsiyet=Kadın & (Ağrı Tipi=anjin veya Ağrı Tipi=notang) & Kan basıncı ≥ 110 & Nabız ≤ 174 & Egzersiz=0 & ST depr $\in [0.3, 3.4]$ & Eğim $\neq$ düz & (Damar Sayısı=0 veya Damar Sayısı=3) & Thal=norm O Halde Sınıf 1
9. Eğer Yaş ≤ 64 & Cinsiyet=Erkek & Kan basıncı ≤ 140 & Kolesterol $\in [197, 231]$ & Kan Şekeri $>120=0$ & Elektrokard $\neq$ hyper & Nabız $\in [76, 182]$ & Egzersiz=1 & ST depr ≤ 3 & Eğim $\neq$ düz & Damar Sayısı ≤ 1 O Halde Sınıf 1
10. Eğer Yaş ≤ 64 & Cinsiyet=Erkek & (Ağrı Tipi=anjin veya Ağrı Tipi=notang) & Kan basıncı ≤ 121 & Elektrokard $\neq$ norm & Nabız ≤ 171 & ST depr $\in [0.1, 3.9]$ & Eğim $\neq$ aşağı & (Damar Sayısı=0 veya Damar Sayısı=2) O Halde Sınıf 1
11. Eğer Yaş ≤ 67 & Cinsiyet=Kadın & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≥ 106 & Kan Şekeri $>120=0$ & Elektrokard=norm & Nabız ≥ 135 & ST depr ≤ 3.2 & Eğim $\neq$ düz & Damar Sayısı $\neq 3$ O Halde Sınıf 1

12. Eğer Yaş ≤ 63 & Cinsiyet=Erkek & Kan basıncı ≤ 141 & Kolesterol $\in [171, 226]$ & Kan Şekeri $>120=0$ & Elektrokard $\neq$ hyper & Nabız ≤ 182 & ST depr ≤ 2.1 & Eğim $\neq$ yukarı & (Damar Sayısı=0 veya Damar Sayısı=2) & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

13. Eğer Yaş ≤ 69 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ notang & Kan basıncı ≤ 144 & Elektrokard=hyper & Nabız ≥ 134 & Egzersiz=0 & ST depr ≤ 3.1 & Eğim $\neq$ düz & Damar Sayısı=0 & Thal=norm O Halde Sınıf 1

14. Eğer Yaş $\in [35, 55]$ & Cinsiyet=Erkek & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≥ 109 & Kolesterol $\in [201, 237]$ & Elektrokard $\neq$ abn & Nabız $\in [97, 178]$ & Egzersiz=0 & ST depr ≤ 2 & Eğim $\neq$ düz & Damar Sayısı=0 & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 1

15. Eğer Yaş $\in [38, 66]$ & Cinsiyet=Erkek & Ağrı Tipi $\neq$ abnang & Kan basıncı ≥ 111 & Kan Şekeri $>120=1$ & Elektrokard $\neq$ hyper & Nabız ≥ 95 & ST depr $\in [0.2, 2.1]$ & Eğim $\neq$ düz & Damar Sayısı ≤ 1 & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 1

16. Eğer Yaş ≤ 41 & Ağrı Tipi $\neq$ abnang & Kan basıncı ≤ 144 & Nabız ≥ 128 & Egzersiz=0 & ST depr ≤ 3.5 & Eğim $\neq$ düz & Damar Sayısı $\neq 2$ & Thal=norm O Halde Sınıf 1

17. Eğer Yaş $\in [38, 64]$ & Cinsiyet=Erkek & Ağrı Tipi $\neq$ asympt & Kan basıncı ≤ 143 & Kolesterol ≤ 221 & Elektrokard $\neq$ abn & Nabız $\in [85, 172]$ & Egzersiz=0 & ST depr ≤ 4 & Damar Sayısı=0 & Thal=Düzelebilir Kusur O Halde Sınıf 1

18. Eğer Yaş ≥ 47 & (Ağrı Tipi=asympt veya Ağrı Tipi=abnang) & Kan basıncı ≥ 112 & Kolesterol ≥ 224 & Elektrokard=hyper & Nabız $\in [90, 150]$ & ST depr $\in [0.2, 3.1]$ & Eğim=yukarı & Damar Sayısı $\neq 3$ & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

19. Eğer Yaş ≥ 49 & Cinsiyet=Kadın & (Ağrı Tipi=anjin veya Ağrı Tipi=abnang) & basıncı ≤ 142 & Kolesterol ≥ 196 & Kan Şekeri $>120=0$ & Elektrokard $\neq$ abn & Nabız ≤ 173 & ST depr $\in [0.1, 3.7]$ & Damar Sayısı $\neq 3$ O Halde Sınıf 1

20. Eğer Yaş ≤ 68 & Cinsiyet=Erkek & (Ağrı Tipi=anjin veya Ağrı Tipi=notang) & Kan basıncı ≥ 112 & Elektrokard=norm & Nabız ≥ 136 & ST depr $\in [0.8, 3.3]$ & Damar Sayısı $\neq 3$ & Thal $\neq$ norm O Halde Sınıf 1

21. Eğer Yaş ≥ 49 & Cinsiyet=Kadın & Ağrı Tipi $\neq$ abnang & Kan basıncı $\in [100, 130]$ & Elektrokard=hyper & Nabız $\in [74, 170]$ & Egzersiz=0 & ST depr ≤ 3.5 & Damar Sayısı=1 O Halde Sınıf 1

22. Eğer Yaş ≤ 65 & Cinsiyet=Kadın & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan basıncı ≤ 146 & Kolesterol $\in [190, 250]$ & Kan Şekeri $>120=0$ & Elektrokard=hyper & Nabız ≥ 131 & ST depr ≤ 3.6 & (Damar Sayısı=0 veya Damar Sayısı=2) O Halde Sınıf 1

23. Eğer Yaş $\in [41, 63]$ & Cinsiyet=Kadın & (Ağrı Tipi=asympt veya Ağrı Tipi=notang) & Kan Şekeri $>120=0$ & Elektrokard=hyper & Nabız $\in [91, 175]$ & Egzersiz=0 & ST depr ≤ 2.2 & Damar Sayısı $\neq 3$ O Halde Sınıf 1

24. Eğer Yaş ≥ 50 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ asympt & Kan basıncı ≥ 110 & Kolesterol $\in [194, 245]$ & Kan Şekeri $>120=1$ & Elektrokard=hyper & Nabız ≤ 181 & Egzersiz=0 & ST depr $\in [0.1, 3]$ & Damar Sayısı ≤ 2 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

25. Eğer Yaş ≤ 50 & Cinsiyet=Erkek & Ağrı Tipi $\neq$ abnang & Kan basıncı ≥ 111 & Kolesterol $\in [190, 250]$ & Nabız $\in [73, 179]$ & Egzersiz=0 & ST depr $\in [0.3, 3.5]$ & Eğim $\neq$ düz & Damar Sayısı ≤ 2 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

26. Eğer Yaş ≤ 66 & Ağrı Tipi $\neq$ abnang & Kan basıncı ≤ 146 & Kolesterol $\in [190, 250]$ & Kan Şekeri $>120=1$ & Nabız ≤ 179 & Egzersiz=0 & ST depr ≤ 3.3 & Eğim=yukarı & Damar Sayısı $\neq 2$ O Halde Sınıf 1

27. Eğer Yaş ≥ 48 & Kan basıncı ≤ 145 & Kolesterol ≤ 230 & Kan Şekeri $>120=0$ & Nabız $\in [74, 152]$ & ST depr ≤ 1 & Eğim=yukarı & Damar Sayısı=0 & Thal $\neq$ norm O Halde Sınıf 1

28. Eğer Yaş $\in [42, 62]$ & Ağrı Tipi=notang & Kan basıncı ≥ 112 & Kan Şekeri $>120=1$ & Nabız ≤ 174 & ST depr $\in [0.6, 3]$ & Eğim $\neq$ yukarı & Damar Sayısı=0 & Thal $\neq$ Kalıcı Kusur O Halde Sınıf 1

29. Eğer Yaş ≤ 48 & (Ağrı Tipi=notang & Ağrı Tipi=abnang) & Kan basıncı ≤ 145 & Elektrokard $\neq$ norm & Nabız ≤ 180 & Egzersiz=0 & ST depr ≤ 1 & Damar Sayısı $\neq 2$ Thal=norm O Halde Sınıf 1

30. Eğer Yaş ≤ 64 & Ağrı Tipi=notang & Kan basıncı ≤ 136 & Kan Şekeri $>120=1$ & Elektrokard=norm & Nabız ≤ 177 & Egzersiz=0 & ST depr ≤ 3.3 & Damar Sayısı=2 & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

31. Eğer Yaş ≤ 68 & Cinsiyet=Kadın & (Ağrı Tipi=anjin & Ağrı Tipi=notang) & Kan basıncı ≤ 147 & Elektrokard $\neq$ abn & Nabız $\in [96, 171]$ & ST depr ≤ 2 & Eğim $\neq$ aşağı & (Damar Sayısı=1 veya Damar Sayısı=2) & Thal=norm O Halde Sınıf 1

32. Eğer Yaş ≤ 65 & (Ağrı Tipi=anjin & Ağrı Tipi=notang) & Kan basıncı ≥ 110 & Kolesterol $\in [190, 250]$ & Elektrokard $\neq$ norm & Nabız ≤ 176 & Egzersiz=0 & ST depr $\in [0.2, 3.3]$ & Eğim $\neq$ aşağı & Damar Sayısı=0 & Thal $\neq$ norm O Halde Sınıf 1

33. Eğer Yaş ≥ 49 & Cinsiyet=Kadın & Ağrı Tipi $\neq$ asympt & Kan basıncı $\in [105, 146]$ & Elektrokard $\neq$ hyper & Nabız ≤ 172 & Egzersiz=0 & ST depr ≤ 3.7 & Eğim $\neq$ yukarı & Damar Sayısı $\neq 3$ & Thal=norm O Halde Sınıf 1

34. Eğer Yaş $\in [38, 66]$ & Cinsiyet=Erkek & Ağrı Tipi $\neq$ asympt & Kan basıncı ≥ 107 & Kan Şekeri $>120=0$ & Elektrokard=hyper & Nabız ≤ 183 & ST depr ≥ 2.1 & Damar Sayısı=0 & Thal=Düzelebilir Kusur O Halde Sınıf 1

35. Eğer Yaş ≤ 67 & Kan basıncı ≤ 143 & Elektrokard=hyper & Nabız ≥ 140 & Egzersiz=1 & ST depr ≤ 3.6 & Eğim=yukarı & Damar Sayısı $\neq 1$ & Thal $\neq$ Düzelebilir Kusur O Halde Sınıf 1

36. Eğer Yaş $\in [40, 65]$ & Kan basıncı ≤ 143 & Kolesterol ≤ 230 & Kan Şekeri $>120=0$ & Elektrokard $\neq \text{abn}$ & Nabız ≥ 134 & Egzersiz $=0$ & ST depr ≤ 2.1 & (Damar Sayısı $=0$ veya Damar Sayısı $=2$) & Thal=Kalıcı Kusur O Halde Sınıf 1

37. Eğer Yaş $\in [41, 65]$ & (Ağrı Tipi=asympt & Ağrı Tipi=notang) & Kan basıncı $\in [103, 146]$ & Kolesterol $\in [197, 232]$ & Kan Şekeri $>120=0$ & Elektrokard=norm & Nabız ≥ 135 & Egzersiz $=0$ & ST depr ≤ 2.3 & Eğim $\neq \text{yukarı}$ & Damar Sayısı ≥ 2 & Thal $\neq \text{norm}$ O Halde Sınıf 1

38. Eğer Yaş ≥ 49 & (Ağrı Tipi=asympt & Ağrı Tipi=notang) & Kan basıncı $\in [109, 143]$ & Kan Şekeri $>120=0$ & Elektrokard=hyper & Nabız ≤ 171 & ST depr $\in [0.1, 2.1]$ & (Damar Sayısı $=0$ veya Damar Sayısı $=2$) & Thal=norm O Halde Sınıf 1

39. Eğer Yaş ≥ 47 & Cinsiyet=Kadın & Ağrı Tipi $\neq \text{asympt}$ & Kan basıncı ≥ 107 & Elektrokard=norm & Nabız ≥ 130 & Egzersiz $=0$ & ST depr ≤ 1 & Eğim=yukarı & Damar Sayısı $\neq 0$ & Thal=norm O Halde Sınıf 1

40. Eğer Yaş ≤ 51 & Cinsiyet=Erkek & Ağrı Tipi $\neq \text{asympt}$ & Kan basıncı ≤ 122 & Kan Şekeri $>120=0$ & Elektrokard=norm & Nabız ≤ 183 & ST depr ≤ 4 & Eğim=yukarı & (Damar Sayısı $=0$ veya Damar Sayısı $=2$) & Thal= Düzenebilir Kusur O Halde Sınıf 1

Çizelge 5.10 Cleveland Kalp Hastalıkları veri kümesi için önerilen yöntem ve diğer kural çıkarma algoritmalarının sınıflandırma başarıları
(internet: Logical rules extracted from data,
<http://www.fizyka.umk.pl/kmk/projects/rules.html>, Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	96,4	
C-MLP2LN	82.5	RA
FSM	82.2	Rafał Adamczak

Cleveland Kalp Hastalıkları veri kümesinde kural çıkarma ile ilgili yapılan iki çalışma sonucu rapor edilmektedir. Rapor edilen başarı %82.2 ve %82.5'dir (internet: Logical rules extracted from data,


<http://www.fizyka.umk.pl/kmk/projects/rules.html>, Mart, 2008) . Bu tezde önerilen yöntemin başarısı %96.4'tür. Çizelge 5.10'da yöntemin Cleveland Kalp Hastalıkları veri kümesi için başarısı diğer yöntemlerle karşılaştırmalı olarak görülmektedir.

Çizelge 5.10'dan görüldüğü üzere önerilen sınıflandırma+kural çıkarma algoritması sonucu oluşan kurallar yüksek bir oranda teşhis başarısına ulaşmıştır.

5.2. Hepatit Veri Kümesinde Uygulama

Hepatit veri kümesi için sinir ağından kural çıkarmak amacıyla aynı sinir ağı tüm verilerle bir daha eğitilmiştir. Ağın YSA1 kısmı 4, BSA kısmı 5 gizli nörondan oluşmaktadır. Bu değerler en iyi sonucu üretmek için deneysel olarak tespit edilmiştir. Bu eğitim sonucunda ağ 155 verinin hepsini öğrenmiştir. Oluşan hata grafiği Şekil 5.3'de görülmektedir.

Eđitim yapıldıktan sonra ađırlıklar ve eřik deđerleri iin bulunan deđerler izelge 5.11- 5.17’da grlmektedir.



řekil 5.3 Hepatit veri kmesi iin tm verilerle eđitim sonucu oluřan hata fonksiyonu

Çizelge 5.11 YSA1 ağı için giriş katmanı ile ara katman arasındaki w ağırlık matrisi

		YSA1 ara katman nöronları			
YSA1 giriş katmanı nöronları		1. nöron	2. nöron	3. nöron	4. nöron
	1. nöron	-0,5471	-0,6665	-0,6665	-0,7794
	2. nöron	0,4763	0,608	0,608	0,7181
	3. nöron	-0,3215	-0,4023	-0,4023	0,2418
	4. nöron	0,2508	0,3438	0,3438	-0,3031
	5. nöron	0,3164	0,0482	0,0482	-0,2547
	6. nöron	-0,3872	-0,1067	-0,1067	0,1935
	7. nöron	-0,0324	-0,1923	-0,1923	0,8065
	8. nöron	-0,0384	0,1338	0,1338	-0,8678
	9. nöron	-1,0388	-0,1065	-0,1065	0,6507
	10. nöron	0,9681	0,048	0,048	-0,712
	11. nöron	0,3158	-0,2142	-0,2142	1,6629
	12. nöron	-0,3865	0,1557	0,1557	-1,7241
	13. nöron	0,4455	0,0177	0,0177	0,3328
	14. nöron	-0,5163	-0,0762	-0,0762	-0,3941
	15. nöron	-0,9232	0,2081	0,2081	0,2394
	16. nöron	0,8524	-0,2666	-0,2666	-0,3006
	17. nöron	-0,5955	-0,0977	-0,0977	-0,2448
	18. nöron	0,5247	0,0392	0,0392	0,1835
	19. nöron	-1,8682	0,1888	0,1888	0,3499
	20. nöron	1,7974	-0,2473	-0,2473	-0,4112
	21. nöron	0,2946	-1,031	-1,031	-0,1679
	22. nöron	-0,3654	0,9725	0,9725	0,1066
	23. nöron	-0,1975	0,2996	0,2996	-0,1395
	24. nöron	0,1267	-0,3581	-0,3581	0,0783
	25. nöron	0,7149	0,2686	0,2686	-1,2021
	26. nöron	-0,7857	-0,3271	-0,3271	1,1408

Çizelge 5.12 BSA ağı için giriş katmanı ile ara katman arasındaki wb ağırlık matrisi

		BSA ara katman nöronları				
		1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
BSA giriş katmanı nöronları	1. nöron	0,1477	-0,1648	3,1744	0,1477	-0,1648
	2. nöron	0,1383	-0,4381	0,182	0,1383	-0,4381
	3. nöron	0,3862	0,4772	0,0638	0,3862	0,4772
	4. nöron	0,2101	-0,0299	2,4754	0,2101	-0,0299
	5. nöron	0,2533	0,1913	-0,5679	0,2533	0,1913
	6. nöron	0,3608	0,1058	-3,0565	0,3608	0,1058
	7. nöron	0,2287	0,1831	-0,2688	0,2287	0,1831
	8. nöron	0,2955	-0,1158	-0,6803	0,2955	-0,1158
	9. nöron	0,3484	0,3702	-0,7979	0,3484	0,3702
	10. nöron	0,1758	-0,3029	-0,1511	0,1758	-0,3029
	11. nöron	0,1379	-0,4163	-0,4496	0,1379	-0,4163
	12. nöron	0,3861	0,4834	-0,4998	0,3861	0,4834
	13. nöron	0,3002	0,2002	-0,1996	0,3002	0,2002
	14. nöron	0,2766	0,1419	0,5477	0,2766	0,1419
	15. nöron	0,2938	0,1487	-2,2486	0,2938	0,1487
	16. nöron	0,1671	-0,3058	1,3264	0,1671	-0,3058

Çizelge 5.13 YSA1 ağı gizli katman nöronlarının θ eşik değerleri vektörü

YSA1 ara katman nöronları			
1. nöron	2. nöron	3. nöron	4. nöron
-1,0708	-0,05849	-0,05849	0,93872

Çizelge 5.14 YSA1 ağı için ara katman ile çıkış katmanı arasındaki v ağırlıklar vektörü

YSA1 ara katman nöronları			
1. nöron	2. nöron	3. nöron	4. nöron
-3,2124	-1,4574	-1,4574	-2,0315

Çizelge 5.15 BSA ağı gizli katman nöronlarının θb eşik değerleri vektörü

BSA ara katman nöronları				
1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
0,9242	0,6673	0,452	0,9242	0,6673

Çizelge 5.16 BSA ağı için gizli katman ile çıkış katmanı arasındaki vb ağırlıklar vektörü

BSA ara katman nöronları				
1. nöron	2. nöron	3. nöron	4. nöron	5. nöron
0,2087	0,9034	-4,6406	0,2087	0,9034

Çizelge 5.17 YSA2 ağı için YSA1 ve BSA ağı çıkışları ile genel çıkış nöronu arasındaki ww ağırlıklar vektörü

YSA2 nöronları	
1. nöron	2. nöron
2,137	1,0835

YSA1 ağı için çıkış nöronunun eşik değeri $\zeta = 1,5719$, BSA ağı için çıkış nöronunun eşik değeri $\zeta b = -0,5715$ ve ağın genel çıkışı için eşik değeri ise $\zeta = -1,3191$ olarak bulunmuştur.

Eğitim işleminin sonucunda ağın genel çıkışı için (2.15)'i de kullanarak aşağıdaki gibi bir fonksiyon elde edilmiştir.

$$C(Y) = \left[1 + e^{\left[-ww_1 \left(\frac{-\sum_{j=1}^4 v_j^* \frac{1}{26} - \sum_{i=1}^{26} w_{ij} x_i + \theta_j}{1+e} \right) + \zeta \right]^{-1} + ww_2 \left(\frac{-\sum_{j=1}^5 v b_j^* \frac{1}{16} - \sum_{i=1}^{16} w b_{ij} x b_i + \theta b_j}{1+e} \right) + \zeta b \right]^{-1} + \zeta \right]^{-1} \quad (5.2)$$

Bulunan $C(Y)$ fonksiyonu optimize edilmiştir. Optimizasyon için Opt-aiNET algoritması kullanılmıştır. Optimizasyon sonucu $C(Y)$ fonksiyonunu 0 yapan antikorların kodu çözülerek “0” sınıfı, $C(Y)$ fonksiyonunu “1” yapan antikorların kodu çözülerek “1” sınıfı oluşturulmuştur. Çözüm antikorları 26 ikili ve 16 gerçel sayıdan oluşmaktadır. Çözüm antikorlarının kodunu çözüp anlaşılır hale getirmek için Bölüm 4.3’te anlatılan yöntem uygulanmıştır. Sonuç olarak 0 sınıfı

için 45, 1 sınıfı için 22 kural elde edilmiştir. Elde edilen kurallar Çizelge 5.18 ve Çizelge 5.19’da görülmektedir.

Çizelge 5.18 Hepatit veri tabanı Sınıf 0 için kurallar

No	Kurallar
1.	Eğer Yaş $\in [13, 67]$ & Cinsiyet=Erkek & İştahsızlık=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 121 & SGOT ≥ 35 & Albumin $\in [3, 6]$ & Pro_time ≥ 13 & Histoloji=Hayır O Halde Sınıf 0
2.	Eğer Yaş $\in [16, 67]$ & Cinsiyet=Erkek & İştahsızlık=Evet & Ben=Evet & Bilirubin ≤ 2 & Alkal_fosfat $\in [65, 112]$ & SGOT ≤ 58 & Albumin $\in [3, 5]$ & Pro_time ≥ 29 O Halde Sınıf 0
3.	Eğer Yaş $\in [19, 67]$ & Steroid=Hayır & Antiviral=Evet & Ben=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat $\in [70, 117]$ & Albumin $\in [3, 6]$ & Pro_time ≥ 28 & Histoloji=Hayır O Halde Sınıf 0
4.	Eğer Yaş $\in [9, 58]$ & Kırıklık=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 115 & Albumin $\in [3, 6]$ & Pro_time ≥ 24 & Histoloji=Evet O Halde Sınıf 0

5. Eğer Yaş $\in [36, 72]$ & Cinsiyet=Erkek & Karaciğer_Sert=Hayır & Ben=Hayır & Asit=Evet & Bilirubin ≤ 1 & Alkal_fosfat $\in [63, 115]$ & SGOT ≤ 57 & Albumin $\in [3, 6]$ & Pro_time ≤ 68 O Halde Sınıf 0
6. Eğer Yaş ≤ 45 & Halsizlik=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert= Evet & Ben= Evet & Bilirubin ≤ 1 & Alkal_fosfat ≤ 117 & SGOT ≤ 53 & Albumin ≤ 6 & Pro_time ≥ 21 & Histoloji=Hayır O Halde Sınıf 0
7. Eğer Yaş $\in [20, 67]$ & Cinsiyet=Kadın & Steroid=Evet & Halsizlik=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 75 & Albumin ≤ 4 & Pro_time $\in [17, 62]$ & Histoloji=Hayır O Halde Sınıf 0
8. Eğer Yaş $\in [20, 70]$ & Steroid=Hayır & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Ben=Hayır & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 68 & SGOT ≥ 17 & Albumin $\in [3, 6]$ & Pro_time ≤ 67 O Halde Sınıf 0
9. Eğer Yaş $\in [37, 70]$ & Antiviral=Evet & İştahsızlık=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Ben=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 67 & SGOT ≥ 16 & Albumin $\in [3, 6]$ & Pro_time ≤ 68 & Histoloji=Evet O Halde Sınıf 0
10. Eğer Yaş $\in [17, 54]$ & Cinsiyet=Erkek & Antiviral=Evet & Halsizlik=Hayır & Karaciğer_Sert=Hayır & Asit=Evet & Bilirubin ≤ 1 &

Alkal_fosfat ≥ 75 & SGOT ≥ 17 & Albumin $\in [3, 6]$ & Pro_time ≥ 25 & Histoloji=Evet O Halde Sınıf 0

11. Eğer Yaş $\in [35, 55]$ & Antiviral=Evet & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Ben=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 74 & SGOT ≤ 59 & Albumin $\in [3, 6]$ & Pro_time ≥ 15 O Halde Sınıf 0

12. Eğer Yaş $\in [14, 72]$ & Steroid=Evet & Halsizlik=Hayır & Kırıklık=Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Ben=Evet & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 76 & SGOT ≤ 61 & Albumin $\in [3, 5]$ & Pro_time $\in [18, 61]$ O Halde Sınıf 0

13. Eğer Yaş $\in [10, 71]$ & Cinsiyet=Erkek & Antiviral=Evet & Kırıklık=Evet & İştahsızlık=Evet & Ben=Hayır & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 75 & Albumin ≤ 4 & Pro_time ≥ 28 & Histoloji= Evet O Halde Sınıf 0

14. Eğer Yaş $\in [17, 69]$ & Steroid=Hayır & Antiviral=Evet & Halsizlik=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 70 & Albumin ≤ 4 & Pro_time ≥ 30 & Histoloji= Evet O Halde Sınıf 0

15. Eğer Yaş $\in [36, 70]$ & İştahsızlık=Evet & Karaciğer_Büyü=Hayır & Karaciğer_Sert=Hayır & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 &

Alkal_fosfat ≥ 75 & SGOT ≤ 57 & Albumin $\in [3, 4]$ & Pro_time ≥ 19 O Halde Sınıf 0

16. Eğer Yaş ≤ 52 & Cinsiyet=Erkek & Antiviral=Evet & Halsizlik= Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Dalak_Palhablı=Evet & Ben=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 119 & Albumin ≤ 4 & Pro_time ≤ 59 O Halde Sınıf 0

17. Eğer Yaş $\in [11, 55]$ & Cinsiyet=Kadın & Steroid=Hayır & Halsizlik=Evet & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Ben=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≤ 105 & SGOT ≥ 15 & Albumin $\in [3, 6]$ & Pro_time ≥ 22 & Histoloji=Hayır O Halde Sınıf 0

18. Eğer Yaş $\in [11, 68]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert= Evet & Ben=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 72 & Albumin $\in [3, 5]$ & Pro_time ≥ 18 & Histoloji= Hayır O Halde Sınıf 0

19. Eğer Yaş $\in [10, 68]$ & Steroid=Hayır & Kırıklık=Evet & İştahsızlık= Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Asit=Evet & Bilirubin ≤ 1 & Alkal_fosfat $\in [62, 120]$ & SGOT ≥ 17 & Albumin $\in [3, 6]$ & Pro_time ≤ 67 & Histoloji= Hayır O Halde Sınıf 0

20. Eğer Yaş $\in [19, 70]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Halsizlik=Hayır & İştahsızlık=Hayır & Dalak_Palhablı=Hayır & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 90 & Albumin $\in [3, 6]$ & Pro_time ≥ 21 & Histoloji= Hayır O Halde Sınıf 0

21. Eğer Yaş $\in [16, 70]$ & Antiviral=Hayır & Halsizlik=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 113 & SGOT ≥ 16 & Albumin ≤ 4 & Pro_time ≥ 17 & Histoloji= Hayır O Halde Sınıf 0

22. Eğer Yaş ≥ 46 & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Kırıklık=Evet & Dalak_Palhablı=Evet & Ben=Evet & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 110 & SGOT ≤ 61 & Albumin $\in [3, 6]$ & Pro_time ≤ 67 O Halde Sınıf 0

23. Eğer Yaş $\in [16, 70]$ & Cinsiyet=Kadın & Halsizlik=Evet & Kırıklık=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Hayır & Ben=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 65 & SGOT ≤ 57 & Albumin $\in [3, 6]$ & Pro_time $\in [20, 64]$ O Halde Sınıf 0

24. Eğer Yaş ≤ 57 & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Büyü=Hayır & Karaciğer_Sert=Hayır & Asit=Evet & Varis=Evet & Bilirubin ≥ 2 & SGOT ≥ 17 & Albumin $\in [3, 6]$ & Pro_time ≥ 15 & Histoloji= Hayır O Halde Sınıf 0

25. Eğer Yaş $\in [11, 69]$ & Cinsiyet= Erkek & Halsizlik=Hayır & Kırıklık= Hayır & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Hayır & Asit=Hayır & Bilirubin ≤ 1 & Alkal_fosfat ≥ 69 & SGOT ≤ 55 & Albumin ≤ 4 & Pro_time ≥ 19 & Histoloji= Evet O Halde Sınıf 0

26. Eğer Yaş $\in [16, 73]$ & Cinsiyet=Erkek & Steroid=Evet & Halsizlik= Evet & Kırıklık=Evet & İştahsızlık=Evet & Dalak_Palhablı=Evet & Varis=Evet &

Bilirubin ≥ 2 & Alkal_fosfat ≤ 109 & SGOT ≤ 60 & Albumin $\in [3.7, 5.5]$ & Pro_time ≥ 28 & Histoloji= Hayır O Halde Sınıf 0

27. Eğer Yaş $\in [19, 69]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Hayır & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 62 & Albumin $\in [3.7, 5.5]$ & Pro_time ≥ 20 & Histoloji=Hayır O Halde Sınıf 0

28. Eğer Yaş ≤ 38 & Steroid=Evet & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Asit=Evet & Varis=Hayır & Bilirubin ≥ 2 & Alkal_fosfat ≥ 72 & SGOT ≤ 58 & Albumin $\in [3, 6]$ & Pro_time ≤ 60 & Histoloji= Hayır O Halde Sınıf 0

29. Eğer Yaş ≤ 42 & Cinsiyet=Erkek & Antiviral=Hayır & İştahsızlık=Hayır & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Evet & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 108 & Albumin $\in [3, 5]$ & Pro_time ≥ 17 & Histoloji=Evet O Halde Sınıf 0

30. Eğer Yaş $\in [19, 70]$ & Cinsiyet=Erkek & Steroid= Hayır & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Bilirubin ≥ 2 & Alkal_fosfat $\in [61, 122]$ & Albumin $\in [3, 5]$ & Pro_time ≥ 15 O Halde Sınıf 0

31. Eğer Yaş ≤ 68 & Cinsiyet=Erkek & Steroid=Hayır & Kırıklık=Hayır & Karaciğer_Sert=Hayır & Dalak_Palhablı=Hayır & Ben=Hayır & Varis=Hayır &

Bilirubin ≥ 2 & Alkal_fosfat ≥ 61 & SGOT ≥ 35 & Albumin $\in [3, 6]$ & Pro_time ≤ 61 O Halde Sınıf 0

32. Eğer Yaş $\in [9, 54]$ & Steroid=Evet & Antiviral=Evet & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Evet & Ben=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 68 & SGOT ≤ 61 & Albumin ≥ 5 & Pro_time ≥ 29 O Halde Sınıf 0

33. Eğer Yaş ≤ 56 & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & İştahsızlık=Hayır & Ben=Evet & Bilirubin ≥ 2 & Alkal_fosfat $\in [62, 117]$ & SGOT ≥ 15 & Albumin $\in [3.7, 5.5]$ & Pro_time ≥ 15 & Histoloji=Evet O Halde Sınıf 0

34. Eğer Yaş $\in [35, 55]$ & Cinsiyet=Erkek & Halsizlik=Evet & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Büyü=Hayır & Dalak_Palhablı=Evet & Asit=Evet & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 72 & SGOT ≥ 17 & Albumin $\in [3, 5]$ & Pro_time ≤ 68 & Histoloji=Evet O Halde Sınıf 0

35. Eğer Yaş ≤ 42 & Cinsiyet=Erkek & Antiviral=Evet & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Hayır & Ben=Evet & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 68 & Albumin $\in [3, 6]$ & Pro_time ≥ 30 & Histoloji=Evet O Halde Sınıf 0

36. Eğer Yaş ≥ 42 & Cinsiyet=Kadın & Steroid=Evet & Antiviral=Evet & Halsizlik=Hayır & İştahsızlık=Evet & Asit=Evet & Varis=Evet & Bilirubin ≥ 2 & Alkal_fosfat $\in [67, 119]$ & SGOT ≥ 16 & Albumin $\in [3, 6]$ & Pro_time ≥ 16 O Halde Sınıf 0

37. Eğer Yaş $\in [16, 67]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Kırıklık=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Evet & Asit=Evet & Varis=Evet & Bilirubin ≥ 2 & Alkal_fosfat $\in [65, 111]$ & SGOT ≤ 59 & Albumin $\in [3, 4]$ & Pro_time ≥ 22 & Histoloji=Evet O Halde Sınıf 0

38. Eğer Yaş $\in [14, 68]$ & Steroid=Hayır & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Hayır & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 64 & SGOT ≥ 16 & Albumin ≤ 4 & Pro_time ≤ 61 O Halde Sınıf 0

39. Eğer Yaş ≤ 43 & Steroid=Evet & Kırıklık=Hayır & Karaciğer_Büyü=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat $\in [61, 110]$ & SGOT ≥ 17 & Albumin $\in [3, 6]$ & Pro_time ≥ 24 & Histoloji=Evet O Halde Sınıf 0

40. Eğer Yaş ≤ 33 & Steroid=Evet & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Ben=Hayır & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 64 & SGOT ≤ 57 & Albumin $\in [3.7, 5.5]$ & Pro_time ≤ 67 O Halde Sınıf 0

41. Eğer Yaş $\in [11, 56]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 63 & SGOT ≥ 16 & Albumin $\in [3, 4]$ & Pro_time ≥ 22 & Histoloji=Evet O Halde Sınıf 0

42. Eğer Yaş $\in [15, 53]$ & Cinsiyet=Erkek & Steroid=Evet & Halsizlik=Hayır & Karaciğer_Büyü=Hayır & Karaciğer_Sert=Hayır & Dalak_Palhablı=Hayır & Ben=Hayır & Asit=Hayır & Varis=Hayır & Bilirubin ≤ 2 & Alkal_fosfat ≥ 60 & SGOT ≥ 17 & Albumin $\in [3.7, 5.5]$ & Pro_time $\in [20, 58]$ & Histoloji=Evet O Halde Sınıf 0

43. Eğer Yaş $\in [37, 70]$ & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 60 & Albumin $\in [3, 6]$ & Pro_time ≥ 19 & Histoloji=Evet O Halde Sınıf 0

44. Eğer Yaş $\in [11, 72]$ & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & Karaciğer_Büyü=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 68 & Albumin ≤ 4 & Pro_time ≤ 67 O Halde Sınıf 0

45. Eğer Yaş $\in [17, 72]$ & Cinsiyet=Kadın & Steroid=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 109 & SGOT ≤ 60 & Albumin $\in [3, 6]$ & Pro_time ≤ 58 & Histoloji=Evet O Halde Sınıf 0

Çizelge 5.19 Hepatit veri tabanı Sınıf 1 için kurallar

No	Kurallar
1.	Eğer Yaş $\in [19, 70]$ & Cinsiyet=Erkek & Antiviral=Evet & Halsizlik=Hayır & Asit=Hayır & Bilirubin ≤ 2 & Alkal_fosfat ≥ 64 & SGOT ≤ 54 & Albumin ≤ 5 & Pro_time ≤ 66 & Histoloji=Evet O Halde Sınıf 1
2.	Eğer Yaş $\in [12, 68]$ & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Bilirubin ≥ 2 & Alkal_fosfat ≥ 64 & SGOT ≥ 16 & Albumin ≤ 3.8 & Pro_time ≤ 51 & Histoloji=Evet O Halde Sınıf 1
3.	Eğer Yaş $\in [11, 70]$ & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Ben=Hayır & Bilirubin ≤ 2 & Alkal_fosfat ≤ 117 & SGOT ≥ 16 & Albumin ≤ 4 & Pro_time ≤ 49 O Halde Sınıf 1
4.	Eğer Yaş $\in [35, 69]$ & Cinsiyet=Erkek & Kırıklık=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Hayır & Ben=Hayır & Asit=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 68 & Albumin $\in [3, 6]$ & Pro_time ≤ 48 & Histoloji=Evet O Halde Sınıf 1
5.	Eğer Yaş $\in [35, 55]$ & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Hayır & Ben=Hayır & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 71 & Albumin ≤ 4 & Pro_time $\in [20, 59]$ & Histoloji=Evet O Halde Sınıf 1

6. Eğer Yaş $\in [8, 69]$ & Cinsiyet=Erkek & Steroid=Hayır & Kırıklık=Hayır & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Varis=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≤ 104 & Albumin $\in [3, 5]$ & Pro_time ≤ 49 & Histoloji=Evet O Halde Sınıf 1

7. Eğer Yaş $\in [14, 67]$ & Antiviral=Evet & Halsizlik=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Varis=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≤ 110 & SGOT ≥ 15 & Albumin $\in [3, 6]$ & Pro_time ≤ 51 O Halde Sınıf 1

8. Eğer Yaş $\in [34, 72]$ & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & Karaciğer_Büyü=Evet & Bilirubin ≤ 2 & Alkal_fosfat ≥ 73 & SGOT ≤ 60 & Albumin $\in [3, 6]$ & Pro_time $\in [10, 50]$ O Halde Sınıf 1

9. Eğer Yaş ≥ 43 & Cinsiyet=Erkek & Steroid=Hayır & İştahsızlık= Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Ben=Hayır & Varis=Evet & Bilirubin ≥ 2 & Alkal_fosfat ≥ 70 & SGOT ≥ 16 & Albumin ≤ 3.8 & Pro_time $\in [10, 50]$ O Halde Sınıf 1

10. Eğer Yaş ≤ 39 & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Hayır & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Varis=Evet & Bilirubin ≥ 2 & Alkal_fosfat ≥ 68 & Albumin $\in [3, 4]$ & Pro_time ≤ 61 & Histoloji=Hayır O Halde Sınıf 1

11. Eğer Yaş $\in [18, 68]$ & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Evet & Karaciğer_Büyü=Hayır

& Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Asit=Evet & Varis=Evet & Bilirubin ≥ 2 & Alkal_fosfat ≥ 63 & Albumin $\in [3, 4]$ & Pro_time ≤ 48 O Halde Sınıf 1

12. Eğer Yaş ≥ 46 & Cinsiyet=Erkek & Steroid=Evet & Halsizlik=Hayır & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Asit=Evet & Bilirubin=2 & Alkal_fosfat ≥ 70 & SGOT ≥ 15 & Albumin $\in [3, 6]$ & Pro_time $\in [15, 64]$ & Histoloji=Hayır O Halde Sınıf 1

13. Eğer Yaş ≤ 35 & Kırıklık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert= Hayır & Dalak_Palhablı= Evet & Ben=Hayır & Asit= Hayır & Bilirubin ≥ 2 & Alkal_fosfat ≥ 70 & SGOT ≥ 16 & Albumin ≤ 4 & Pro_time $\in [15, 61]$ & Histoloji=Evet O Halde Sınıf 1

14. Eğer Yaş ≥ 41 & Cinsiyet=Erkek & Antiviral=Evet & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Dalak_Palhablı=Hayır & Bilirubin ≥ 2 & Alkal_fosfat ≥ 70 & SGOT ≤ 61 & Albumin $\in [3, 6]$ & Pro_time ≤ 45 & Histoloji=Evet O Halde Sınıf 1

15. Eğer Yaş $\in [18, 70]$ & Cinsiyet=Erkek & Steroid=Hayır & Antiviral=Evet & Kırıklık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Hayır & Ben=Hayır & Asit=Hayır & Bilirubin ≥ 2 & Alkal_fosfat ≥ 71 & Albumin ≤ 4 & Pro_time ≤ 43 O Halde Sınıf 1

16. Eğer Yaş $\in [37, 70]$ & Cinsiyet=Erkek & İştahsızlık= Hayır & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Ben=Hayır & Varis=Evet &

Bilirubin ≥ 2 & Alkal_fosfat ≤ 111 & SGOT ≥ 35 & Albumin $\in [3, 4]$ & Pro_time $\in [14, 59]$ & Histoloji=Evet O Halde Sınıf 1

17. Eğer Yaş $\in [37, 72]$ & Cinsiyet=Erkek & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Evet & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Bilirubin ≥ 2 & Alkal_fosfat ≥ 68 & Albumin ≤ 3.8 & Pro_time ≥ 22 & Histoloji=Evet O Halde Sınıf 1

18. Eğer Yaş ≤ 44 & Cinsiyet=Erkek & Halsizlik=Evet & İştahsızlık=Evet & Karaciğer_Sert=Hayır & Dalak_Palhablı=Evet & Bilirubin ≤ 1 & Alkal_fosfat ≥ 69 & SGOT ≤ 59 & Albumin $\in [3, 6]$ & Pro_time ≥ 25 & Histoloji=Evet O Halde Sınıf 1

19. Eğer Yaş $\in [35, 55]$ & Antiviral=Evet & Halsizlik=Hayır & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Sert=Evet & Ben=Hayır & Asit=Hayır & Bilirubin ≤ 2 & Alkal_fosfat ≥ 71 & Albumin ≤ 4 & Pro_time $\in [10, 50]$ O Halde Sınıf 1

20. Eğer Yaş $\in [35, 55]$ & Antiviral=Evet & Halsizlik=Hayır & İştahsızlık=Evet & Dalak_Palhablı=Hayır & Ben=Hayır & Bilirubin ≥ 2 & Alkal_fosfat $\in [26, 114]$ & SGOT ≥ 17 & Albumin $\in [3, 4]$ & Pro_time ≤ 44 O Halde Sınıf 1

21. Eğer Yaş $\in [18, 71]$ & Cinsiyet=Erkek & Steroid=Evet & Antiviral=Evet & Kırıklık=Hayır & İştahsızlık=Hayır & Karaciğer_Büyü=Evet & Karaciğer_Sert=Evet & Ben=Hayır & Asit=Hayır & Varis=Hayır & Bilirubin ≥ 2 &

Alkal_fosfat ≥ 68 & Albumin $\in [3, 6]$ & Pro_time ≤ 52 & Histoloji= Evet O Halde Sınıf 1

22. Eğer Yaş $\in [35, 55]$ & Cinsiyet=Erkek & Steroid=Evet & Halsizlik=Evet & İştahsızlık=Evet & Karaciğer_Büyü=Evet & Dalak_Palhablı=Evet & Ben=Hayır & Asit=Evet & Varis=Hayır & Bilirubin ≤ 2 & Alkal_fosfat ≥ 75 & SGOT ≤ 53 & Albumin $\in [3, 6]$ & Pro_time ≤ 68 & Histoloji= Evet O Halde Sınıf 1

Çizelge 5.20 Hepatit veri kümesi için önerilen yöntem ve diğer kural çıkarma algoritmalarının sınıflandırma başarıları
(internet: Logical rules extracted from data,
<http://www.fizyka.umk.pl/kmk/projects/rules.html>, Mart, 2008)

Yöntem	Başarı %	Referans
Önerilen Yöntem	96.8	
C-MLP2LN	96.1	http://www.fizyka.umk.pl
FSM	90	http://www.fizyka.umk.pl
CART (decision tree)	82.7	http://www.fizyka.umk.pl

Hepatit veri kümesinde kural çıkarma ile ilgili yapılan üç çalışma sonucu rapor edilmektedir. Rapor edilen başarı %82.7, %90 ve %96.1.'dir (internet: (Logical rules extracted from data, <http://www.fizyka.umk.pl/kmk/projects/rules.html>, Mart, 2008). Bu tezde önerilen yöntemin başarıları %96.8'dir. Çizelge 5.20'de önerilen yöntemin başarıları diğer yöntemlerle karşılaştırmalı olarak görülmektedir.

Çizelge 5.20’den görüldüğü üzere önerilen “sınıflandırma”+”kural” çıkarma algoritması sonucu oluşan kurallar yüksek bir oranda teşhis başarısına ulaşmıştır.

5.3. Bölüm Değerlendirilmesi

Bu bölümde, bir önceki bölümde önerilen hibrit bulanık sinir ağından kural çıkarma yöntemi Cleveland Kalp Hastalıkları ve Hepatit Hastalığı veri kümelerine uygulanmış ve başarısı incelenmektedir. Önce verilerin tamamı kullanılarak eğitim yapılmaktadır. Bu işlemin sonucu olarak Cleveland Kalp Hastalıkları veri kümesinde %99, Hepatit veri kümesinde %100 başarı elde edilmektedir. Daha sonra eğitilen ağın oluşturduğu fonksiyon elde edilmektedir. Oluşturulan fonksiyon minimize edilerek 0 sınıfının kuralları, maksimize edilerek 1 sınıfının kuralları oluşturulmuştur. Bu işlemin sonucu olarak Cleveland Kalp Hastalıkları veri kümesinde %96.4, Hepatit veri kümesinde %96.8 başarı elde edilmiştir. Elde edilen oranlar literatürle karşılaştırıldığında önerilen kural çıkarma algoritmasının başarılı olduğu görülmektedir.

6. SONUÇ VE ÖNERİLER

6.1. Sonuçlar

Örneklerden öğrenme zekanın önemli bir işlevi olup, son yıllarda istatistik, yapay zeka gibi alanlarda uğraşan araştırmacıların çok ilgisini çekmektedir. Örneklerden öğrenen tümevarımsal algoritmalar geliştirilerek gerçek dünya problemlerine uygulanmaktadırlar.

En yaygın kullanılan tümevarımsal öğrenme algoritmalarından biri yapay sinir ağlarıdır. YSA'lar sınıflandırma için sıklıkla kullanılmaktadır ve bir çok problemde yüksek başarı sergilemektedirler. Ancak YSA'lar elde ettiği bilgilerin anlaşılır olmamasından dolayı, kullanışlı olmamaktadırlar. Bu durum, anlaşılır kuralların önemli olduğu bir çok veri madenciliği problemlerinde sorun oluşturmaktadır. Bu nedenle YSA'dan kural çıkarmak için çeşitli yöntemler geliştirilmektedir.

Bu çalışmada iki problem üzerinde durulmuştur. Önce sınıflandırma için bir sinir ağı geliştirilmektedir, ikinci aşamada geliştirilen sinir ağından kural çıkarmak için bir yöntem önerilmektedir.

Önce sınıflandırma için hibrit bir ağ modeli önerilmektedir. Bugüne kadar yapılan çalışmalarda veriler genellikle ya ikili, ya da gerçel olarak kodlanmaktaydı. Gerçek dünya problemlerinde veriler genellikle hem ayrık hem de gerçel niteliklerden oluşmaktadır. Bu çalışmada ayrık nitelikler ikili olarak kodlanırken, gerçel nitelikler bulanıklaştırılmaktadır. YSA ve BSA'nın birleşiminden oluşan bir hibrit ağ oluşturularak kodlanmış veriler hibrit ağa sunulmaktadır. Eğitim algoritması olarak, Geri Yayılım kullanılmaktadır. Sistemin performansını değerlendirmek için 10 kez çapraz doğrulama ve "eğitim"+"test" yöntemleri kullanılmaktadır.

İkinci aşamada oluşturulan bu hibrit ağdan kural çıkarmak için bir yöntem önerilmektedir. Bunun için sinir ağı eğitimi bitirdikten sonra oluşan fonksiyon çıkarılmış ve optimize edilmiştir. Optimizasyon için bir yapay bağışıklık algoritması olan Opt-aiNET kullanılmıştır. Bu çalışmada popülasyon bireyleri hem ikili, hem de gerçel sayılardan oluştuğu için hipermutasyon işlemi iki aşamada yapılmıştır. Bireyin ikili kodlanmış ve gerçel kodlanmış parçaları ayrı ayrı hipermutasyona tabi tutulmuştur. Sistemin bulduğu antikorların kodları çözülmüş ve kurallar oluşturulmuştur. Kod çözümü için ikili kodun ait olduğu özellikler kullanılmış, eğer birkaç özellik bir arada geçerliyse, “VEYA” operatörü ile birleştirilmiştir. Gerçel sayılar ise üyelik dereceleri olduğundan dolayı, önce durulaştırılmışlardır. Bu şekilde oluşan aralık, o niteliğin standart sapması kadar sağa ve sola genişletilmiş ve sonuç aralığı tespit edilmiştir. Elde edilen nitelik değerleri “VE” operatörü ile birleştirilmiştir.

Özet olarak çalışma üç aşamadan oluşmaktadır:

1. Verileri kodlama
2. Sınıflandırma
3. Kural çıkartma

Sistemin başarısını test etmek için her iki yöntem iki farklı veri tabanında uygulanarak elde edilen sonuçlar literatürde rapor edilen sonuçlarla karşılaştırılmaktadır. Her iki veri tabanında da yöntemlerin başarılı olduğu görülmektedir. Genel olarak bakıldığında doğru tanı oranı yüksek olan bir sistem geliştirildiği görülmektedir. Çalışmada alınan önemli sonuçlardan bazıları şunlardır:

1. Tıpta doğru teşhisin ne kadar önemli olduğu göz önünde bulundurulduğunda, bu tip bir sınıflandırma sisteminin önemi daha iyi anlaşılmaktadır.
2. Çalışmamızda başarı ölçümlerinin güvenilirliğinin sağlanması amacıyla iki farklı veritabanı kullanılmıştır. Her iki veritabanı araştırmalara açık olduğu için üzerlerinde bir çok uygulama yapılarak bize çalışmamızın sonucunu karşılaştırma olanağı sunmaktadır.

3. Tıp alanında bulanık mantık kullanıldığında karşılaşılan önemli sorunlardan birisi verilerin doğru bulanıklaştırılmasıdır. Yapılan çalışmada görülmektedir ki, doğru bulanıklaştırma için o hastalığın ait olduğu alan uzmanının desteği gerekmektedir.
4. Başarılı sınıflandırma yapmak için bir sinir ağının geliştirilmesini ve bu ağdan kural çıkarılmasını amaçlayan bu çalışmada, sınıflandırma için hibrit bir sinir ağı önerilmiştir. Sistemin performansı iki şekilde ölçülmüştür: 10 kez çapraz doğrulama ve “eğitim”+”test”. Her iki yöntemde de sistemin başarılı olduğu görülmektedir. Kural çıkarmak için bir yapay bağışıklık algoritması olan Opt-aiNET kullanılarak optimizasyon yapılmaktadır. Oluşturulan kural tabanının sınıflandırma başarısını yükselttiği görülmektedir.

Yapılan bu çalışmanın gerçek bir sistemde kullanılması mümkündür. Öncelikle kullanılacak hastalıkla ilgili bulanıklaşacak verilerin bulanıklaştırılması ve sinir ağının eğitilmesi gerekmektedir. Ağ bu şekilde kullanılabileceği gibi istenirse, optimizasyon yapılarak o hastalık için kurallar oluşturulabilir.

6.2. Öneriler

Bu çalışmada hibrit bulanık sinir ağı kullanarak teşhis başarısının yükseldiği gözlemlenmektedir. Ayrıca bulanıklaştırılmış verilerle yapılmış bir çalışmanın, klasik kodlanmış verilerle yapılan çalışmadan daha başarılı olduğu görülmektedir.

Bu tez çalışmasının sonucunda;

- Çevrimiçi bir teşhis sistemi tasarlanarak, sistemin test edilmesi ve sonuçların değerlendirilmesi,

- Farklı hastalıklarla ilgili ve daha fazla veriye sahip veritabanları üzerinde bu uygulamaların gerçekleştirilmesi ve doğrulama sonuçlarının analiz edilmesi,
- Eğitime girilen örnek sayısının artırılarak teşhis oranlarının incelenmesi gibi bazı önemli konuların ileriye yönelik birer çalışma olarak önerilmesinde fayda görülmektedir.

7. KAYNAKLAR

- Adam ve ark. (2002) Adam B-L, Qu Y, Davis JW, Ward MD, Clements MA, Cazares LH et al., Serum protein fingerprinting coupled with a pattern-matching algorithm distinguishes prostate cancer from benign prostate hyperplasia and healthy men., *Cancer Res.*, 62:3609—14, 2002.
- Ahn ve ark. (2000) Ahn B.A., Cho S.S. & Kim C.Y., The integrated methodology of rough set theory and artificial neural network for business failure prediction, *Expert Syst. Appl.* 18, pp: 65–74, 2000.
- Akşit ve ark. (1996) Akşit F., Akgün Y. & Kiraz N. Mikrobiyoloji, Açıköğretim Fakültesi Yayınları, 1996.
- Alexander & Mozer (1995) Alexander J.A. & Mozer M.C., Template-based algorithm for connectionist rule extraction, in: G. Tesauro, D. Touretzky, T. Leen (Eds.), *Advances in Neural Information Processing Systems*, vol. 7, MIT Press, Cambridge, MA, 1995.
- Aliev ve Aliev (2001) Aliev R.A. & Aliev R.R., *Soft Computing And Its Applications*, World Scientific Publishing Co., 2001
- Allahverdi (2002) Allahverdi N. *Uzman Sistemler. Bir Yapay Zeka Uygulaması.* Nobel Yayın evi ,2002.
- Altman (1968) Altman E., Financial ratios, discriminant analysis, and the prediction of corporate bankruptcy, *J. Finance* 23, pp:589–609, 1968.
- Altman ve ark. (1981) Altman E. L., Eisenbeis, R. A., & Sinkey, J., *Application of classification techniques in business, banking and finance*, Greenwich, CT: JAI Pres, 1981.
- Altun (2007) Altun, A.A., *Esnek Hesaplama Yöntemleri ile Otomatik Parmakizi Tanıma*, Dr Tezi, Selçuk Üniversitesi, 2007.
- Arondel ve Girardin (1998) Arondel C. & Girardin P., Sorting cropping systems on the basis of their impact on groundwater quality, *Tech. Rep. no.158*, LAMSADE, University of Paris-Dauphine, Paris, 1998.
- Ball ve ark. (2002) Ball G, Mian S, Holding F, Allibone RO, Lowe J, Ali S et al., An integrated approach utilizing artificial neural Networks and seldi mass spectrometry for the classification of human tumours and rapid identification of potential biomarkers.*Bioinformatics*, 18(3):pp: 395—404, 2002.
- Baykal ve Beyan (2004a) Baykal N. & Beyan T., *Bulanık Mantık Uzman Sistemler ve Denetleyiciler*, Bıçaklar, 2004.

- Baykal ve Beyan (2004b) Baykal N. & Beyan T., Bulanık Mantık İlke ve Temelleri, Bıçaklar, 2004.
- Bennet ve Blue (1997). Bennet K. P., & Blue J. A., A support vector machine approach to decision trees. Rensselaer Polytechnic Institute, Math Report, No. 97- 100, 1997.
- Berkson (1944) Berkson J., Application of the logistic function to bioassay. Journal of the American Statistical Association 39, pp: 357–365, 1944.
- Bhattacharyya ve Pendharkar (1998) Bhattacharyya, S., & Pendharkar, P. C., Inductive, evolutionary and neural techniques for discrimination: a comparative study, Decision Sciences, 28 (4),1998
- Bioch ve ark. (1996) Bioch, J. C., O. van der Meer, et al. Classification using Bayesian neural nets, The 1996 IEEE International Conference on Neural Networks, pp: 1488-1493, Washington, DC, Institute of Electrical and Electronics Engineers, 1996.
- Brans ve Mareschal (1994) Brans, J.-P. & Mareschal, B., How to Decide with PROMETHEE. ULB and VUB. Brussels Free Universities: Belgium, 1994,
<<http://homepages.ulb.ac.be/~bmaresc/PromWeb.htm>>.
- Breiman ve ark. (1984) Breiman, L., Friedman, JH., Olshen, RA & Stone, CJ., Classification and regression trees. Monterey, CA: Wadsworth & Boks / Cole Advanced Boks & Software, 1984
- Carpenter ve Markuzon (1998) Carpenter, G. A. & N. Markuzon, ARTMAP-IC and medical diagnosis: instance counting and inconsistent cases, Neural Networks 11(2) pp: 323-336, 1998
- Cheung (2001). Cheung, N., Machine learning techniques for medical analysis, School of Information Technology and Electrical Engineering, BsC thesis, University of Queensland, 2001
- Clark ve Niblett (1987) Clark, P., & Niblett, T., The CN2 induction algorithm. Machine Learning, 3 (4), pp: 261–283, 1987.
- Craven (1996) Craven, M. W., Extracting Comprehensible Models From Trained Neural Networks, Dr tezi, Wiskonsin Üniversitesi, 1996.
- Craven ve Shavlik (1996) Craven, M.W. & Shavlik, J.W., Extracting tree-structured representations of trained networks, Advances in Neural Information Processing Systems, vol. 8, MIT Press, Cambridge, MA, pp: 24–30, 1996.
- Das ve Mozer (1998) Das, S. & Mozer, M., Dynamic on-line clustering and state extraction: an approach to symbolic learning, Neural Networks 11 (1), pp: 53–64, 1998.
- de Castro ve Von Zuben De Castro L.N. & Von Zuben, F.J., Artificial Immune Systems: Part I – Basic Theory and Applications, Technical

- (1999) Report-TR – DCA 01/99
- de Castro ve Timmis (2002) De Castro L. N. & Timmis, J. Artificial Immune Systems: A New Computational Intelligence Approach, London: Springer, 2002.
- Dias ve Tsoukias, (2004) Dias, L.C. & Tsoukias, A., On the constructive and other approaches in decision aiding, In: Antunes C.H., Figueira J., Climaco J. (Eds), Aide multicritere a la decision: Multiple criteria decision aiding. CCDRC/INESCC/FEUC: Coimbra.pp: 13–28, 2004.
- Duch ve ark. (1998) Duch, W., Adamczak, R. & Grabczewski, K., Extraction of logical rules from training data using backpropagation networks, Neural Process. Lett. 7 pp: 1–9, 1998.
- Duch ve ark. (1999) Duch, W., Adamczak, R., Grabczewski, K. & Zal, G., Hybrid neuralglobal minimization method of logical rule extraction, J. Adv. Comput. Intell. 3 pp: 348–356, 1999.
- Duch ve ark. (2000) Duch, W., Adamczak, R. & Grabczewski, K., A new methodology of extraction, optimization and application of crisp and fuzzy logical rules, IEEE Trans. Neural Networks 11 (2) pp:1–31, 2000.
- Duda ve ark. (2000) Duda, R.O., Hart, P.E. & Stork, D.G. (Eds.), Pattern Classification, second ed. Wiley Interscience, New York, 2000.
- Eklund ve Hoang (1998) Eklund, P. W. & A. Hoang, Classifier Selection and Training Set Features: LMDT, 1998, citeseer.nj.nec.com/309003.html.
- Elmas (2003a) Elmas Ç., Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayınevi, 2003.
- Elmas (2003b) Elmas, Ç., Bulanık Mantık Denetleyiciler (Kuram, Uygulama, Sinirsel Bulanık Mantık), Seçkin Yayınevi, 2003.
- Fausett (1994) Fausett L., Fundamentals of Neural Networks. Architectures, Algorithms and Applications, Prentice-Hall, 1994.
- Fisher (1936) Fisher, R. A., The use of multiple measurements in taxonomic problems. Annals of Eugenics, 7, 179–188, 1936.
- Freed ve Glover (1981) Freed, N., & Glover, F. A linear programming approach to the discriminant problem, Decision Sciences, 12, pp: 68–74, 1981.
- Fuller (1995) Fuller R., Neural Fuzzy Systems, Abo Akademi University, 1995.
- Gallant (1993) Gallant, S. I., Neural Network Learning and Expert Systems. MIT Press, Cambridge, MA, 1993.

- Garcez ve ark. (2001) Garcez, A.S.D., Broda, K. & Gabbay, D.M., Symbolic knowledge extraction from trained neural networks: a sound approach, *Artif. Intell.*, 125 pp: 155–207, 2001.
- Gültekin (2002) Gültekin S.S., Çeşitli Tipteki Mikroşerit Antenlerin Karakteristik Parametrelerinin Farklı Algoritmalarla Eğitilen Yapay Sinir Ağları ile Hesaplanması, S.Ü. Fen Bilimleri Enstitüsü, Doktora Tezi, 2002
- Hamilton ve ark. (1996) Hamilton, H. J., Shan, N., & Cercone, N., RIAC: A rule induction algorithm based on approximate classification, *Tech. Rep. CS 96-06*, University of Regina, 1996.
- Han & Kamber (2001) Han, J., & Kamber, M., *Data Mining: Concepts and Techniques*, Morgan Kaufmann, 2001.
- Hand (1981) Hand, D. J. *Discrimination and classification*, New York: Wiley, 1981.
- Haykin (1994) Haykin S., *Neural Networks: A Comprehensive Foundation*, Macmillan Colleg Publishing Comp. Inc., 1994.
- Hruschkaa ve Ebecken (2006) Hruschkaa, E. R. & Ebecken, N. F. F., Extracting rules from multilayer perceptrons in classification problems: A clustering-based approach , *Neurocomputing* 70, pp: 384–397, 2006.
- Ishibuchi ve ark. (1992) Ishibuchi H., Nozaki K. & Tanaka H., Distributed representation of fuzzy rules and its application to pattern classification, *Fuzzy Sets and Systems*, 52, pp: 21-32, 1992.
- Ishibuchi ve ark. (1994) Ishibuchi H., Nozaki K. & Tanaka H., Interpolation of fuzzy IF-THEN rules by neural Networks, *International Journal of Approximate Reasoning*, 10, pp: 3-27, 1994.
- Jackson (1998) Jackson P.,. *Introduction to Expert Systems*, third ed. West Group, New York, 1998.
- Jaszkiewicz ve Ferhat (1999) Jaszkiewicz, A. & Ferhat, A.B., Solving multiple criteria choice problems by interactive trichotomy segmentation. *European Journal of Operational Research* 113, pp: 271–280, 1999.
- Jo ve ark. (1997) Jo H., Han I., & Lee H., Bankruptcy prediction using case-based reasoning,neural networks and discriminant analysis, *Expert Syst. Appl.* 13 pp: 97–108, 1997.
- Joshi ve Moudgalya (2004) Joshi M.C. & Moudgalya K.M., *Optimization Theory and Practice*, Alpha Science International Ltd, U.K., 2004
- Karaboğa (2004) Karaboğa D., *Yapay Zeka Optimizasyon Algoritmaları*, Atlas, 2004.

- Karlík (1994) Karlík B.,Çok fonksiyonlu protezler için yapay sinir ağları kullanarak miyoelektrik kontrol, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 1994.
- Karna ve Bren (1989) Karna K. N. & Bren D. M., An Artificial Neural Networks Tutorial Basics, Neural Networks, 1, no:1 pp: 4-23, 1989
- Kaufman ve Rousseeuw (1990) Kaufman, L. & Rousseeuw P. J., Finding Groups in Data—An Introduction to Cluster Analysis, Wiley Series in Probability and Mathematical Statistics, 1990
- Keedwell ve ark. (2000) Keedwell, E., Narayanan, A. & Savic, D., Creating rules from trained neural networks using genetic algorithms, Int. J. Comput. Syst. Signals, 1 (1) pp: 30–42, 2000.
- Keeney ve Raiffa (1976) Keeney, R.L. & Raiffa, H., Decisions with Multiple Objectives – Preferences and Value Tradeoffs. John Wiley and Sons, New York, 1976.
- King ve ark. (1998) King, M. A., J. F. Elder IV, et al., Evaluation of Fourteen Desktop Data Mining Tools, IEEE International Conference on Systems, Man, and Cybernetics, San Diego, CA, 1998, citeseer.nj.nec.com/293388.html.
- Koehler (1991) Koehler, G. J., Linear discriminant functions determined through genetic search. ORSA Journal on Computing, 3 (4), pp: 345–357, 1991.
- Kohavi (1995) Kohavi, R., A study of cross validation and bootstrap for accuracy estimation and model selection. The Fourteenth International Joint Conference on Artificial Intelligence, San Francisco, CA:Morgan Kaufman , pp: 1137-45, 1995.
- Korobow ve ark. (1976) Korobow, L., Stuhr, D. & Martin, D., A probabilistic approach to early warning changes, in: Bank Financial Condition, Federal Reserve Bank of New York, pp: 187–194 (Monthly Review), 1976.
- Lee ve Wang (1994) Lee H. M. & Wang W.T., neural network architecture for classification of fuzzy inputs, Fuzzy Sets and Systems, 63, pp: 159-173, 1994.
- Lee ve Mangasarian (2001a). Lee, Y. J., & Mangasarian, O. L., SSVM: A smooth support vector machine for classification, Computational Optimization and Applications, 20(1), pp: 5–22., 2001
- Lee ve Mangasarian (2001b). Lee, Y. J., & Mangasarian, O. L. RSVM: Reduced support vector machines, In Proceedings of the first SIAM international conference on data mining, 2001.
- Liu (1998) Liu, B. Integrating Classification and Association Rule Mining. KDD-98, Knowledge Discovery and Data Mining, New York: pp: 80-86, 1998.

- Loo (2005) Chu Kiong Loo, Accurate and Reliable Diagnosis and Classification Using Probabilistic Ensemble Simplified Fuzzy ARTMAP, IEEE Transactions On Knowledge And Data Engineering, Vol. 17, No. 11, pp: 1589-1593, 2005.
- Lu ve ark.
(1996) Lu, H., Setiono, R. & Liu, H., Effective data mining using neural networks, IEEE Trans Knowledge Data Eng 8 (6) pp: 957-961, 1996
- Ludermir (1998) Ludermir, T.B., Extracting Rules from Feedforward Boolean Neural Networks, in: Proceedings of the V Brazilian Symposium on Neural Networks, pp: 61-65, 1998.
- Marzban ve
Stumpf (1996). Marzban, C. & Stumpf, G., A neural network for tornado prediction based on Doppler radar-derived attributes, Journal of Applied Meteorology, 35, pp: 617-626, 1996.
- Michie ve ark.
(1994) Michie, D., D. J. Spiegelhalter, et al., Machine learning, neural and statistical classification. New York, Ellis Horwood, 1994.
- Narazaki (1996) Narazaki, H., Watanabe, T. & Yamamoto, M., Re-organizing knowledge in neural networks: an explanatory mechanism for neural networks in data classification problems, IEEE Trans. Syst. Man Cybern. 26 (1) pp: 107-117, 1996.
- Nauck ve Kruse
(1999). Nauck, D., & Kruse, R., Obtaining interpretable fuzzy classification rules from medical data, Artificial Intelligence in Medicine, 16, pp: 149-169, 1999.
- Oates (1994) Oates, T. MSDD as a Tool for Classification. EKSL Memorandum 94-29, Department of Computer Science, University of Massachusetts at Amherst, 1994.
- Olmeda ve
Fernandez
(1997) Olmeda, I. & Fernandez, E., Hybrid classifiers for financial multicriteria decision making: the case of bankruptcy prediction, Comput. Econ. 10, pp: 317-335, 1997.
- Palade ve ark.
(2000) Palade, V., Neagu, D. & Puscasu, G., Rule extraction from neural networks by interval propagation, in: Proceedings of the Fourth IEEE International Conference on Knowledge-Based Intelligent Engineering Systems, Brighton-UK, pp: 217-220, 2000.
- Pantalone ve
Platt (1987) Pantalone, C.C. & Platt, M.B., Predicting bank failure since deregulation, N. Engl. Econ. Rev., Federal Reserve Bank of Boston pp: 37-47, 1987.
- Pena-Reyes ve
Siper (1999) Pena-Reyes, C. A., & Sipper, M., A fuzzy-genetic approach to breast cancer diagnosis, Artificial Intelligence in Medicine, 17, pp: 131-155., 1999.

- Pendharkar ve ark. (1999) Pendharkar, P.C., Rodgerb, J.A., Yaverbauma, G.J., Hermana, N. & Benner, M., Association, statistical, mathematical and neural approaches for mining breast cancer patterns, *Expert Systems with Applications* 17, pp: 223–232, 1999
- Pham ve ark. (2000) Pham, D. T., Dimov, S. S., & Salem, Z., Technique for selecting examples in inductive learning, In *European symposium on intelligent techniques*, Aachen-Germany pp: 119–127, 2000.
- Quinlan (1986) Quinlan, J. R., *Induction of Decision Trees*, Machine Learning, 1, pp: 81–106, 1986.
- Quinlan (1993) Quinlan, J. R., *C4.5: programs for machine learning*. San Mateo, Calif., Morgan Kaufmann Publishers, 1993
- Quinlan (1996). Quinlan, J. R., Improved use of continuous attributes in C4.5, *Journal of Artificial Intelligence Research*, 4, pp: 77–90, 1996.
- Rumelhart ve ark. (1986) Rumelhart, D. E., Hinton, G. E., & William, R. J., Learning internal representations by error propagation. In D. E. Rumelhart & J. L. McClelland (Eds.), *Parallel distributed processing: exploration in the microstructure of cognition*, Foundations, 1. Cambridge, MA: MIT Press., 1986.
- Rumelhart ve McClelland (1986) Rumelhart, D.E. & McClelland J.L., *Paralel Distributed Processing: Explorations in the Microstructure of Cognition*”, Vol.1, MIT Pres, Cambridge, Massachusetts, 1986.
- Sağıroğlu ve ark. (2003) Sağıroğlu Ş., Beşdok E. & Erler M., *Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları*,Ufuk Yayıncılık, 2003.
- Saito ve Nakano (1988) Saito, K. & Nakano, R., Medical diagnostic expert system based on PDP model, In *Proceedings of the IEEE International Conference on Neural Networks*, pp: 255-262, San Diego, CA. IEEE Pres,1988.
- Sethi ve Yoo (1996) I. Sethi & J. Yoo, Multi-valued logic mapping of neurons in feedforward networks, *Eng Intell. Syst.* 4 (4) pp: 243–253, 1996.
- Setiono ve Leow (2000) Setiono, R. & Leow, K., FERNN: an algorithm for fast extraction of rules from neural networks, *Appl. Intell.* 12 (1–2) pp: 15–25, 2000.
- Shin ve ark. (2005) Shin, K.-S., Lee, T.S., & Kim, H.-J., An application of support vector machines in bankruptcy prediction model, *Expert Syst. Appl.* 28 pp: 127–135, 2005.

- Sigillito ve ark.
(1989) Sigillito, V. G., Wing, S. P., Hutton, L. V. & Baker, K. B., Classification of radar returns from the ionosphere using neural Networks, Johns Hopkins APL Technical Digest, 10, pp: 262-266, 1989.
- Smith ve ark.
(1988) Smith, J. W., J. E. Everhart, et al., Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. Proceedings of the Symposium on Computer Applications and Medical Care (Washington, DC). R. A. Greenes. Los Angeles, CA, IEEE Computer Society Press: pp:261-265, 1988.
- Snyders ve
Omlin (2001) Snyders, S. & Omlin, C., Rule Extraction from Knowledge-Based Neural Networks with Adaptive Inductive Bias, in: Proceedings of the Eighth International Conference on Neural Information Processing, Vol. 1, pp: 143–148, 2001.
- Ster ve Dobnikar
(1996). Ster, B., & Dobnikar, A., Neural networks in medical diagnosis: Comparison with other methods, In The proceedings of the international conference on engineering applications of neural networks (EANN'96) pp: 427–430, 1996.
- Sundaram
(1996) Sundaram, R.K., A First Course in Optimization Theory, Cambridge University Pres, USA, (1996).
- Tam (1991) Tam K.Y., Neural network models and the prediction of bank bankruptcy, Omega 19 pp: 429–445, 1991.
- Tam ve Kiang
(1992) Tam, K.Y. & Kiang, M., Predicting bank failures: a neural network approach, Decis. Sci. 23, pp: 926–947, 1992.
- Tang ve ark.
(2004) Tang, Y., Jin, B., Sun, Y. & Zhang, Y-Q. Granular Support Vector Machines for Medical Binary Classification Problems, IEEE Symposium on Computational Intelligence in Bioinformatics and Computational Biology, pp: 73-78, 2004.
- Tchoumatchenko
ve Ganascia
(1994) Tchoumatchenko, I. & Ganascia, J.-G., A Bayesian framework to integrate symbolic and neural learning, In Proceedings of the Eleventh International Conference on Machine Learning, pp: 302-308, New Brunswick, NJ. Morgan Kaufmann, 1994.
- Thrun (1995) Thrun, S., Extracting rules from artificial neural networks with distributed representations, In Tesauro, G., Touretzky, D., & Leen, T., editors, Advances in Neural Information Processing Systems (volume 7). MIT Press, Cambridge, MA, 1995.
- Towell ve
Shavlik (1993) Towell, G.G. & Shavlik, J., Extracting refined rules from knowledgebased neural networks, Mach. Learn. 13 pp: 71–101, 1993.

- Van Gestel, ve ark. (2002) Van Gestel, T., Suykens, J. A. K., Lanckriet, G., Lambrechts, A., De Moor, B., & Vandewalle, J., Bayesian framework for least squares support vector machine classifiers, gaussian processes and kernel fisher discriminant analysis, Neural Computation, 14(5), pp: 1115–1147, 2002
- Wahba ve ark. (1992) Wahba, G., C. Gu, et al., Soft Classification, a.k.a. Risk Estimation, via Penalized Log Likelihood and Smoothing Spline Analysis of Variance. The mathematics of generalization: the proceedings of the SFI/CNLS Workshop on Formal Approaches to Supervised Learning, Santa Fe, Addison-Wesley Pub. Co.: pp:331-360., 1992
- Weijters ve ark. (1997) Weijters, T., Bosh, A.V.D. & Herik, J.V.D., Intelligible neural Networks with BP_SOM, in: Proceedings of the Ninth Dutch Conference on Artificial Intelligence, pp: 27–36, 1997.
- Zurada (1992) Zurada J. M., Introduction to Artificial Neural Networks, West Publishing Company, 1992
- Optimizasyon, <http://tr.wikipedia.org/wiki/Optimizasyon>, son erişim: 19.06.2007
- Asuncion, A & Newman, D.J. UCI Machine Learning Repository [<http://www.ics.uci.edu/~mllearn/MLRepository.html>]. Irvine, CA: University of California, Department of Information and Computer Science , 2007., son erişim: Ocak, 2007
- Benchmark datasets used for classification: comparison of results, :<http://www.fizyka.umk.pl/kmk/projects/datasets.html>: son erişim: Mart, 2008.
- Logical rules extracted from data, <http://www.fizyka.umk.pl/kmk/projects/rules.html>, Mart, 2008
- SUZEP, <http://farabi.selcuk.edu.tr/egitim/ysa>, son erişim: Aralık 2007
- Tıp Bilişimi Güz Okulu, http://www.turkmia.org/eski/file/231verimadenciligi_baykal.ppt, son erişim: Ocak, 2008
- Veri Madenciliği ve Elektronik Ticaret, <http://www.inet-tr.org.tr/inetconf7/eposter/inceoglu.doc>, son erişim: Ocak, 2008