

**GAZ KARIŞIMLARINI QCM SENSÖR DİZİSİ VE
YAPAY SINİR AĞI KULLANARAK BULUNMASI**

Ferzende TEKÇE

Dumlupınar Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik-Elektronik Anabilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır.

Danışman : Yrd. Doç. Dr. Ahmet ÖZMEN

Ağustos-2005

KABUL VE ONAY SAYFASI

Ferzende Tekçe'in YÜKSEK LİSANS tezi olarak hazırladığı Gaz Karışımlarını QCM Sensör Dizisi ve Yapay Sinir Ağı Kullanarak Bulunması başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

...../...../.....
(Sınav tarihi)

Üye : Yrd. Doç. Dr. Mehmet Ali EBEOĞLU

Üye : Yrd. Doç. Dr. Cengiz YENİKAYA

Üye : Yrd. Doç. Dr. Ahmet ÖZMEN (Danışman)

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 09/08/.05. gün ve ..12... sayılı kararıyla onaylanmıştır.

Prof.Dr. M. Sabri ÖZYURT

Fen Bilimleri Enstitüsü Müdürü

GAZ KARIŞIMLARINI QCM SENSÖR DİZİSİ VE YAPAY SINİR AĞI KULLANARAK BULUNMASI

Ferzende TEKÇE

Elektrik-Elektronik Mühendisliği Yüksek Lisans Tezi, 2005

Tez Danışmanı: Yrd. Doç. Dr. Ahmet ÖZMEN

ÖZET

Özellikle son yıllarda hızlı ve otomatik analiz imkanı sağlayan akıllı proses sistemlerinde büyük gelişmeler kaydedilmiştir. Gerek endüstriyel üretimde gerekse bilimsel çalışmalarında kullanıcıya büyük avantajlar sağlayan bu sistemlerden bir tanesi de elektronik burunlardır. Bu sistemlerin koku ve gaz analizinde kullanılan geleneksel yöntemlere göre avantajı; hızlı, objektif ve daha ucuz analiz imkanı sağlamalarıdır.

Bu tez çalışmasında; TUBİTAK Marmara Araştırma Merkezi, Malzeme Teknolojileri Enstitüsü’nde Sensör Gurubu’nda geliştirilen sistemden alınmış datalar kullanılmıştır. Bu datalar kullanılarak YSA ile bir gaz karışımının bileşimlerini bulan sistem geliştirilmiştir. YSA’yı gerçeklemek için iki farklı yol izlenilmiştir. Yapay sinir ağları modeli Xilinx Spartan-II Field Programmable Gate Array (FPGA) çip setli Xess Board kullanarak donanımsal olarak gerçeklenmiş, fakat gerçeklenen donanımsal YSA modeli istenilen performansı sağlamasına rağmen sensör karakteristiklerinden dolayı kullanılmaktan vazgeçilmiştir. Bunun yerine Matlab kullanılarak yazılımsal olarak gerçeklenen Geri Yayımlı Yapay Sinir Ağları kullanılmıştır.

Sensör tepkilerine ait dijital datalar düzenlenerek sonradan gaz karışımlarındaki gazları tespit etmekte kullanılan 3 katmanlı YSA’nın eğitiminde kullanıldı. Sistem aşağıdaki gaz karışımıları kullanılarak test edildi; Etanol-Aseton, Etanol-Trikloretilen, Aseton-Trikloretilen.

Anahtar Kelimeler: YSA, FPGA , QCM, Matlab, NNTOOL, Elektronik Burun, Geri Yayımlı YSA

FINDING THE COMPOSITION OF GAS MIXTURES BY A QCM SENSOR ARRAY AND AN ARTIFICIAL NEURAL NETWORK

Ferzende TEKÇE

Electrical and Electronics Engineering MSc. Thesis, 2005

Supervisor: Assist. Prof. Dr. Ahmet ÖZMEN

SUMMARY

In recent years, automation systems and smart analysis systems have shown very rapid progress. Electronic noses have very important place in these systems; both in industrial plants and scientific researches. Electronic noses are used in smell and gas analysis to detect critical gases that may harm humans, which is quite a new topic in the academia. A lot of researches have currently been done in the area around the world.

In this thesis, the data obtained from the system which was developed by the Sensor Group in the Material Technology Institute of the Marmara Research Center, a branch office of the Scientific & Technological Council of Turkey (TÜBİTAK), have been used. Two different ways have been tested to construct NN. First, it has been constructed in hardware using FPGA (Field Programmable Gate Array) technology. Although the hardware system was provided sufficient performance, we had to quit due to sensor characteristics and find another way to implement NN. Then, a feed-forward back-propagation NN was constructed in software using Matlab.

The digital data obtained from sensor array is preprocessed first, and then some of these data is used to train 3-layer NN. The rest of the data is used to test the system. The system is tested with the following gas mixtures: (1) Ethanol-acetone, (2) Ethanol-trichloroethylene, (3) Acetone-trichloroethylene.

Keywords: YSA, FPGA, QCM, Matlab, NNTOOL, Electronic Nose, Feed-forward Backpropagation

TEŞEKKÜR

Bu çalışmada bana yardımcı olan başta danışman hocam Yrd. Doç. Dr. Ahmet ÖZMEN; Marmara Araştırma Merkezi, Malzeme Teknolojileri Enstitüsü’nde Sensör Gurubu, Yrd. Doç. Dr. Mehmet Ali EBEOĞLU, Arş. Gör. Kadir VARDAR ve katkılarından dolayı diğer bölüm öğretim elemanlarına ve hiçbir zaman maddi ve manevi desteklerini esirgemeyen sevgili aileme sonsuz teşekkür ederim.



İÇİNDEKİLER

| | <u>Sayfa</u> |
|--|--------------|
| ÖZET..... | iv |
| SUMMARY | v |
| TEŞEKKÜR | vi |
| ŞEKİLLER DİZİNİ..... | ix |
| ÇİZELGELER DİZİNİ..... | xii |
| SİMGELER DİZİNİ..... | xiii |
| 1. GİRİŞ..... | 1 |
| 2. YAPAY SİNİR AĞLARI..... | 4 |
| 2.1 YSA'ların Tarihi Gelişimi..... | 4 |
| 2.2 Geri Yayımlı YSA'nın Yapısı..... | 5 |
| 2.3 Geri Yayımlı YSA'da Kullanılan Transfer Fonksiyonları..... | 7 |
| 2.4 Geri Yayımlı YSA'da Öğrenme..... | 9 |
| 2.5 Geri Yayımlı YSA Denklemleri | 11 |
| 3. DONANIMDA YSA GERÇEKLEME..... | 14 |
| 3.1 HDL..... | 14 |
| 3.2 FPGA..... | 14 |
| 3.3 FPGA ile YSA tasarımı..... | 18 |
| 3.3.1 Dataların gösterimi..... | 18 |
| 3.3.2 Çarpma..... | 19 |
| 3.3.3 Aktivasyon fonksiyonu (Sigmoid)..... | 19 |
| 3.3.4 Nöronun modellenmesi..... | 22 |
| 4. YAZILIMDA YSA GERÇEKLEME..... | 27 |
| 4.1 Matlab..... | 27 |
| 4.2 Matlab'ın kullanım amacı ve yeri..... | 27 |
| 4.3 Sensör analiz programı..... | 28 |
| 4.4 NNTOOL (Neural Network Tool) | 28 |
| 5. KOKU SENSÖRÜ VE SENSÖR DİZİLERİ..... | 32 |

İÇİNDEKİLER (devam)

| | Sayfa |
|---|--------------|
| 5.1 Metal Oksit Yarıiletkenleri (Metal Oxide Semiconductors) (MeOX) (MeOx)..... | 32 |
| 5.2 Metal Oksit Yarıiletken Alan Etkili Transistörleri (Metal Oxide Semiconductor Field Effect Transistors) (MOSFET)..... | 32 |
| 5.3 Yüzey Akustik Dalga Cihazları (Surface Acoustic Wave Devices) (SAW)..... | 33 |
| 5.4 Polimerler-Kimyasal Dirençler (Conducting Polymers- Chemiresistors)..... | 33 |
| 5.5 Optik Sensörler (Optical Sensors)..... | 34 |
| 5.6 Kuartz Kristal Mikrobalsans Sensörleri (Quartz Crystal Microbalance Devices) (QCM)..... | 34 |
| 6. GAZ KARIŞIMLARINI QCM SENSÖR DİZİSİ VE YAPAY SİNİR AĞI KULLANARAK BULUNMASI..... | 35 |
| 6.1.TUBİTAK Marmara Araştırma Merkezi’nden alınmış datalar ve özellikleri..... | 37 |
| 7. SONUÇ..... | 55 |
| KAYNAKLAR DİZİNİ..... | 60 |

EKLER

1. Hardware Implementation of a Neuron-Model
2. Finding the Composition of Gas Mixtures by a Phthalocyanine Coated QCM Sensor Array and an Artificial Neural Network

ŞEKİLLER DİZİNİ

| <u>Sekil</u> | <u>Sayfa</u> |
|---|--------------|
| 2. 1 Nöronun Temel Yapısı..... | 5 |
| 2. 2. Tek Katmanlı YSA | 6 |
| 2. 3 Çok Katmanlı YSA..... | 6 |
| 2. 4. Log-sigmoid Transfer Fonksiyonu | 7 |
| 2. 5. Tan-sigmoid Transfer Fonksiyonu..... | 7 |
| 2. 6. Lineer Transfer Fonksiyonu..... | 8 |
| 2. 7 Üç Katmanlı Yapay Sinir Ağı..... | 11 |
| 3. 1 CPLD ve FPGA mimarisi | 15 |
| 3. 2 FPGA ile devre tasarımının aşamaları | 17 |
| 3. 3 Sigmoid fonksiyonun donanımda gerçekleştirilmesi..... | 20 |
| 3. 4 Sigmoid fonksiyonunu ve donanımsal yaklaşımı..... | 21 |
| 3. 5 Yapay Sinir Ağı modelinin şeması | 24 |
| 3. 6 Kontrol devresinin durum diyagramı..... | 25 |
| 3. 7 YSA'nın simülasyonuna ait zaman diyagramları | 26 |
| 4. 1 Sensör analiz programının kullanıcı ara yüzü..... | 28 |
| 4. 2 NNTOOL | 29 |
| 4. 3 NNTOOL kullanılarak yapılan YSA'nının görünümü..... | 31 |
| 6. 1. TUBİTAK-MAM'da kullanılan deney düzeneğinin şematik görünümü | 35 |
| 6. 2. Etanol sabit tutularak asetonun değiştirilmesi ile farklı oranlarda elde edilen karışımlar. | 36 |
| 6. 3 Filtrelenmemiş sensör 5'in aseton ve trikloretilen gaz karışımılarına verdiği tepki. | 41 |
| 6. 4 Filtrelenmemiş sensör 3'ün aseton ve trikloretilen gaz karışımılarına verdiği tepki. | 41 |
| 6. 5 Filtrelenmiş sensör 5'in aseton ve trikloretilen gaz karışımılarına verdiği tepki. | 42 |
| 6. 6 Filtrelenmiş sensör 3'ün aseton ve trikloretilen gaz karışımılarına verdiği tepki. | 42 |
| 6. 7 8 sensörün etanol ve trikloretilen gaz karışımılarına verdikleri tepkilerin 3D grafikleri..... | 44 |

ŞEKİLLER DİZİNİ (devam)**Sekil****Sayfa**

| | |
|--|----|
| 6.8 8 sensörün aseton ve trikloretilen gaz karışımılarına verdikleri tepkilerin 3D grafikleri. | 45 |
| 6.9 8 sensörün etanol ve aseton gaz karışımılarına verdikleri tepkilerin 3D grafikleri. | 46 |
| 6.10. Data işleme sisteminin blok şeması | 47 |



ÇİZELGELER DİZİNİ

| <u>Sekil</u> | <u>Sayfa</u> |
|---|--------------|
| 3. 1 Dataların gösterimi | 18 |
| 3. 2 Temsil edilen datarlar..... | 19 |
| 3. 3 Tasarlan sigmoid fonksiyonuna ait bellek adresleri ve bu adreslere karşılık atanmış alanlar..... | 21 |
| 4. 1 NNTOOL kullanılarak yapılabilen YSA çeşitleri | 30 |
| 6. 1 Aseton ve Trikloretilen gazlarına ait karışım oranları ve dosya isimnleri..... | 37 |
| 6. 2 Aseton ve Trikloretilen gazları için ölçüm ortam şartları..... | 37 |
| 6. 3 Aseton ve Trikloretilen gazları için ölçüm özelliklerı | 37 |
| 6. 4 Etanol ve Trikloretilen gazlarına ait karışım oranları ve dosya isimnleri..... | 38 |
| 6. 5 Etanol ve Trikloretilen gazları için ölçüm ortam şartları..... | 38 |
| 6. 6 Etanol ve Trikloretilen gazları için ölçüm özelliklerı | 38 |
| 6. 7 Aseton ve Etanol gazlarına ait karışım oranları ve dosya isimnleri | 39 |
| 6. 8 Aseton ve Etanol gazları için ölçüm ortam şartları..... | 39 |
| 6. 9 Aseton ve Etanol gazları için ölçüm özelliklerı..... | 39 |
| 6. 10 Etanol ve trikloretilen gaz karışımı için çıkış eğitim datası | 48 |
| 6. 11 Etanol ve trikloretilen gaz karışımı için 0 ile 3.3 arasına çekilmiş çıkış eğitim datası..... | 48 |
| 6. 12 Etanol ve trikloretilen gaz karışımı için çıkış test datası | 48 |
| 6. 13 Etanol ve trikloretilen gaz karışımı için 0 ile 3.3 arasına çekilmiş çıkış test datası | 48 |
| 6. 14 Etanol ve trikloretilen gaz karışımı için eğitim giriş datası..... | 49 |
| 6. 15 Etanol ve trikloretilen gaz karışımı için 0 ile 1 arasına çekilmiş eğitim giriş datası..... | 50 |
| 6. 16 Etanol ve trikloretilen gaz karışımı için test giriş datası | 50 |
| 6. 17 Etanol ve trikloretilen gaz karışımı için 0 ile 1 arasına çekilmiş test giriş datası..... | 51 |
| 6. 18 Etanol ve trikloretilen gaz karışımı için test sonuçları. | 51 |
| 6. 19 Etanol ve trikloretilen gaz karışımı için hatalar..... | 51 |
| 6. 20 Etanol ve trikloretilen gaz karışımı için 1., 2., 4. ve 7. sensör datarları kullanılarak eğitilmiş YSA'nın test sonuçları. | 51 |

ÇİZELGELER DİZİNİ (devam)

| <u>Sekil</u> | <u>Sayfa</u> |
|---|--------------|
| 6. 21 Etanol ve trikloretilen gaz karışımıları için 1., 2., 4. ve 7. sensördataları kullanılarak eğitilmiş YSA hataları | 52 |
| 6. 22 Etanol ve aseton gaz karışımıları için test çıkış dataları | 52 |
| 6. 23 Etanol ve aseton gaz karışımıları için test sonuçları | 52 |
| 6. 24 Etanol ve aseton gaz karışımıları için hatalar | 52 |
| 6. 25 Etanol ve aseton gaz karışımıları için 1., 2., 5. ve 7. sensördataları kullanılarak eğitilmiş YSA'nın test sonuçları | 53 |
| 6. 26 Etanol ve aseton gaz karışımıları için 1., 2., 5. ve 7. sensördataları kullanılarak eğitilmiş YSA hataları | 53 |
| 6. 27 Aseton ve trikloretilen gaz karışımıları için test çıkış dataları | 53 |
| 6. 28 Aseton ve trikloretilen gaz karışımıları için test sonuçları | 53 |
| 6. 29 Aseton ve trikloretilen gaz karışımıları için hatalar | 54 |
| 6. 30 Aseton ve trikloretilen gaz karışımıları için 1., 2., 4. ve 7. sensördataları kullanılarak eğitilmiş YSA'nın test sonuçları | 54 |
| 6. 31 Aseton ve trikloretilen gaz karışımıları için 1., 2., 4. ve 7. sensördataları kullanılarak eğitilmiş YSA hataları | 54 |

SİMGELER DİZİNİ

| <u>Kısaltmalar</u> | <u>Açıklama</u> |
|---------------------------|-------------------------------------|
| YSA | Yapay Sinir Ağları |
| FPGA | Field Programmable Gate Array |
| HDL | Hardware Description Language |
| QCM | Quartz Crystal MicroBalance Devices |



1 GİRİŞ

Günümüz teknolojisindeki gelişmeler, insan duyularının kısmen de olsa modellenebilmesini sağlamıştır. Bu duyular arasında modellenmesi en zor olanı, koklamadır. Burnun üst kısmında küçük bir alanda sıralanan hücrelerde bulunan alıcılar, nefes alındığında koku moleküllerini tespit eder. Ancak, her hücre sadece tek tip alıcıya sahip ve her alıcı yalnızca sınırlı sayıda madde tespit edebilmektedir. Bu nedenle her hücre birkaç koku için uzmanlaşmış durumdadır. Hücreler çok küçük sinir dokusu lifleri üzerinden direkt beynin koku alma kontrolünü yürüten alanına ilettilir - olfactory bulb (beynin koku alma merkezi). Ancak, her tip hücre doku içindeki farklı bir alana - veya glomerulusa - bağlanır. Buradan bilgi beynin diğer bölgelerine ilettilir ve birkaç farklı koku alma alıcısından gelen bilgiler birleştirilir. Böylelikle kesin, belirgin bir koku biçimlendirilip algılanır. İnsan burnu 10000 farklı kokuya kadar ayırt etme yeteneğine sahiptir[1].

Son yıllarda hızlı ve otomatik analiz imkanı sağlayan akıllı proses sistemlerinde, büyük gelişmeler kaydedilmiştir. Gerek endüstriyel üretimde gerekse bilimsel çalışmalarında kullanıcıya büyük avantajlar sağlayan bu sistemlerden bir tanesi de elektronik burunlardır. Elektronik burun; insan koku alma duyusunu taklit edilerek yapılmış elektronik sistemlerdir. E-burun sistemleri üzerine ilk araştırmalar 1970'li yıllarda İngiltere'de, Warwick Üniversitesi'nde gaz sensörleri üzerine yürütülen çalışmalarla başlamıştır[1]. Daha sonra çeşitli ülkelerde farklı gruplar tarafından geliştirilen e-burunların hemen hepsi, Warwick'te geliştirilen ana sistem üzerine tasarlanmıştır. E-burun terimi ise ilk olarak ancak 1990'lı yılların başında literatüre girmiştir. İlk prototip sistemler 1993'de, ilk ticari sistemler ise 1994'de piyasaya sürülmüştür.

Elektronik burunda kullanılan sensörler, insan burnundaki hücreler gibi belirli maddelere tepki verecek şekilde imal ediliyorlar. Koku, gaz ve uçucu bileşiklerin tespitinde ve tanınmasında kullanılan yaklaşımlardan birisi, her biri belli bir kimyasala tepki verecek şekilde tasarlanmış olan algılayıcılarından bir dizisini oluşturmaktır. Bu tür bir yaklaşımda, algılayıcıların sayısı en az analiz edilecek kimyasalların sayısı kadar olmalıdır. Bu durumda, son derece seçici kimyasal algılayıcıları tasarlamak zor ve pahalı olmaktadır. Aynı zamanda, spesifik algılayıcıların kullanımı ve belirli özelliklerin tespit edilmek istenmesi, pek çok pratik uygulama için sınırlı bir performans sergilemektedir. Alternatif bir yaklaşım, farklı kimyasallar arasındaki farkı ayırt etmek için yüksek seviyeli bilgi işlemeye dayanan ve geniş bir cevap aralığına sahip algılayıcıları kullanmaktır. Amaç, kısmi seçici algılayıcıları bir araya getirerek daha fazla kimyasala tepki veren bir dizi oluşturmaktır. Böylece, daha fazla kimyasalın tespitini yapmak mümkün olacaktır.

Elektronik burun'un en önemli kısmı olan ve her geçen gün geliştirilen yeni ve farklı özelliklerdeki sensörler konunun uygulama alanlarını ve biçimlerini genişletmektedir. Önceleri yaygın kullanım alanları çevre ve gıda teknolojilerinde yoğunlaşmıştır. Ama günümüzde askeri, tıp, kimya vb. sektörlerinde de kullanılmaya başlanmıştır[2]. Kimyadaki gaz oranlarının belirlenmesi ve analiz yöntemlerinden bağımsız ve tamamen kokuları algılayabilen sensörler, gaz analiz yöntemleri için tamamlayıcı bir unsurdur. Bilindiği gibi koku ve aromalar algılanabilme açısından oldukça karmaşık bir yapıda olduklarından, gaz analiz yöntemlerine ilaveten böyle bir değerlendirme yöntemi önemli bir avantaj sağlayacaktır. Elektronik burun'un en önemli özelliği; kokuyu insan burnundaki hassasiyet derecesinde daha iyi algılayıp ayırtılabilmesi ve sonucu objektif olarak sunmasıdır. Bilindiği gibi tuzlu, tatlı ve birkaç tat dışındaki lezzetler aynı zamanda koklanarak algılanabilmektedir. Bu özellik, gıdalardaki uçucu veya yarı uçucu kimyasalların varlığından kaynaklanmaktadır. Bu kimyasalların analizinde, gaz oranlarının belirlenmesi, benzeri yöntemler kullanılması ve bir sonuca ulaşılması oldukça uzun bir işlem gerektirdiğinden, pratik bir yöntem değildir. Gaz kromatografisinden farklı olarak elektronik burun uçucu kimyasalları alıp ayırtırmak yerine, kullandığı bir dizi sensörü kullanarak birbirinden çok az farklı bir grup sinyal üretir. Bu özellik insan burnunun çalışmasına benzemektedir. Elektronik burunda kokuyu algılayan kimyasal sensörler, kokuyu analiz eden (tanıyan) kısımda YSA'dır.

E-burun kullanılarak solunum ve sindirim sistemlerindeki kokulardan hastalık tespiti yapan makinelerin sistemler için bir çok üniversite ve kuruluş yoğun araştırmalar正在做。Bu yöntemle, solunum yolunda oluşan kanser vakalarında tümörlerin çıkarmış olduğu kokudan yararlanarak, hastalık oluşum evresinde tespit edilebilir. Kanser vakalarında erken teşhis hayat kurtarıcı olduğundan, elektronik burunun bu alanda ki kullanımının yaygınlaşması bir çok insanın hayatını kurtaracaktır。

Kimyasal, nükleer veya ikisinin karışımı olan, insan sağlığı ve diğer canlılara zarar veren tehlikeli atıklara (hazardous wastes) ait kokuların ve kokunun yayıldığı zaman canlılara vereceği zararın önceden bilinmesi gereklidir. Nükleer veya kimyasal bomba atıldığından bunun yayılma etkisinin canlılara ulaşmadan vereceği zarara yönelik savunma yapılması amacıyla bu bilginin işleneceği ortama çok hızlı bir biçimde tanınıp aktarılmalıdır. Bu tür sistemlerde, gazın algılanması için elektronik burunun kullanılıyor.

Bu tez çalışmasında; sensör dizilerinden gelen sinyalleri YSA kullanarak ortamdağı gazları tanıyan ve gaz oranlarını bulan yazılım geliştirildi. Bu yazılımda kullanılan YSA'yı gerçeklemek için iki farklı yöntem denendi:

1-YSA'yı FPGA (Field Programmable Gate Array) kullanarak donanımsal gerçekleme.

2-YSA'yı PC kullanarak yazılımsal olarak gerçeklemek.

Öncelikle, sistem donanımsal olarak FPGA (Field Programmable Gate Array) kullanılarak gerçekleştirilmeye çalışıldı. Hedeflenen; elde taşınabilir hızlı ve yer kaplamayan koku algılama sistemi yapmaktı. Fakat, sensörlerin ortam şartlarından çok etkilenmesi (yoğunluk,sıcaklık,nem,basınç), sensör tepkilerinin yavaş olması, bilgisayar teknolojisindeki gelişme ve boyutlarının küçülmesinden dolayı sistemin yazılımsal olarak gerçekleştirmesinin, daha uygun olacağına karar verildi. Bu çalışma içinde FPGA kullanılarak gerçekleştirilen bir nöronun, tasarım aşamalarına da yer verildi.

2. YAPAY SİNİR AĞLARI

İnsan beyni nöron adı verilen sinir hücreleri ve bunlar arasındaki bağlantılarından oluşan karmaşık bir sistemdir. İnsan beyninde yaklaşık 100 milyar nöron ve nöron başına düşen bağlantı sayısının da ortalama birkaç bin olduğu düşünülürse, insan beyni karmaşık bir ağa benzetilebilir. Nöronlar bu bağlantıları sayesinde birbirleriyle iletişim kurarlar.

Yapay sinir ağ (YSA) algoritmaları insan sinir sistemi mimarisinden esinlenerek geliştirilmiştir. Ancak, beynin çalışma sistemiyle ilgili bilgilerin kısıtlı olması ve bu tür çalışmalara yol gösterememesi araştırmacıları mevcut biyolojik bilgilerden farklılaşarak bazı yararlı fonksiyonlar bulmaya itmiştir. Günümüzde çok sayıda YSA modelleri geliştirilmiştir. Bu modellerin geliştirilmesinde biyolojik sinir sistemlerinin prensiplerinden ve mühendislik biliminin imkanlarından faydalanyılmıştır.

YSA'lar doğrusal olmayan sistemlerin kontrolünde ve modellenmesinde büyük kolaylıklar sağladıklarıdır. Son yıllarda başta mühendislik olmak üzere pek çok bilim dalında karmaşık problemlere çözümler üretmeleri YSA'lara olan ilgiyi arttırmıştır. Çeşitli meslek gruplarında çalışma yapanlar YSA'ları kendi uzmanlık alanlarına taşıyarak, bu alanda kullanacakları uygulamaları ve yöntemleri arar hale gelmişlerdir. Bu ilgi teorik ve uygulama alanlarındaki başarılarla daha da pekişmiştir.

2.1 YSA'ların Tarihi Gelişimi

İnsan beyni üzerindeki uzun süreli çalışmalar sonucu, sinir sistemi ve fonksiyonları hakkında oldukça önemli bilgiler elde edilmiştir. Nöronların fonksiyonlarının ve birbirleriyle olan bağlantılarının daha iyi anlaşıılması, araştırmacıların teorilerini test etmek amacıyla bazı matematiksel modeller geliştirmelerine olanak sağlamıştır.

İlk defa 1940'larda Mc Cullah ve Pitts tarafından ilk biyolojik sinir modeli ortaya konulmuştur. 1949'da Hebb tarafından yazılan "Organization Behavior" isimli kitapta hücresel seviyede öğrenme mekanizmaları anlatılmıştır. Hebb, bu kitapta YSA öğrenme algoritmaları için başlangıç noktası sayılan bir öğrenme kanunu ileri sürmüştür. Bugün üzerine bazı eklemeler yapılmış olan bu model, o dönemin bilim adamlarına, bir nöron ağın öğrenme işini nasıl gerçekleştirdiği konusunda önemli fikirler vermiştir. 1950'de Dosenblait basit bir nöron modeline dayanarak perceptron modelini ve öğrenme kuralını geliştirmiştir.

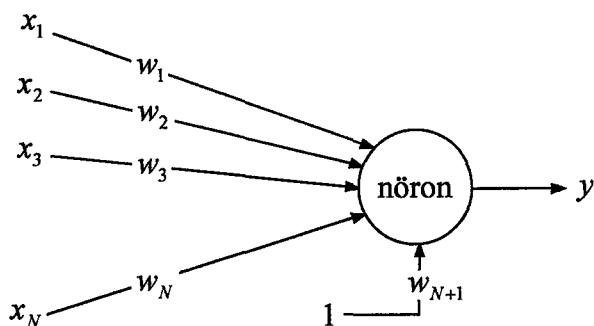
Minsky ve Papert 1969'da yazdıkları bir kitapta o güne kadar kullanımda olan ağların teorik olarak bir çok basit problemi çözemediklerini ispatlamış ve onlarınvardığı sonuçlara kimse karşı çıkamamıştır. Cesareti kırılan bazı araştırmacılar başka alanlara kaymışlardır. Bu tür çalışmalara uygulanan teşvik destekleri çekilmiş ve YSA konusundaki çalışmalar uzun bir süre duraklama dönemine girmiştir.

1976'da Grossberg tarafından adaptif rezonans teorisi geliştirilmiştir. 1982'da Hopfield tarafından Hopfield ağı geliştirilmiştir. 1984'de Kohonen eğitcisiz öğrenen ve "Self Organizing Maps" ismini verdiği özel bir ağ geliştirmiştir. 1986'da Rumelhard "Parallel Distributed Processing" grubuyla ileri beslemeli modellerde yeni bir öğrenme modeli oluşturarak hatanın geriye yayılması anlamına gelen "Back Propagation" algoritmasını geliştirmiştir. Son yıllarda, teori uygulamaya dönüştürülmüş ve teknolojinin ticari kısmıyla ilgilenen şirketler ortaya çıkmaya başlamıştır.

Geri yayılmış ağı modelinin en çok kullanılan ağı modeli olması ve adatif kontrolde çok geniş uygulama alanı bulması nedeniyle bundan sonraki kısımlarında geri yayılmış ağı modeli anlatılacaktır.

2.2 Geri Yayılmış YSA'nın Yapısı

YSA'lar birbirleriyle aynı özelliklere sahip nöron adı verilen çok basit işlem elemanlarından oluşurlar. Bir nöronun temel yapısı Şekil 2.1.'de görüldüğü gibidir.



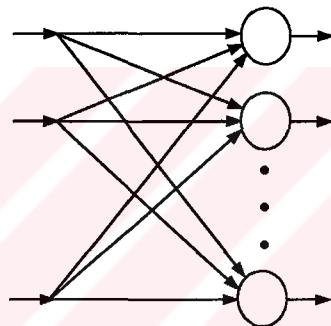
Şekil 2. 1 Nöronun Temel Yapısı

$X = [x_1, x_2, x_3, \dots, x_N, 1]$ dizisi giriş değerlerini, $W = [w_1, w_2, w_3, \dots, w_N, w_{N+1}]$ dizisi ise ağırlık değerlerini gösterir. y çıkış fonksiyonu olup denklemi aşağıda verilmiştir.

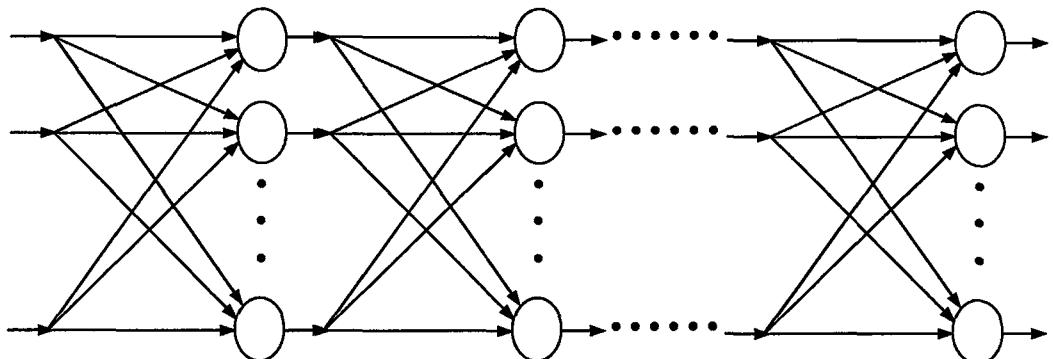
$$y = f(\text{Net}) = f(WX) = f(w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_Nx_N + w_{N+1})$$

Bir grup nöronun paralel olarak araya gelmesi katmanı oluşturur. İki veya daha fazla katmanın peş peşe bağlanması çok katmanlı ağı oluşturur. İlk katman dışarıdan bilgi aldığı için ilk katmanın giriş kısmı fazladan bir katman varmış gibi giriş katmanı olarak düşünülebilir. Giriş katmanı bilgi işlemez sadece dışarıdan bilgi alır. Son katman dışarıya bilgi aktardığından çıkış katmanı olarak isimlendirilir. Varsa diğer katmanlara ara katmanlar adı verilir.

Tek katmanlı bir ağa Şekil 2.2.'de, çok katmanlı bir ağa Şekil 2.3.'de görülmektedir. Pratikte genel olarak iki katmanlı ağlar (giriş kısmı da katmandan sayılırsa üç katmanlı ağlar) kullanılır.



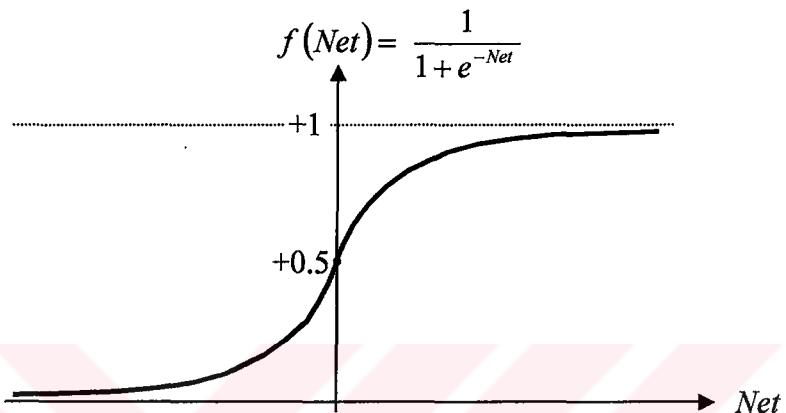
Şekil 2. 2. Tek Katmanlı YSA



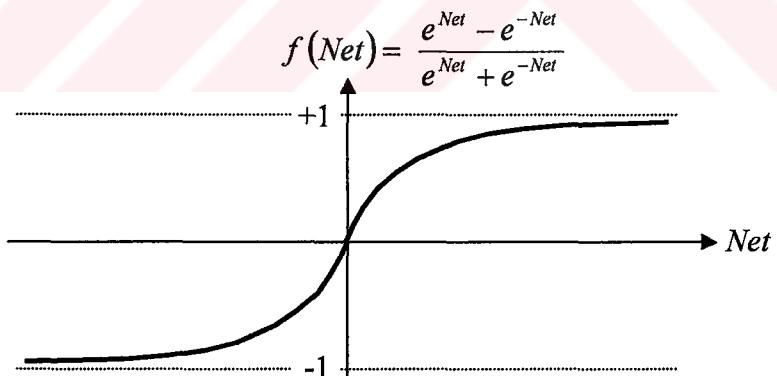
Şekil 2. 3 Çök Katmanlı YSA

2.3 Geri Yayılmış YSA'da Kullanılan Transfer Fonksiyonlar

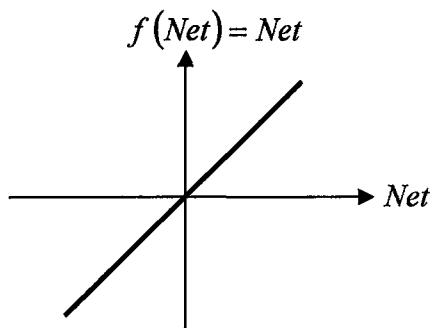
Pek çok transfer fonksiyonu mevcuttur. Transfer fonksiyonunun seçimi önemlidir. YSA algoritması seçilen transfer fonksiyonuna göre tasarlanır. En yaygın olarak kullanılanları log-sigmoid, tan-sigmoid ve lineer transfer fonksiyonları olup grafikleri aşağıda verilmiştir.



Şekil 2. 4. Log-sigmoid Transfer Fonksiyonu



Şekil 2. 5. Tan-sigmoid Transfer Fonksiyonu



Şekil 2. 6. Lineer Transfer Fonksiyonu

Log-sigmoid transfer fonksiyonu,

$$f(Net) = \frac{1}{1 + e^{-Net}} \quad \text{olup birinci ve ikinci dereceden türevleri}$$

$$f'(Net) = f(Net)(1 - f(Net))$$

$$f''(Net) = f(Net)(1 - f(Net))(1 - 2f(Net))$$

Tan-sigmoid transfer fonksiyonu,

$$f(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \quad \text{olup birinci ve ikinci dereceden türevleri}$$

$$f'(Net) = 1 - f^2(Net)$$

$$f''(Net) = -2f(Net)(1 - f^2(Net))$$

Lineer transfer fonksiyonu,

$$f(Net) = Net \quad \text{olup birinci ve ikinci dereceden türevleri}$$

$$f'(Net) = 1$$

$$f''(Net) = 0$$

Yapay sinir ağında kullanılan transfer fonksiyon log-sigmoid ise bütün veriler 0 ile 1 arasında dağıtilır. Bu işlem ve geri dönüşüm için aşağıdaki denklemler kullanılır.

$$v_n = \frac{v - v_{\min}}{v_{\max} - v_{\min}}$$

$$v = v_{\min} + (v_{\max} - v_{\min})v_n$$

Eğer verilerin 0 ile 1 arasına değil de $0 < a < b < 1$ olmak üzere a ile b arasına dağıtılması istenirse, dağıtma ve geri dönüşüm için aşağıdaki iki denklem kullanılır.

$$v_n = a + (b - a) \left(\frac{v - v_{\min}}{v_{\max} - v_{\min}} \right)$$

$$v = v_{\min} + (v_{\max} - v_{\min}) \left(\frac{v_n - a}{b - a} \right)$$

Kullanılan transfer fonksiyon tan-sigmoid ise bütün veriler -1 ile +1 arasında dağıtilır. Bu işlem ve geri dönüşüm için aşağıdaki denklemler kullanılır.

$$v_n = \frac{2v - v_{\min} - v_{\max}}{v_{\max} - v_{\min}}$$

$$v = (v_{\min} + v_{\max} + (v_{\max} - v_{\min}) \cdot v_n) / 2$$

Kullanılan transfer fonksiyon lineer ise bütün giriş ve çıkış değerleri aynı tan-sigmoid'te olduğu gibi -1 ile +1 arasına dağıtilacak şekilde ayarlanır.

2.4 Geri Yayımlı YSA'da Öğrenme

YSA'lar belirli bir probleme göre programlanmadıkları halde o problemi çözmeyi öğrenebilirler. YSA için öğrenme giriş vektörleri ile karşılık gelen çıkış vektörleri arasında bir çeşit bağlantı kurmak diye tanımlanabilir. Öğrenme ağırlık değerlerindeki uygun değişimeler ile sağlanır. Uygun bir şekilde eğitilen ağı, daha sonra kendisine sunulan ve eğitim setinde bulunmayan verilere de uygun cevaplar verecektir. YSA'lar bu özelliklerinden dolayı çok değişkenli sistemlere kolaylıkla uygulanabilmektedirler.

Eğitme aşaması hem ilerleme hem de geri yayılma safhalarını içerirken, kullanma aşaması sadece ilerleme safhasını içerir. Ayrıca eğitme aşamasında hata minimize olana kadar bu iki safha devamlı tekrarlanır. Bu yüzden eğitme aşaması kullanma aşamasına göre oldukça yavaştır. Eğitme aşamasında kullanılan geri yayılma algoritmasının özü, ilerleme sonucu ortaya

çıkan hatayı geriye doğru yansıtarak ağırlıkları daha doğru sonuçlar verecek şekilde düzeltmektir. Buna genelleştirilmiş delta kuralı denir ve aşağıdaki adımlardan oluşur.

1. Eğitim kümesinden bir sonraki eğitim çiftini seç (Giriş vektörü ve karşılık gelen çıkış vektörü).
2. Giri \vec{s} vektörünü ağın girişlerine uygula ve ağ çıkışlarını hesapla.
3. Ağ çıkışları ile çıkış vektörü (hedef vektör) arasındaki hatayı hesapla.
4. Hatayı küçük tecek şekilde ağın ağırlıklarını ayarla.
5. Hata istenen seviyeye ulaşana kadar yukarıdaki işlemleri tekrarla.

Kullanma aşamasında ağırlıklar verilen girişlere karşılık gelecek çıkışları bulmak için kullanılır. Zaten bu aşamada gerçek sonuçlar bilinmediğinden hatanın hesaplanması geri yansıtılması mümkün değildir.

Eğitimde kullanılan veriler ne kadar çok, çeşitli ve sağlam olursa öğrenme o kadar etkin olur. Fakat bütün veriler eğitim için kullanılmamalı, bazıları test etmek için saklanmalıdır. Eğer hiç eğitilmemiş verilerle de doğru sonuçlar veriyorsa ağ veriler arasındaki bağlantıları doğru kurmuş ve kullanılmaya hazır demektir. Eğer büyük hatalar oluşuyorsa ağı daha çok veya daha iyi veriler ile tekrar eğitmek gerekecektir. Ayrıca ağıda kullanılan nöron sayısını değiştirmek de işe yarayabilir.

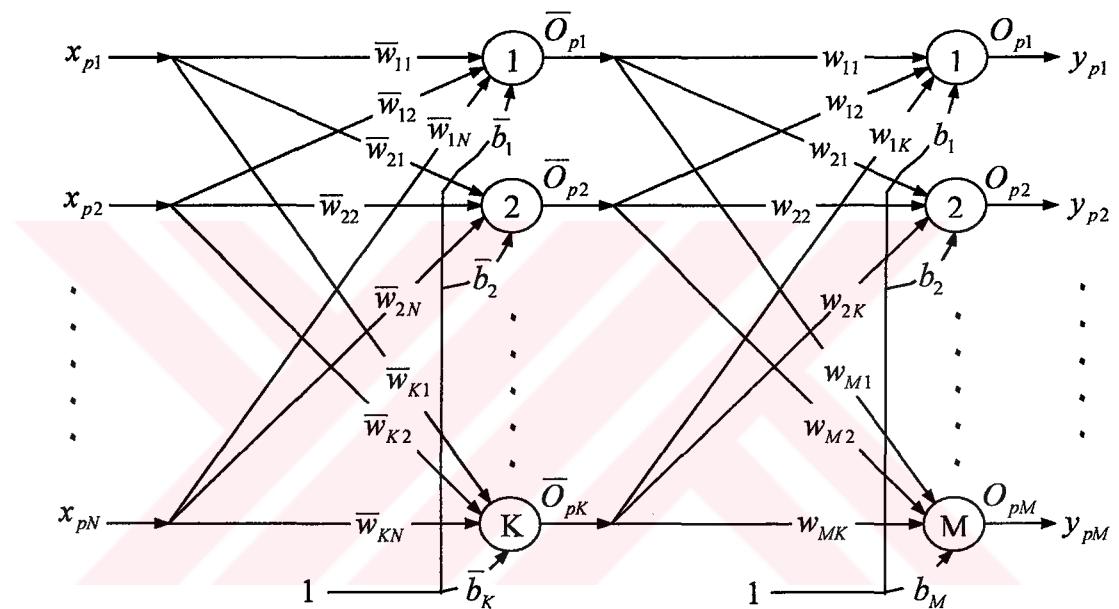
Öğrenme hızı ağın büyülüğüne ve vektör sayısına bağlı olmakla beraber eğitimi hızlandıracak bazı eğitim parametrelerinden de yararlanılmaktadır. Bunlar; Eğitim oran (η), Momentum (α) ve Bias (b) parametreleridir. η ve α parametreleri 0 ile 1 arasında uygun değerlerde seçilmelidirler. Örneğin $\eta = 0.4$, $\alpha = 0.6$ gibi. Bu seçim kullanılan verilere ve transfer fonksiyonuna göre değişebilir. Deneme yanılma ile uygun değerler seçilebilir. Bu parametreler çok küçük seçilirlerse eğitim yavaşlar, büyük seçilirlerse de eğitim gerçekleşmeyecektir. Bias parametreleri ise her bir nörona fazladan bir ağırlık eklemek şeklinde olup eğitimi oldukça hızlandırır.

Eğitim işlemi yapılrken ağ, yerel veya genel olup olmadığı bilinmeyen bir en küçük değere ulaşır. Eğer hata değeri yerel en küçük değere ulaşmışsa, bir süre sonra ağın çıkışındaki hata istenmeyen şekilde yükselebilir. Bu problem genellikle fazla bir zorluğa sebep olmaz. Eğer ağ istenilen bir çözüme ulaşmadan durursa, ara birimlerde veya eğitim parametrelerinde değişiklik yapılarak veya başlangıç ağırlık değerleri farklı bir değer aralığında seçilmesi ile

problem çözülür. Bir ağ istenilen bir çözüme ulaştığında, bu çözümün genel en küçük hata değeri olduğu tam olarak söylememez, fakat önemlide değildir.

2.5 Geri Yayılımlı YSA Denklemleri

Katman sayısının fazla olması iyi olmakla beraber hesapsal yükü üssel bir biçimde artıracagından pratikte genel olarak üç katmanlı ağlar kullanılır. Üç katmanlı bir ağın genel yapısı Şekil 7'de gösterilmiştir.



Şekil 2.7 Üç Katmanlı Yapay Sinir Ağı

Giriş katmanı veri işlemez. Dışarıdan aldığı verileri ara katmana ileter. Ara katman çıkışları

$$\bar{O}_{pk} = f(\bar{b}_k + \sum_{n=1}^N \bar{w}_{kn} x_{pn}), \quad p = 1, \dots, P, \quad k = 1, \dots, K$$

Çıkış katmanı ara katman çıkışlarını kullanır. Çıkış katmanı çıkışları

$$O_{pm} = f(b_m + \sum_{k=1}^K w_{mk} \bar{O}_{pk}), \quad p = 1, \dots, P, \quad m = 1, \dots, M$$

Herhangi bir veri için hata

$$E_p = \frac{1}{2} \sum_{m=1}^M (y_{pm} - O_{pm})^2$$

Bütün verileri kapsayan toplam hata

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M (y_{pm} - O_{pm})^2$$

Ağırlık düzeltme miktarları

$$\begin{aligned}\Delta w_{mk}(t+1) &= -\eta \frac{\partial E_p}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) \\ &= -\eta \frac{\partial E_p}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial w_{mk}} + \alpha \Delta w_{mk}(t) = \eta \delta_{pm} \bar{O}_{pk} + \alpha \Delta w_{mk}(t)\end{aligned}$$

$$\begin{aligned}\Delta b_m(t+1) &= -\eta \frac{\partial E_p}{\partial b_m} + \alpha \Delta b_m(t) \\ &= -\eta \frac{\partial E_p}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial b_m} + \alpha \Delta b_m(t) = \eta \delta_{pm} + \alpha \Delta b_m(t)\end{aligned}$$

$$\begin{aligned}\Delta \bar{w}_{kn}(t+1) &= -\eta \frac{\partial E_p}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E_p}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{w}_{kn}} + \alpha \Delta \bar{w}_{kn}(t) = \eta \bar{\delta}_{pk} x_{pn} + \alpha \Delta \bar{w}_{kn}(t)\end{aligned}$$

$$\begin{aligned}\Delta \bar{b}_k(t+1) &= -\eta \frac{\partial E_p}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) \\ &= -\eta \sum_{m=1}^M \frac{\partial E_p}{\partial O_{pm}} \frac{\partial O_{pm}}{\partial \bar{O}_{pk}} \frac{\partial \bar{O}_{pk}}{\partial \bar{b}_k} + \alpha \Delta \bar{b}_k(t) = \eta \bar{\delta}_{pk} + \alpha \Delta \bar{b}_k(t)\end{aligned}$$

Düzeltme miktarlarının ağırlıklara ilavesi

$$w_{mk}(t+1) = w_{mk}(t) + \Delta w_{mk}(t+1)$$

$$b_m(t+1) = b_m(t) + \Delta b_m(t+1)$$

$$\bar{w}_{kn}(t+1) = \bar{w}_{kn}(t) + \Delta \bar{w}_{kn}(t+1)$$

$$\bar{b}_k(t+1) = \bar{b}_k(t) + \Delta \bar{b}_k(t+1)$$

Ara ve çıkış katmanında log-sigmoid transfer fonksiyonu kullanılırsa

$$\delta_{pm} = O_{pm} (1 - O_{pm}) (y_{pm} - O_{pm})$$

$$\bar{\delta}_{pk} = \overline{O}_{pk} (1 - \overline{O}_{pk}) \sum_{m=1}^M \delta_{pm} w_{mk}(t)$$

Ara ve çıkış katmanında tan-sigmoid transfer fonksiyonu kullanılırsa

$$\delta_{pm} = (1 - O_{pm}^2) (y_{pm} - O_{pm})$$

$$\bar{\delta}_{pk} = (1 - \overline{O}_{pk}^2) \sum_{m=1}^M \delta_{pm} w_{mk}(t)$$

Ara katmanda tan-sigmoid çıkış katmanında lineer transfer fonksiyonu kullanılırsa

$$\delta_{pm} = y_{pm} - O_{pm}$$

$$\bar{\delta}_{pk} = (1 - \overline{O}_{pk}^2) \sum_{m=1}^M \delta_{pm} w_{mk}(t)$$

elde edilir.

3. DONANIMDA YSA GERÇEKLEME

Bir YSA modeli; yazılımsal veya donanımsal olarak gerçekleştirilebilir. Donanımsal gerçeklemeyle karşılaşıldığında yazılımsal gerçekleme; hem basit hem ucuzdur ve düşük performans gerektiren yapay sinir ağı sistemleri genellikle yazılımsal olarak gerçekleştirir. İşlemci performansları hızla gelişiyor, örneğin Intel Pentium serisinde sürekli bir gelişme var fakat gelinen son nokta yüksek performanslı YSA'lar için halen yetersiz. Sıralı işlemler için hızlı olsalar bile, gerçek zamanlı çalışan yüksek sayıda nöron ve sinaps içeren YSA'lar için yetersizler. Bu yüzden, yüksek hız gerektiren YSA'lar donanımsal olarak gerçekleştiriyorlar.

Başka bir sebepte, taşınabilir makinelerde ergonomik olmaları için PC yerine daha hafif olan özelleşmiş tasarımların kullanılması. Örneğin, koku sensörü patlayıcı gazları algılamak için kullanılıyor. Bundan dolayı, gerçek zamanlı ölçüm yapabilen ve taşınabilir küçük boyutlara sahip olacak şekilde tasarlanması gerekiyor. Bu kısıtlamalar bizi tasarımda kullanılacak yapay sinir ağlarını tasarlama için, donanımı seçmemizde etkili oldu.

3.1 HDL

Orta ölçekli bir dijital devrede, 30bin-100bin arası lojik kapı bulunur. Bunların tamamen insan emeği ile tasarlanması neredeyse imkansızdır, çok uzun zaman alır ve hata yapmaya çok açktır. Bu yüzden, HDL (hardware description language - donanım tanımlama dili) denilen diller geliştirilmiştir. HDL sayesinde tasarımcı, tasarımını kod yazarak gerçekleştirir ve bilgisayar yazılımı bu kodu sentezleyerek, transistör seviyesinde devreyi üretebilir. Verilog ve VHDL en çok bilinen HDL'lerdir.

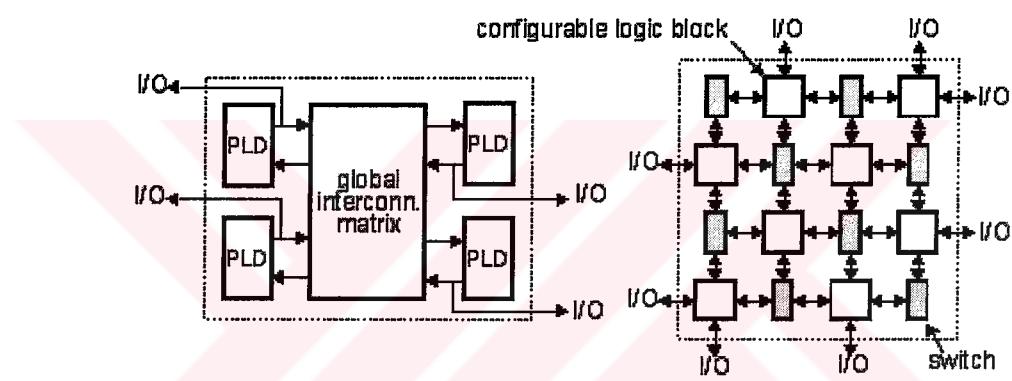
HDL ile tasarım üst düzey register transferleri ile (RTL : register transfer level) veya kapı seviyesinde (gate level) yapılabilir. HDL'de devrenin her bloğu, bir "modül" olarak adlandırılıp, bu modüller gerektiğinde başka devrelerin alt devreleri olarak tekrar kullanılabilirler.

3.2 FPGA

Devre tasarımını kadar layout tasarımını da artık insan emeğini aşmış durumdadır. Aynı zamanda, birkaç bin adet üretim/satış bile chip tasarımını ve üretim hazırlığı maliyetlerini karşılayamayabilir. Çoğu durumda, daha önceden seri olarak üretilmiş, programlanabilir chip'ler kullanmak, ASIC üretmekten veya üretirmekten çok daha uygun olmaktadır.

Programlanabilir chip'lerin en bilinen örneği mikroişlemcilerdir. Mikroişlemciler, kendi komut setinde yazılmış komutlar dizisini yani programı, adım adım işletecek işlev görürler.

Ama paralel olarak yürütmesi gereken, yazılımla gerçekleştirilmesi uygun olmayan uygulamalar için programlanabilir kapı dizileri (PGA : programmable gate array) kullanılabilir. PGA'ler, içerisinde belirli bir tip kapıdan çok sayıda bir matris şeklinde bulunduran ve bu matris içindeki belirli bağlantılar yakıtlarla istenilen devrenin elde edilmesini sağlayan devrelerdir. Yine de çok karmaşık işlemler için ve özellikle de gerçekleştirildiği fonksiyon zamanla değiştirilmesi gerektiğinde PGA'ler yeterli değildir. Bu gibi yerlerde CPLD (complex programmable logic device) ve FPGA (field programmable gate array) kullanılabilir. Bu iki tip entegre devreler birbirine çok benzemekle birlikte, devre mimarisleri ve konfigürasyon şekli ile birbirlerinden ayırlırlar.



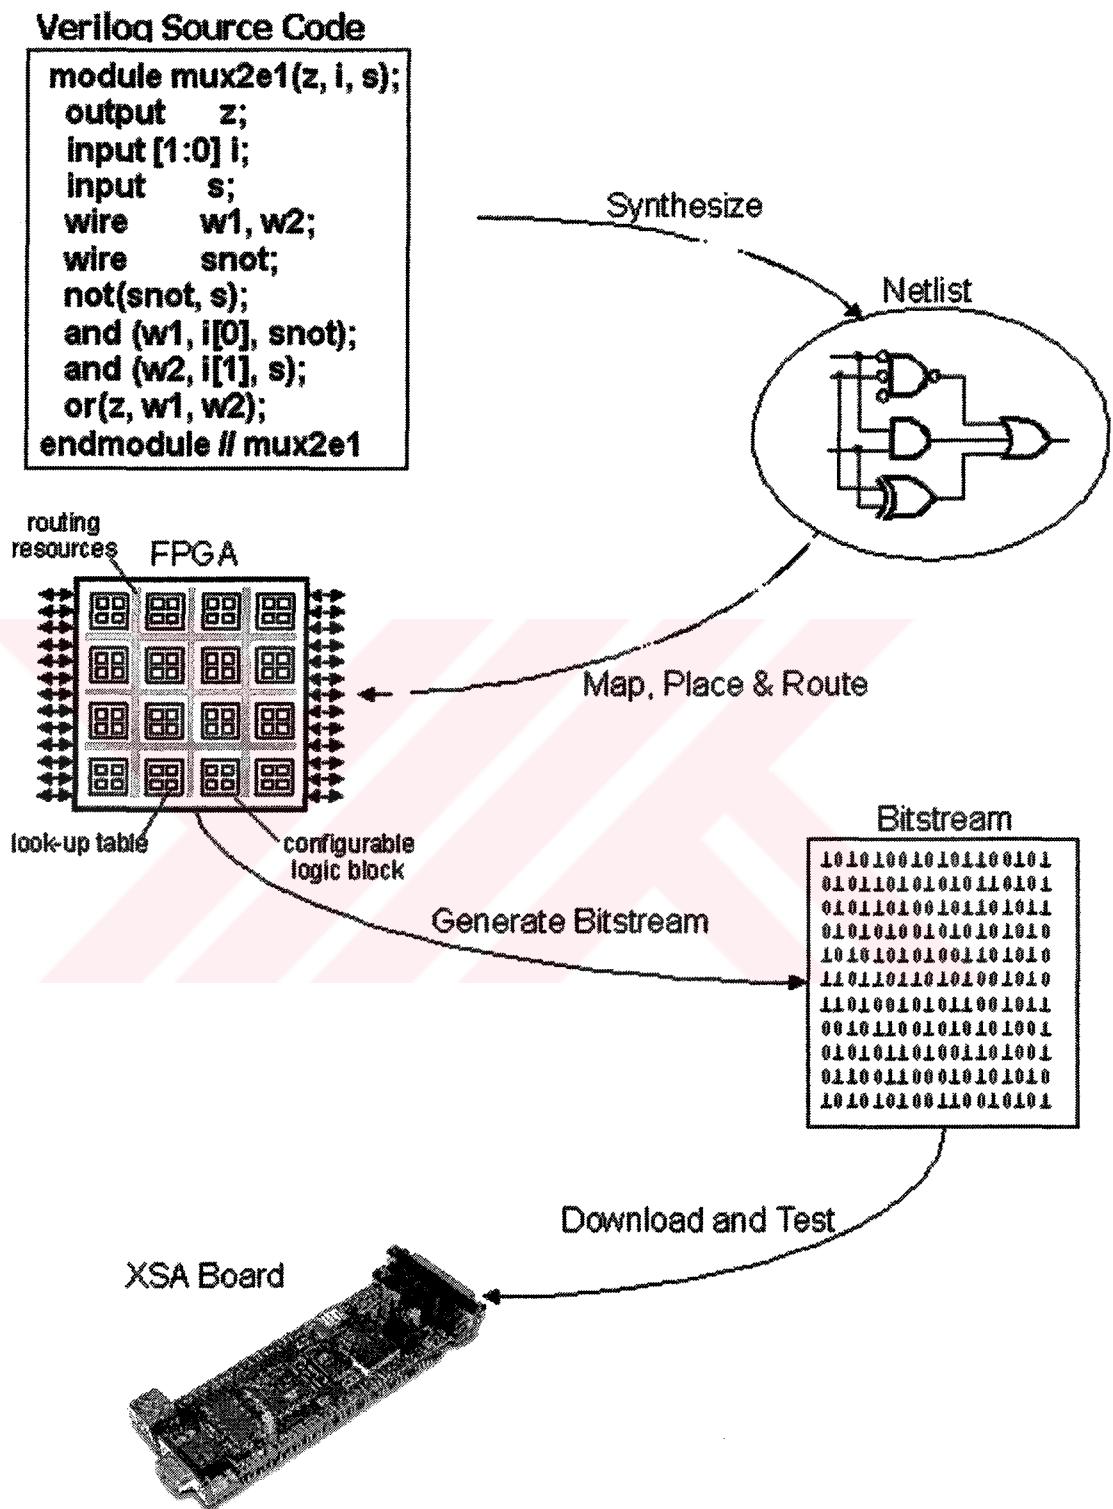
Şekil 3. 1 CPLD ve FPGA mimarisı

Bir FPGA, birkaç bin ile birkaç milyon arasında kapı içerebilir. Bu kapılar logic cell'ler, flip-flop'lar ve multiplexer'lar olarak gruplanmıştır ve bloklar arasında bir bağlantı yoktur. Ancak, chip çalışmaya başladığı anda konfigürasyon amaçlı kullanılan birkaç pini ile dışarıdan tasarım bilgisini alır. Tasarım yazılımı ile üretilen konfigürasyon dosyası, bir ROM'a yüklenir. FPGA bu tasarım dosyasındaki tasımı yükler ve kendisine verilen fonksiyonu gerçekleştirmeye başlar. Besleme kesildiğinde FPGA tekrar fabrika çıkış haline döner. Konfigürasyon bilgisi doğrudan FPGA'e bağlı bir ROM'dan alınabileceği gibi bazı uygulamalarda, aynı devre üzerindeki ROM kullanan başka bir chip'ten (DSP, microcontroller vs.) de alınabilir. Hatta PC tabanlı bazı uygulamalarda, FPGA, bağlı olduğu PC'den her açılışta konfigürasyonunu alır.

Günümüzde en önde gelen FPGA ve CPLD üreticileri Xilinx, Altera, Lattice, Actel ve Cypress gibi firmalardır. Xilinx, lider sayılabilecek bir firmadır. FPGA, CPLD, Configuration PROM'ları, çeşitli IP core'ler üretmektedir. Xilinx CoolRunner ailesi CPLD'leri düşük güç

tüketimi ile iddialıdır. CoolRunner'lar 3.3V cihazlardır, giriş çıkışları 5V'u da tolere edebilir. 750-12000 arasında kapı, 36-260 arasında I/O portu içerirler.

Xilinx Spartan ailesi FPGA'leri Spartan-II, Spartan-III gibi alt gruplara sahiptir. Çalışma gerilimi, kapı sayısı, I/O sayısı açısından farklı çok fazla ürüne sahip bir ailedir. Xilinx Virtex ailesi ise 8 milyondan fazla kapiya sahip modelleri ile, geniş ölçekli uygulamalara yöneliktedir. Kapı sayısı ve hız arttıkça FPGA'lerin fiyatları da artmaktadır ve Virtex ailesinde oldukça pahalı modeller vardır.



Şekil 3. 2 FPGA ile devre tasarımının aşamaları

3.3 FPGA ile YSA tasarıımı

Bu çalışmada, bir yapay sinir ağı modeli Xilinx Spartan-II Field Programmable Gate Array (FPGA) çip setli Xess Board kullanarak gerçekleştirildi. Xilinx firmasına ait yazılımlar kullanılarak tasarımlar hazırlandı. YSA modeli; dört girişli tek çıkışlı ve her bir işlemi 8 bit çözünürlükle yapabilecek şekilde tasarlandı. YSA'nın ağırlık değerleri, bilgisayarda hesaplandı ve FPGA'da çarpma işleri için kullanılan 8 bitlik saklayıcılara yüklenildi. Tasarlamış olduğumuz bu temel YSA modeli kullanılarak, senkronize çalışan karmaşık donanımsal YSA'lar yapılabilir.

3.3.1 Dataların gösterimi

Bu tasarımın giriş, çıkış ve ağırlık derlerinde doğal ikilik formatta sayılar kullanıldı. Bu çalışmada, doğal sayıların ikilik formata dönüştürülmesinde -8 ile 8 arasında değişen kodlama teknolojisi kullanıldı[4]. Bu kodlamada, basitçe dijital sayılar kullanılarak datalar temsil eder. Tablo 3.1'de bu kodlanma kullanılarak sayıların dijital olarak temsil edilmesi gösterilmiştir.

Tablo 3. 1 Dataları gösterimi

| Sayı | Dijital karşılığı |
|------------|-------------------|
| 0.5 | 1000 0000 |
| 0.25 | 0100 0000 |
| 0.125 | 0010 0000 |
| 0.0625 | 0001 0000 |
| 0.03125 | 0000 1000 |
| 0.015625 | 0000 0100 |
| 0.0078125 | 0000 0010 |
| 0.00390625 | 0000 0001 |
| 0 | 0000 0000 |

Tablo 3.2'de, bazı sayılar için bu kodlama sisteminden dolayı oluşan hataları görebilirsiniz. Bu kodlamayla sayılar dijital çeviriliğinde, saylarda çok küçük bir kayıp oluşuyor. Bu kodlamanın kullanıldığı YSA sistemlerinde, oluşan bu kaybın sistemin cevabında neden olduğu hata ihmal edilebilir kadar küçük[5].

Tablo 3. 2 Temsil edilen datalar

| Sayı | Sayıının dijital gösterimi | Dijital sayıdan geri elde edilen sayı |
|------------|----------------------------|---------------------------------------|
| 0.28534547 | 0100 1001 | 0.28515625 |
| 0.54120351 | 1000 1010 | 0.53906250 |
| 0.81504492 | 1101 0000 | 0.81250000 |

3.3.2 Çarpma

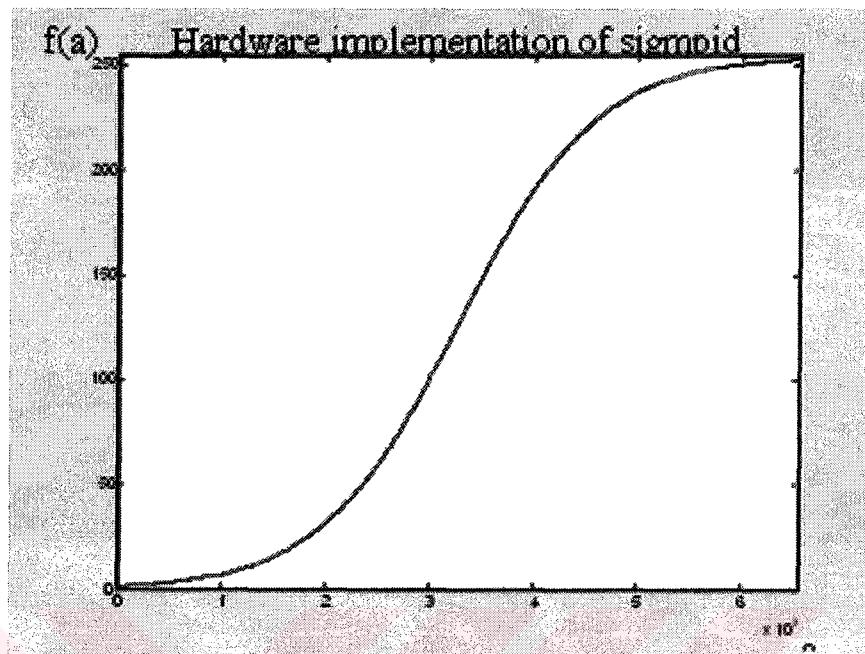
Çarpma devresi, yapay sinir ağındaki aritmetik işlemlerde kullanılan en önemli kısmıdır. YSA modelinde, 8 bitlik dört giriş ağırlık değerleri ile çarpılıp, sonuçları toplam saklayıcısında saklanıyor. (Şekil 3.5.). FPGA'nın kapı sayısı ve sistemin performansı göz önünde bulundurularak bir çok çarpma modelinden biri seçilebilir. Seri, paralel ve seri-paralel melez çarpma algoritmalarından biri seçilebilir[4,5]. Bu çalışmada, seri çapma devresi kullanıldı. Dışarıdan alınan giriş değerleri, seçiciler yardımı ile kendi ağırlık değerleri ile birlikte çarpma devresinin girişine gönderiliyor. Böylece, çarpma devresinin çıkışından her giriş ile ağırlık değerinin çarpımına ait 16 bitlik bir sayılar elde ediliyor. Bu sayılar, sırası ile bir sonraki çarpma işleminin sonucu ile toplanarak toplam data elde ediliyor.

3.3.3 Aktivasyon fonksiyonu (Sigmoid)

Aktivasyon fonksiyonlarında sigmoid fonksiyonu, genellikle 16 bitlik çarpma çıkışını 8 bite çevirmek için kullanılıyor. Çünkü, çıkış datasının değişim aralığı giriş datası ile aynı olmak sorunda, aksi takdirde sistem karasız olur. Aşağıdaki denklem geleneksel non-linear aktivasyon fonksiyonu gösteriyor.

$$y = \frac{1}{(1 + e^{-a})}$$

Yukarıdaki geleneksel aktivasyon formülü incelenirse, fonksiyonun direkt dijital tasarlama uygunduğu görülmeli. Çünkü, fonksiyon sonsuz eksponensiyel dizi içeriyor. Bazı teknolojiler kullanılarak sigmoid fonksiyonuna yakın dijital devreler yapılabilir[4,5]. Alternatif bir yöntem de bellek alanları kullanılarak bu işlemler yapmaktadır. Her iki yöntemde de fonksiyonun alabileceği değerler aralıklara bölünerek yaklaşık değerleri bulunuyor.



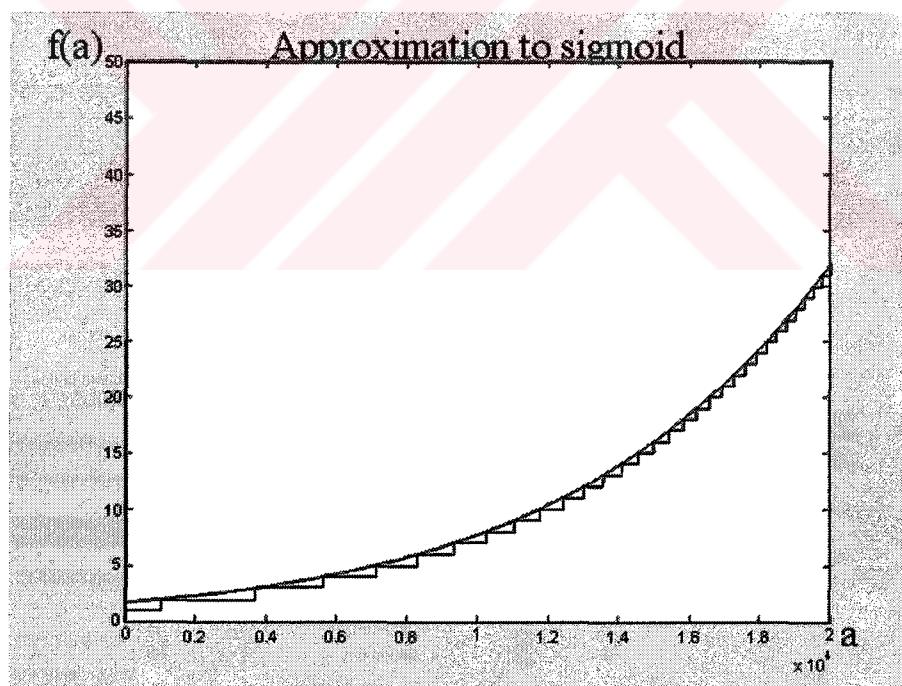
Şekil 3.3 Sigmoid fonksiyonun donanımda gerçeklenmesi

Tasarladığımız devrede, çarpmının çıkışı 16 bitlik ve kullandığımız Xess bordunun üzerinde 256 Kb'lık flash RAM mevcut. Bu RAM'ı kullanarak devredeki sigmoid fonksiyonunu gerçekledik. Şekil 3.3. donanımda yapılmış sigmoid fonksiyonunu gösteriyor, X eksenin RAM'daki adresleri Y eksenin ise RAM'daki değerleri gösteriyor (veya YSA'nın çıkışlarını).

Tablo 3.3'teki birinci sütun, flash RAM'ın adreslerini ve ikinci sütundaki verilerde onluk sayıları ifade ediyor. Sigmoid fonksiyonu 8 alana bölünmüş 64 K'lık RAM alanını kullanıyor. Her bölge 32 bloğa bölünmüş ve her blok benzer dataları tutuyor. Bu datalar, bilgisayarda hesaplanıp bordun üzerindeki RAM'a yükleniyor. Bordun üzerindeki FPGA ile RAM arasındaki bağlantılar FPGA'nın kullanabileceği şekilde dizayn edilmiş.

Tablo 3. 3 Tasarlan sigmoid fonksiyonuna ait bellek adresleri ve bu adreslere karşılık atanmış alanlar.

| INPUT | OUTPUT |
|----------------|------------|
| 0 .. 20012 | 0 .. 31 |
| 20013 .. 25568 | 32 .. 63 |
| 25569 .. 29420 | 64 .. 95 |
| 29421 .. 32767 | 96 .. 127 |
| 32768 .. 36115 | 128 .. 159 |
| 36116 .. 39967 | 160 .. 191 |
| 39968 .. 45520 | 192 .. 223 |
| 45521 .. 65536 | 224 .. 255 |



Şekil 3. 4 Sigmoid fonksiyonunu ve donanımsal yaklaşımı

Şekil 3.4.'de sigmoid fonksiyonu ile donanımsal olarak gerçekleşen sigmoid'ten elde edilmiş değerlerin karşılaştırılması görülmüyor. Grafikten de görüldüğü gibi, donanımsal yaklaşım ile elde edilen değerler ile sigmoid fonksiyonu arasında fark kabul edilebilir ölçülerde.

3.3.4 Nöronun modellenmesi

Yaptığımız nöron modeline ait devrenin şeması şekil 3.5.'te görülmüyor. Tasarlanan devre modüller, bu yüzden istenildiği taktirde YSA kolaylıkla genişletilebilir. Tasarım şu lojik bloklardan oluşuyor; 8 bit çarpma , 16 bit toplama, 8 bit saklayıcılar (W_0, W_1, W_2, W_3), 16 bit saklayıcı 8 yollu 4×1 'lik multiplexerler, bir dekoder, bir sayıcı ve bir kontroller. Aktivasyon fonksiyonu hariç bütün modüller Spartan II FPGA'da gerçekleştirildi. Gerçeklediğimiz bu devre donanımda büyük yer kapladı fakat hızı tatmin edilir ölçülerde.

Deney bordu olarak Xess firmasının üretmiş olduğu, XSA-50 bordu kullanıldı. Bord üzerinde programlanabilir iki adet çipe sahip; Xilinx Spartan 2-XC2S50 FPGA ve Xilinx XC9572 kompleks programlanabilir lojik çip (CPLD). Bord ; 8 Mbyte SDRAM, 128 Kbyte flash RAM, 100 MHz programlanabilir osilatör , 4 adet iki konumlu anahtar, 7 segment display ve PC bağlantısı için kullanılan standart portlara (paralel, PS/2 ve VGA portları) sahip. FPGA, CPLD, osilatör, flash ve SDRAM paralel port kullanılarak programlanıyor.

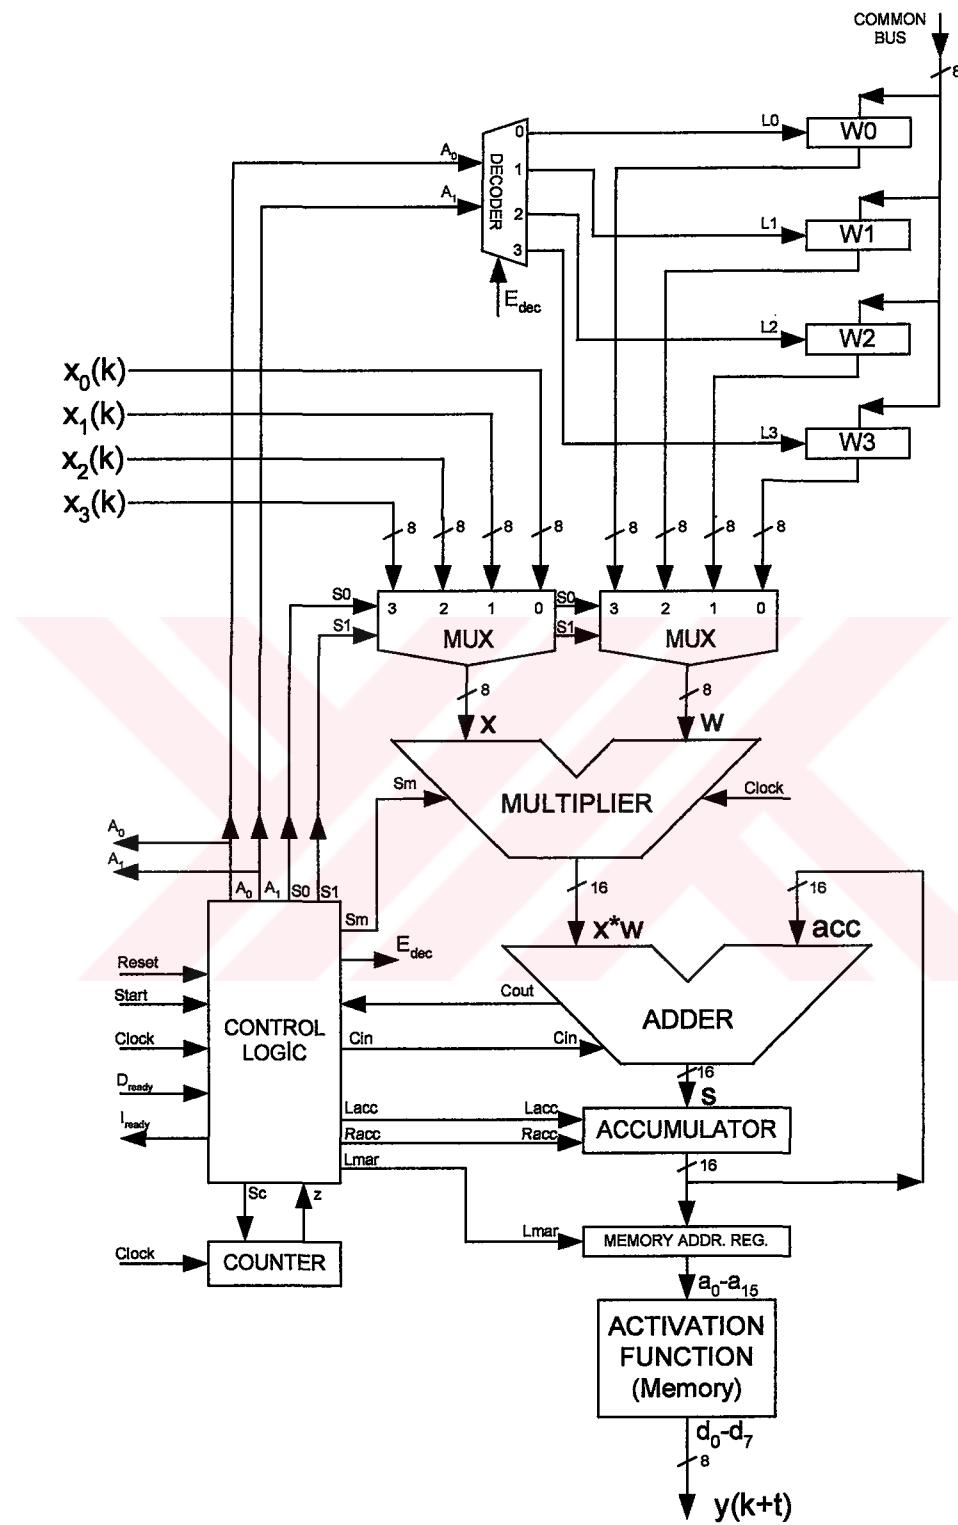
Tasarımların büyük çoğunluğu, Verilog-HDL kullanılarak kapı seviyesinde tasarlandı. Sadece çarpma işlemi davranışsal olarak tasarlandı. Bütün parçalar tek tek tasarlandı; saklayıcılar, çarpma, toplama, multiplexerler, dekoderler ve kontroller. Hepsi derlenip ayrı ayrı simülasyonları yapıldı. Kontrol devresi şekil 3.6.'daki durum diyagramı kullanılarak tasarlandı.

Tasarım sırasında kaynaklar dikkatli kullanılmalı çünkü, seçilecek algoritmalar tasarımın hem performansını hem de çipte kapladığı alanı etkileyecektir. Bir çok araştırmacı, geniş ölçekli projeleri az yer kaplamaları için seri olarak tasarlıyorlar. Biz tasarımımız hazırlarken buna dikkat etmek sorundayız çünkü, kullanmış olduğumuz XC2S50 FPGA 50.000 kapı ve 384 ayarlanabilir lojik alana (CLB) sahip. Devremiz, toplam 56 IO'ya sahip ve FPGA üzerinde kullanılabilir 176 IO var. Bazı IO'lar bord kaynakları için kullanılalar da bu tasarımımız için bir sorun değil.

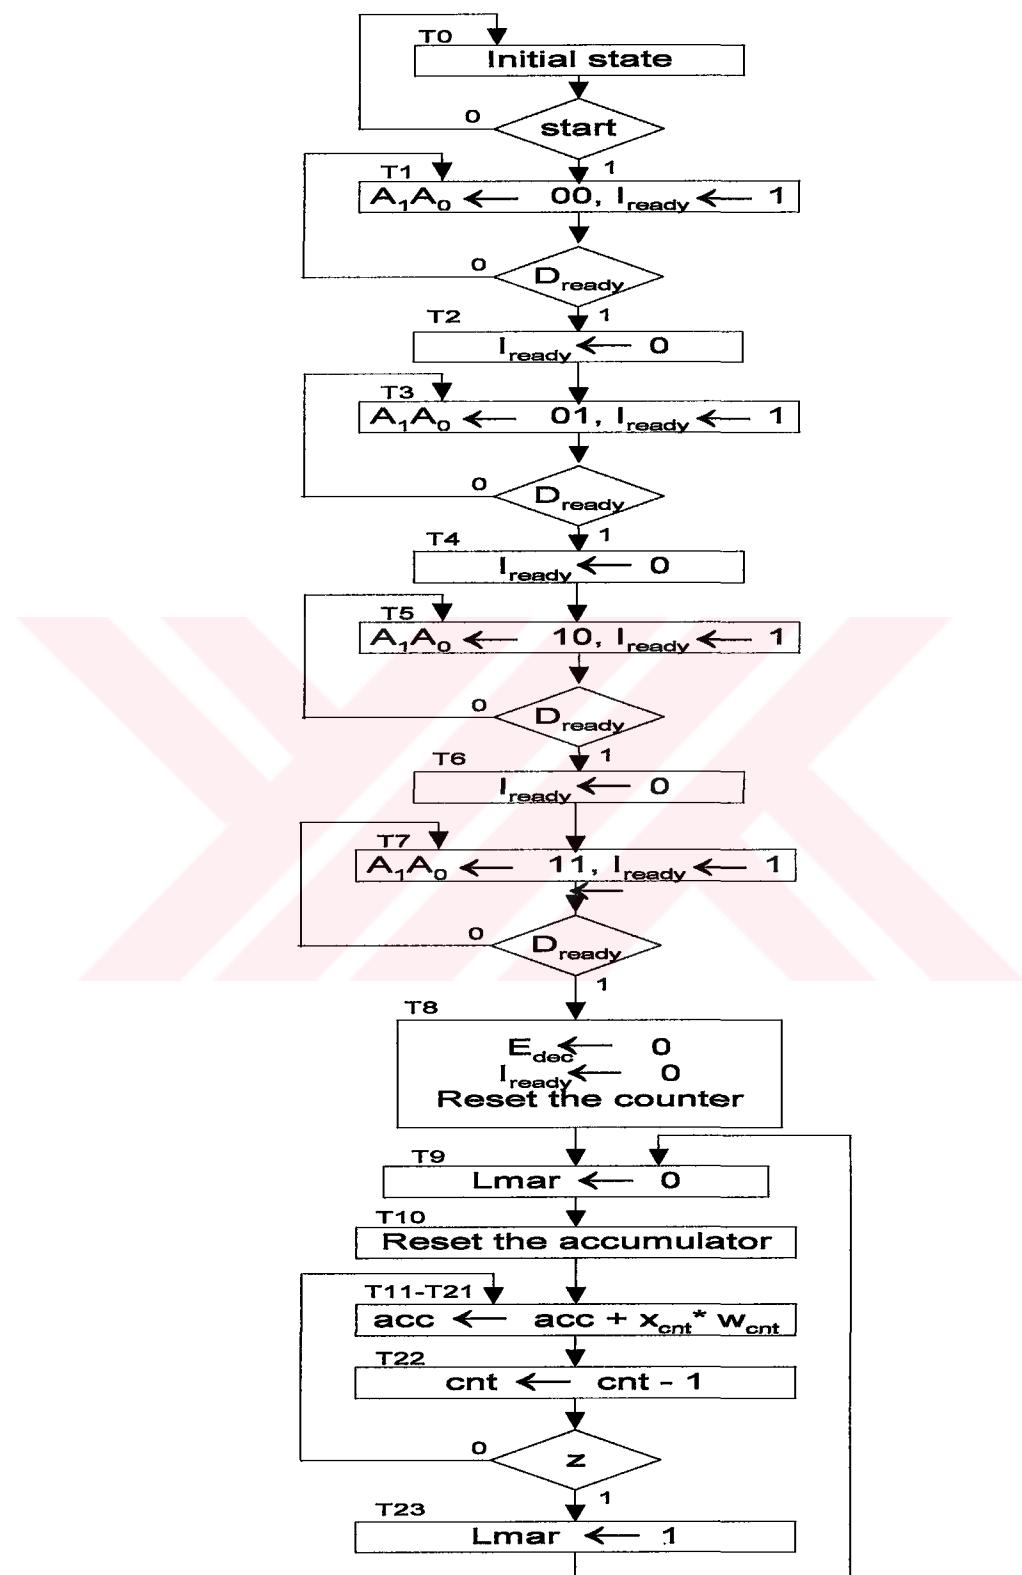
Bütün modüller FPGA'ya yüklenmeden önce, Xilinx firmasına ait olan ModelSim XE programı kullanılarak simülasyonları yapıldı. Bu program kullanılarak her modüle uygun değerler gönderildi ve doğru çalışıp çalışmadıkları test edildi. En son işlem olarak bütün modüller birleştirilerek devrenin tamamı test edildi. Bu test sonucuna ait ModelSim XE çıktısı şekil 3.7.'te görülmüyor.

Simülasyonlardan sonra elde edilen tasarım, Xilinx Project Navigator programı kullanılarak derlendi. Bu yazılıma ait bazı araçlar kullanılarak tasarımın hızı, devrelerin çipteki dağılımı ve çipte kapladığı alan bulundu. Tasarımı XC2S50 FPGA’ın içindeki kaynakların yaklaşık olarak 35%’ni kullanıyor. Bu tasarım, yapılan hesaplamalara göre maksimum 74.305 MHz’de çalışabilir.

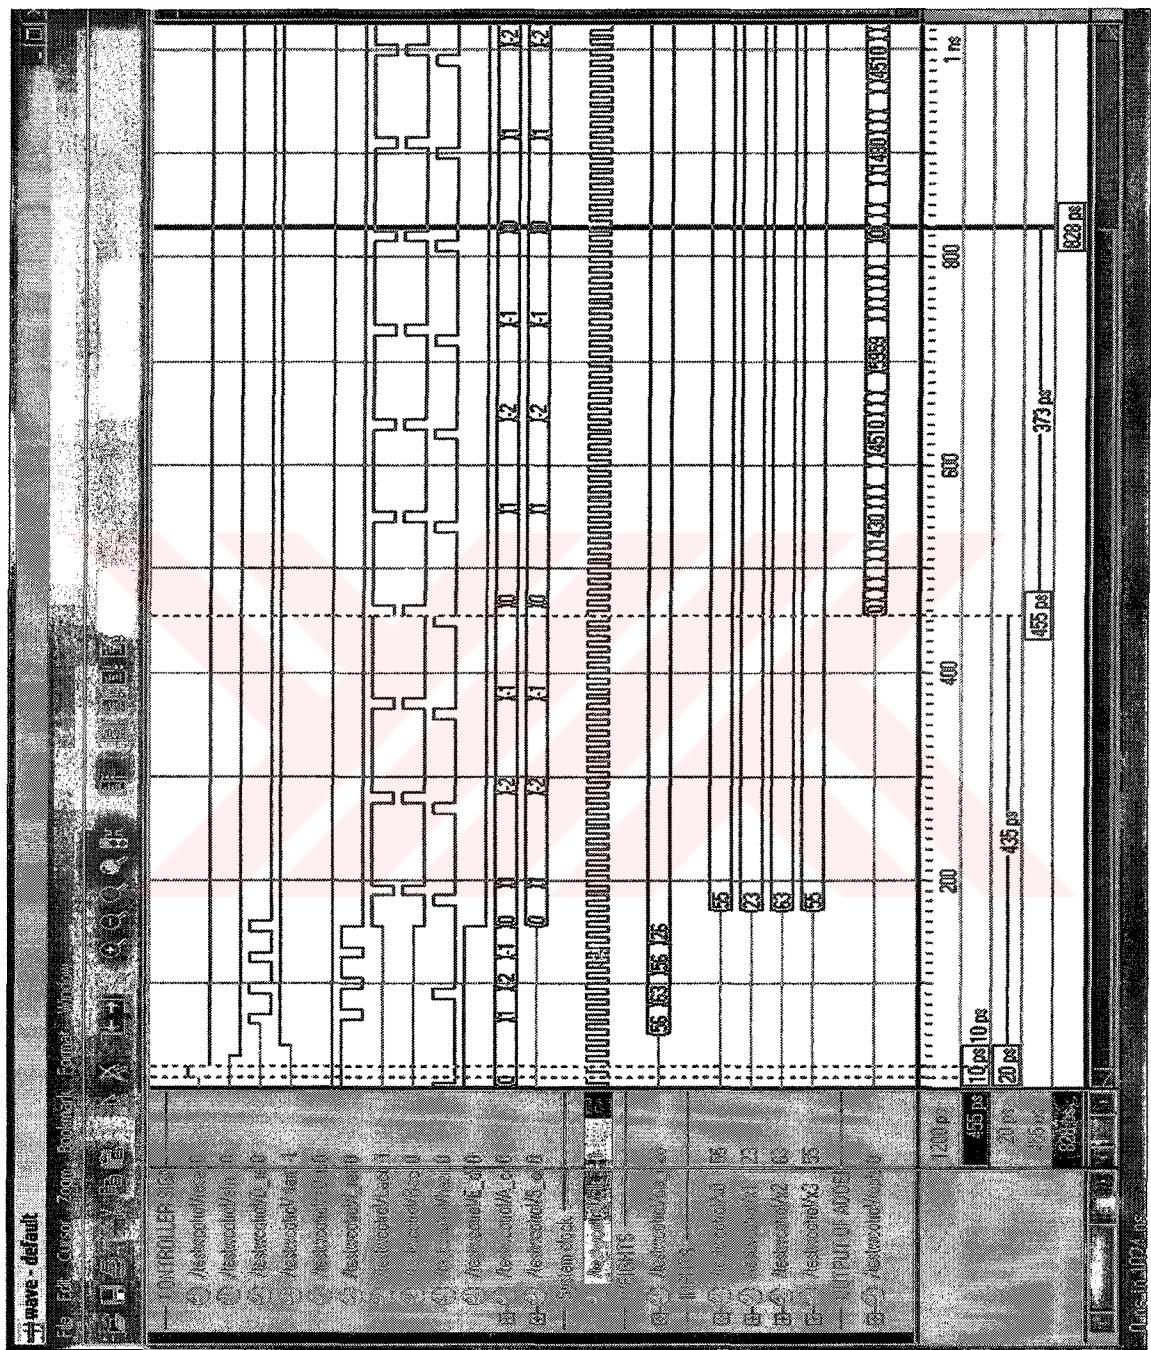




Şekil 3. 5Yapay Sinir Ağrı modelinin şeması



Şekil 3. 6 Kontrol devresinin durum diyagramı



Şekil 3. 7 YSA'nın simülasyonuna ait zaman diyagramları

4 YAZILIMDA YSA GERÇEKLEME

4.1 Matlab

Bu çalışmada YSA'yı yazılımda gerçeklemek için MATLAB kullanıldı. MATLAB; (MATrix LABoratory); ilk defa 1985'de C.B Moler tarafından matematik ve özellikle de matris esaslı matematik ortamında kullanılmak üzere geliştirilmiş etkileşimli bir paket programlama dilidir.

İlk sürümleri FORTRAN diliyle hazırlanmış olmakla beraber son sürümleri (1999 yılı itibariyle) C dilinde hazırlanmıştır. MATLAB mühendislik alanında (hesaplamalarında); sayısal hesaplama, veri çözümleri ve grafik işlemlerinde kullanılabilecek genel amaçlı bir program olmakla beraber özel amaçlı modüler paketlere de sahiptir. CONTROL TOOLBOX, SIGNAL TOOLBOX gibi paket programlar CACSD (Bilgisayar destekli denetim sistemi tasarıımı) paketler olup bunlar denetim sistemlerinin tasarımindan çok etkili araçlardır. Ayrıca WINDOWS ortamında çalışan SIMULINK, etkileşimli benzetim programlarının hazırlanması ve çalıştırılmasında büyük kolaylıklar sağlamaktadır.

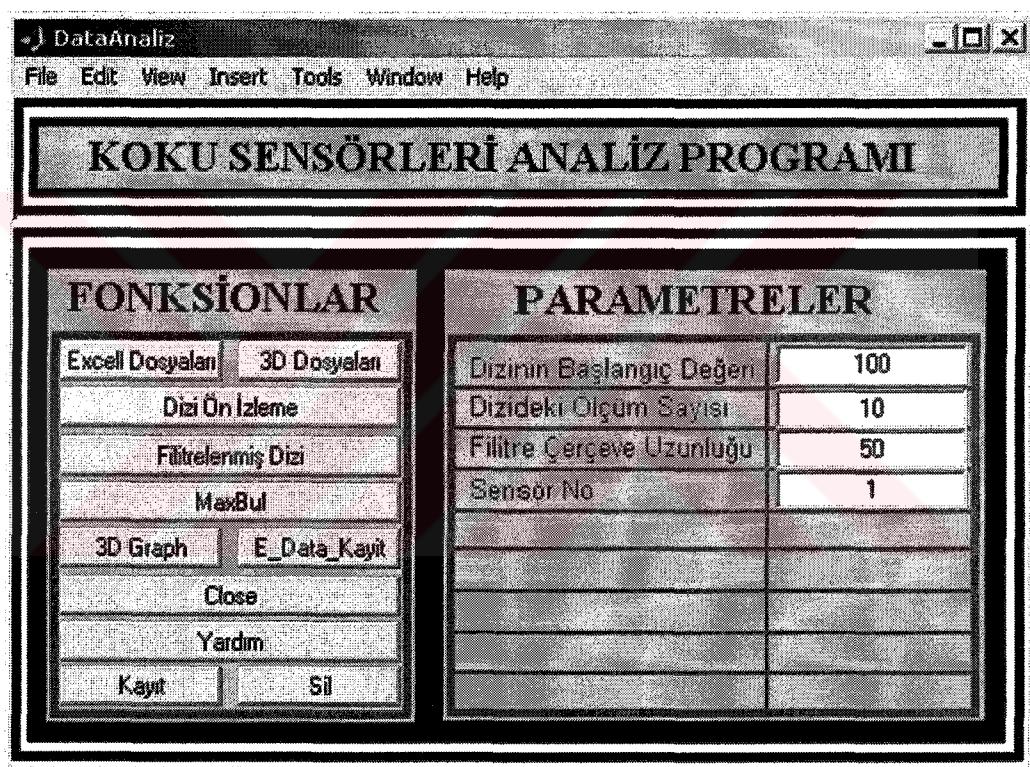
4.2 Matlab'ın kullanım amacı ve yeri

MATLAB tüm mühendislik alanında, sayısal hesaplamalar, veri çözümlemesi ve grafik işlemlerinde kolaylıkla kullanılabilen bir programlama dilidir. FORTRAN ve C gibi yüksek seviyeden programlama dilleri ile yapılabilen hesaplamaların pek çoğu MATLAB ile yapmak mümkündür. Buna karşılık MATLAB'ın fonksiyon kütüphanesi sayesinde FORTRAN ve diğer programlama dillerine göre MATLAB'ta daha az sayıda komutla çözüm üretmek mümkündür. MATLAB'ın kullanım yerleri;

- Denklem takımlarının çözümü, doğrusal ve doğrusal olmayan diferansiyel denklemlerinin çözümü, integral hesabı gibi sayısal hesaplamalar,
- Veri çözümleme işlemleri,
- İstatistiksel hesaplamalar ve çözümlemeler,
- Grafik çizimi ve çözümlemeler,
- Bilgisayar destekli denetim sistemi tasarımı.

4.3 Sensör analiz programı

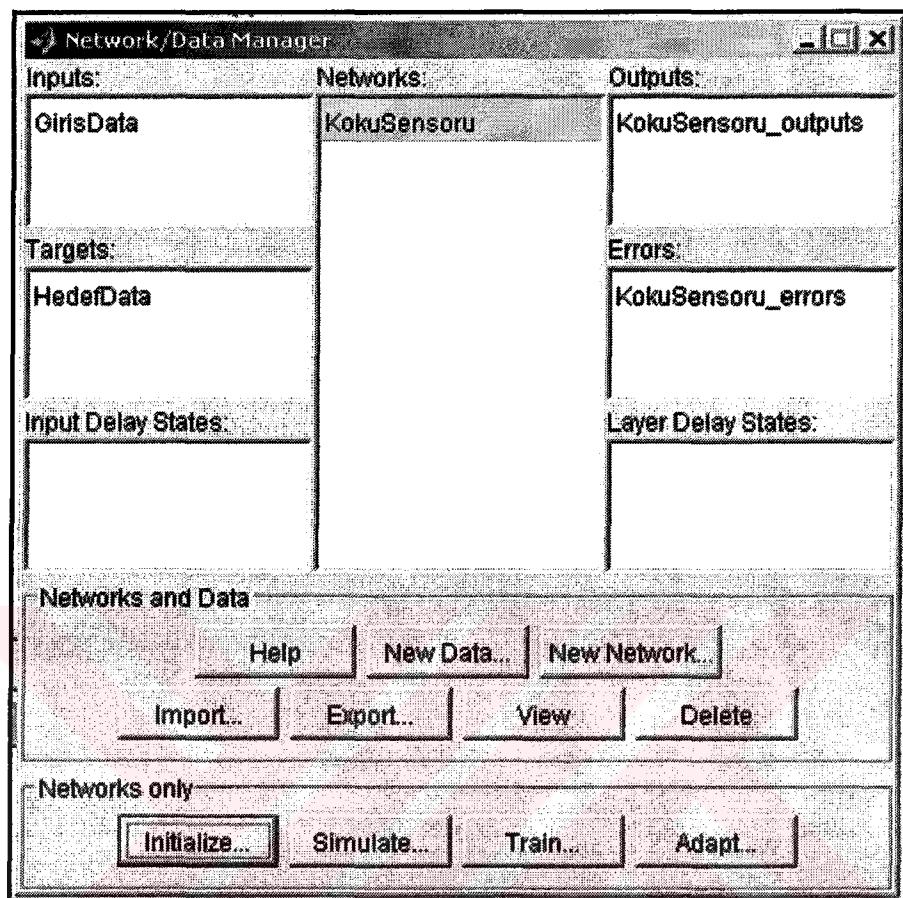
Datalar YSA'ya uygulanmadan önce matlab kullanılarak hazırlanan bir program yardımıyla düzenlendi. Bu program sensörlerden elde edilen datalardan oluşan dizilerin filtrelenmesi, her ölçüm aralığına ait maksimum noktanın bulunmasında ve değerlerin uygun aralıklara çekilmesinde kullanıldı. Sensör davranışlarının analiz edilmesi için bu program kullanılarak dataların iki ve üç boyutlu grafikleri çizildi. Böylece sensör davranışları daha iyi anlaşıldı. Bu bilgiler ışığında YSA tasarlandı. Eldeki dataların bir kısmı rasgele seçilerek YSA'nın doğruluğunu test etmek için kullanıldı. Geriye kalan data ile YSA'nın eğitimi yapıldı.



Şekil 4. 1 Sensör analiz programının kullanıcı ara yüzü

4.4 NNTOOL (Neural Network Tool)

Matlab'da YSA oluşturmak için iki farklı yol izlenebilir. Matlab'da YSA için hazırlanmış fonksiyonları kullanarak yada nntool'u kullanarak gerekli YSA tasarlabilir. Nntool; matlab'da hazırlanmış GUI'e (Graphical User Interfaces) sahip bir paket program.



Şekil 4. 2 NNTOOL

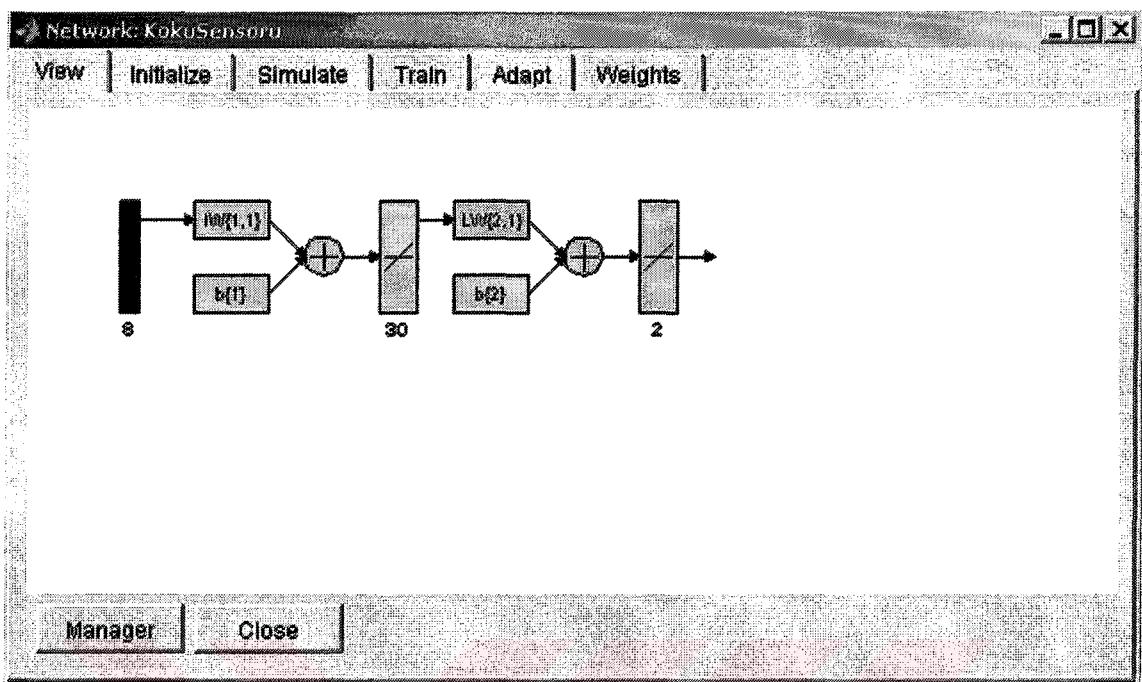
Şekil 4.2.'ta Nntool'a ait arayüz görülmüþdir. Nntool'da YSA'ı oluþturmadan önce, eğitim için kullanılacak giriş ve hedefdatalarının hazırlanması gerekiyor. Giriş ve hedefdatalar; YSA ile çözümlenmeye çalışılan problemin deneyler sonucunda elde edilmişdataların, bir kısmından oluşuyor. Giriş ve hedef için kullanılmayan datalar ise YSA eğitildikten sonra ağın doğruluðunu test etmek için kullanılıyor. Hazırlanmışdatalar, import seçeneðini kullanarak YSA'ya giriş ve hedefdatalar olarak ekleniyor.

Giriş, hedefdataları girildikten sonra NewNetwork butonu kullanarak yapay sinir ağını oluþturuluyor. Açılan menüde yaygın kullanılan YSA algoritmaların hepsi mevcut. Tablo 4.1'e nntool'da kullanabileceğiniz YSA çeşitleri ve bunlardan Feer-forward backprop seçtiðiniz zaman, bu YSA türü için kullanabileceğiniz diğer fonksiyonların listesi verilmiş.

Tablo 4. 1NNTOOL kullanılarak yapılabilen YSA çeşitleri

| YSA çeşitleri | Feer-forward backprop için geçerli | | | |
|------------------------------|------------------------------------|------------------------|-------------------------------|--------------------------|
| | Eğitim fonksiyonları | Transfer fonksiyonları | Adaptif Öğrenme fonksiyonları | Performans fonksiyonları |
| Competitive | TRAINBFG | LOGSIG | LEARNGD | MSE |
| Cascade-forward backprop | TRAINBR | PURELIN | LEARNGDM | MSEREG |
| Elman backprop | TRAINCGB | TANSIG | | SSE |
| Feer-forward backprop | TRAINCGF | | | |
| Time-delay backprop | TRAINCGP | | | |
| Generalized regression | TRAINGD | | | |
| Hopfield | TRAINGDM | | | |
| Liner layer (desing) | TRAINGDA | | | |
| Liner layer (train) | TRAINGDX | | | |
| LVQ | TRAINLM | | | |
| Perceptron | TRAINOSS | | | |
| Probabilistic | TRAINR | | | |
| Radial basis (exact fit) | TRAINRP | | | |
| Radial basis (fewer neurons) | TRAINSCG | | | |
| Self-organizing map | | | | |

Problemin çözümü için giriş, hedef data, YSA çeşidi ve diğer uygun parametreler oluşturulduktan sonra, ağıın eğitimini ve testi programdaki menüleri kullanarak kolaylıkla yapabiliyor. Şekil 4.3.'de nntool kullanılarak elde edilen YSA'nın şekli görülmüyor.



Şekil 4. 3 NNTOOL kullanılarak yapılan YSA'nının görünümü.

5. KOKU SENSÖRÜ VE SENSÖR DİZİLERİ

Sensör dizisi birden fazla sensörden oluşmuş n tane sensör grubudur. Uçucu bir kimyasal bileşen sensör dizisiyle temas geçince elektriksel niceliği değişmektedir. Bir sensör dizisi, farklı türlerde yada aynı türde olsun, farklı birçok kimyasal ve kokuyu elektriksel nicelikleri değişterek tanımlayabilir. Kullanılan sensör dizisi; farklı örnekler için fark edilebilir şekilde farklı olan cevap üretmelidir. Bu nedenle dizi seçimi bireysel sensörler yerine dizinin geniş bir limitine cevap verebilen, cevaplarında özel olmamalıdır. Sensör seçimi uygulamaya göre yapılır. Önce birçok sensörün kullanıldığı elektronik burunlarla bir araştırma yürütülür ve daha sonra gerekli metodun geçerliliği ve uygulanabilirliği saptanır. Farklı sensörlerin verdiği tepkilere bağlı olarak uygun olan sensör bulunmalıdır.

Kullanılan sensör dizilerinde farklı yapılar:

5.1 Metal Oksit Yarıiletkenleri (Metal Oxide Semiconductors) (MeOX) (MeOx)

Metal oksit yarıiletken sensörler, yüzeydeki gaz adsorbsiyonu ve sıra yüzey reaksiyonlarının sebep olduğu iletim değişimidir. Sensör; elektrikle ısıtılmış seramik topak üzerine metal oksit malzemesinin ince, gözenekli bir film tortusu bırakması ve yüksek sıcaklıkta tavlanmasıyla yapılır. Bu cihazlar SnO_2 , ZnO , In_2O_3 , WO_3 , Fe_2O_3 , Ga_2O_3 , TiO_2 ve platin veya palladium gibi katalitik metallerin katkılamaıyla üretilirler. Sistemde direnci artıran, yarıiletken malzemenin iletim bandındaki elektronların yoğunluğunu azaltarak, sensör yüzeyi oksijen adsorbe ederek, algılayıcı malzemenin elektriksel iletimini azaltır. Sistemde 100 ile 600 °C arasında artırılan sıcaklık, yüzey reaksiyonlarının hızlanmasıdan ve kimyasal sistemdeki adsorbe edilmiş suyun çıkış bilgisine girişmesinden emin olmak için kullanılır. Çok yaygın kullanılan bir sensör (SnO_2); elektrik bağlantılarına da sahip ısıtılmış bir seramik taban üzerinde sinterlenmiş kalay oksit yapısıdır. Bu basit sensör dizileri, çapraz-reaktif sensör dizisi (cross-reactive sensör array) olarak kullanılabilir. Metal oksitlerin avantajı, gazlara karşı duyarlılıklarından dolayıdır.

5.2 Metal Oksit Yarıiletken Alan Etkili Transistörleri (Metal Oxide Semiconductor Field Effect Transistors) (MOSFET)

MOSFET sensörü katkılanmış bir yarıiletkenle katalitik metal kaplı bir izolatörden oluşur. Gaz, molekülleri katalitik yüzeyde tepki verirken, cihazın çıkış sinyali elektrik polarizasyonu sebebiyle sensördeki potansiyel değişimden FET'in I_d akım değişimleridir. Bu sensörler 100 ile 200 °C arasındaki sıcaklıklarda çalışırlar.

5.3 Yüzey Akustik Dalga Cihazları (Surface Acoustic Wave Devices) (SAW)

SAW cihazları; kuartz gibi piezoelektrik maddeler üzerinde dijite edilmiş elektrotların şekillendirilmesiyle üretilir. Seçici absorbe edici maddenin ince film kaplaması yüzey üzerinde biriktirilir. Rayleigh yüzey akustik dalgasını üreten bir radyo frekansı uygulanır. Moleküllerin yüzey üzerinde absorbe edilmesi, kütleyi artırır, dalga frekansını değiştirir. Sistemi belirleyici eşitlik, QCM için olan akustik ince katı filmleriyle aynı Sauerbrey eşitliği ile tanımlanır. Kütle birikmesinde sıcaklık kontrolü önemlidir. QCM ile birlikte cihazın cevabı, farklı zar özelliklerini kullanarak değiştirilebilir. Kullanılan kaplamalar; polimerler, lipidler ve kendiliğinden kurulan tek tabakalardır (self-assembled mono-layers). SAW cihazları birkaç yüz MHz frekansta çalıştırılır ve çok küçük yüzeylere sahiptirler. Her ikisi birden QCM cihazlarına kıyasla SAW için daha yüksek hassasiyet ve daha hızlı cevap özelliklerine sahiptir.

SAW cihazlarının QCM'e ek avantajları da vardır. Yeniden üretilenabilir karakteristiklerinden başka düşük maliyet ve imalatta fotolitografi metodu kullanılarak minyatürize edilebilirlik. Fakat neme karşı duyarlılıklıdır.

5.4 Polimerler-Kimyasal Dirençler (Conducting Polymers- Chemiresistors)

Direnç ölçümu üzerine kurulu gaz sensörleri, yaygın olarak kullanılmakta olan ince film polimerlerdir. Polipirol, bu sensörlerde en yaygın olarak kullanılan malzemedir. Polimerler; polimerin yapısı boyunca genişleyen, konuge edilmiş n elektron sistemine sahiptirler. Buharların emilmesi, iç zincir sekmesini, ana zincir iletimini, sayıcı elektrostatikleri ve bunların her birinin iletimini değiştirir. Monomerik değişimlerin farklı sınıfları üzerine kurulmuş polimerler bu sensörlerde kullanılmaktadır. Ölçülen genel özellik; uçucu moleküllerin polimerle ilişki içindeyken polimer direncindeki değişimdir. Değişen yapılar veya fonksiyonel gruplar polimerle birleştirilmiş ve farklı doping yapıcı iyonlar kullanılarak elde edilmektedir. Bunlar seçim ve hassasiyetteki değişimleri belirlemektedir.

İletici polimer sensörler çevre sıcaklığında çalışabilirler. İmalatları kolay olup güç tüketimini de düşürürler. İletici polimer sensörlerin cevap süreleri uzundur. Avantajları; küçük ebat, oda sıcaklığında çalışma ve polar (kutupsal) analitlere hassasiyetidir. Limitleri; sensör fabrikasyon yeniden üretilenabilirliği, nem hassasiyeti, zaman üzerine temel çizgi iletiminin yıgilması (drift off baseline conductivity over time), cevabın yeniden üretilenabilirliğinin noksantılılığı, dengeleme duyarlılığı ve ışık hassasiyetidir.

Alternatif polimer kaplı kimyasal rezistor sensör dizisi cihazı, siyah karbon organik polimer kompoziti üzerine kurularak Lewis ve yardımcıları tarafından geliştirilmiştir. İletken bir

malzeme olan karbon farklı polimerlerle birleştirilerek yapılabilir. Polimer kimyasal sensörler duyarlı oldukları bir gaz ortamda iken iletkenlikleri ve dielektrik özelliklerinde değişimler oluşmaktadır. Bunun sonucu olarak da sensörün direnci ve kapasitesi algılayıcı gaz nedeniyle büyümektedir.

5.5 Optik Sensörler (Optical Sensors)

Optik gaz sensörleri yapay burunlarda da sıkça kullanılmaktadır. Burada ışık kaynağı hem algılanan gazı hem de referans molekülü tahrif eder. Ölçülen sinyal; absorbe, yansıtma, floresanslık veya chemiluminescence özelliklerindeki optik değişimlerdir.

5.6 Kuartz Kristal Mikrobalans Sensörleri (Quartz Crystal Microbalance Devices) (QCM)

QCM sensörleri adsorbe edilen moleküllerin kütlesini ölçer. Aynı zamanda hacim akustik dalga sensörleri (BAW) ve kalınlık kayma mod sensörleri olarak da bilinirler. Aktif element, temel rezonans frekanslı bir piezoelektrik kristalidir. Kütle ilave edildiğinde yayının rezonans frekansı azalır. Frekans değişimi Sauerbrey eşitliği ile;

$$\Delta f = -(1/p_m k_f) f_0^2 (\Delta m/A)$$

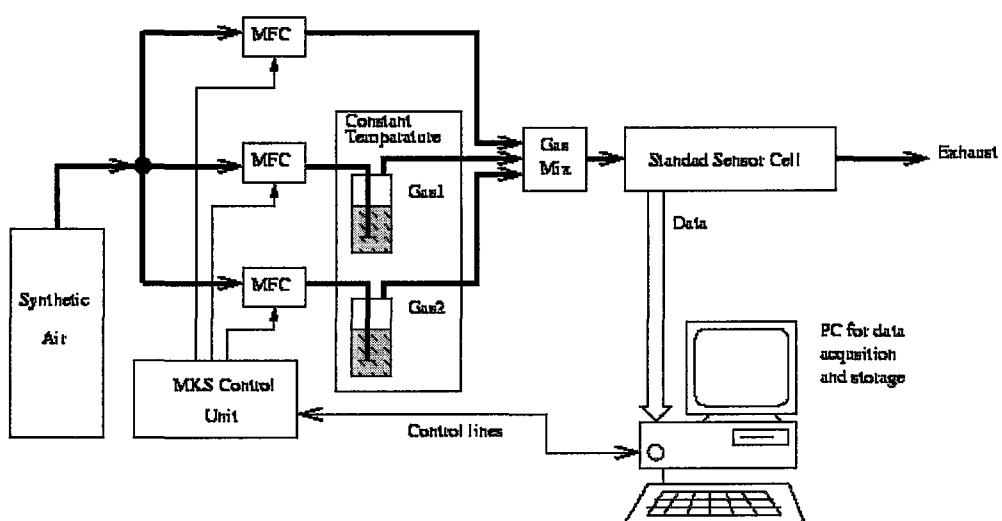
$$\Delta f = -2,3 \times 10^6 f_0^2 (\Delta m/A)$$

Δf ; absorbe edilen kütleden dolayı frekanstaki değişim, f_0 ise piezoelektrik kristalinin temel rezonans frekansıdır. Δm ; yüzey üzerinde biriken kütledir. A ise sensör alanıdır. Bu yüzden ölçülmüş frekansta ve cihazın kütle yükünde tahmin edilen liner bir değişme mevcuttur.

Kuartz kristali osilatör yüzeyi; algılayıcı kimyasal, absorbe edici maddenin ince bir filmi ile kaplıdır. Kullanılan malzemeler; ince polimer filmler, tek tabaka filmler ve yüzeye bağlı moleküllerdir. Moleküller absorbe edilirken, rezonans frekansı artan kütle yüzünden azalır. Frekans değişimi, sistemin çıkış sinyali olarak kullanılabilir.

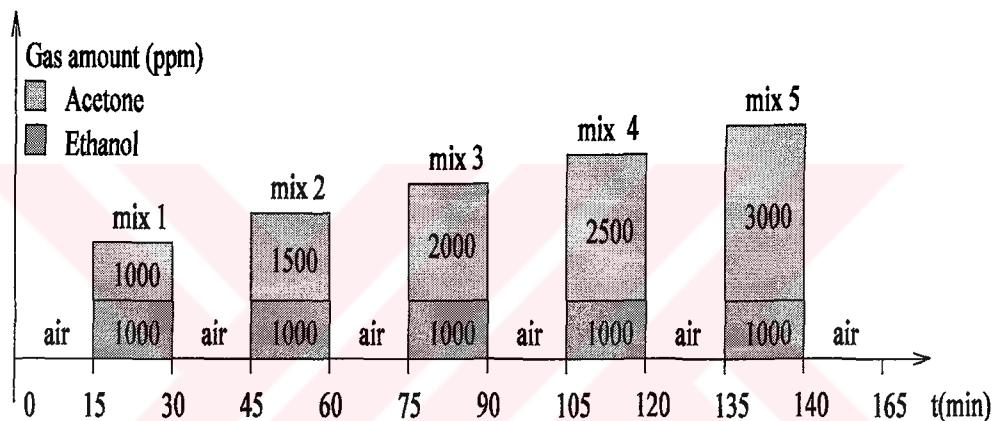
6. GAZ KARIŞIMLARINI QCM SENSÖR DİZİSİ VE YAPAY SINİR AĞI KULLANARAK BULUNMASI

Bu çalışmada; gaz karışımını niteliklerini ölçmede TUBİTAK Marmara Araştırma Merkezi, Malzeme Teknolojileri Enstitüsü'nde Sensör Gurubu'ncı geliştirilmiş sekiz adet Quartz Crystal Microbalances (QCM) den oluşan SCC kullanılmıştır. Şekil 6.1'deki deney düzeneği kullanılarak gaz karışımı SCC QCM sensörleri yardımıyla ölçüлerek gerekli datalar elde edilmiştir. Elde edilen datalar sensörlerdeki Δf 'lerdir. Her deneyde; kullanılan gazların türleri, karışımındaki oranları ve 8 sensöre ait Δf değerleri ayrıntılı olarak bilgisayar ortamında kaydedilmiştir. Çalışmalar sırasında üç farklı gaz karışımı SCC hücresına verilmiştir. Bu gazlar: (1) etanol ve aseton, (2) etanol ve trikloretilen, (3) aseton ve trikloretilen. Her deney temizleme ve gaz karışımının sensöre uygulanması olmak üzere toplam 165 dakika süren beş farklı gaz bileşiminin ölçülmesinden oluşuyor. Gaz oranları değiştirilerek etanol ve aseton için , etanol ve trikloretilen için , aseton ve trikloretilen için en az 25 olmak üzere toplam 75 farklı grup data alınmıştır. Daha sonra alınmış datalar geliştirdiğimiz Sensör Analiz Programı kullanılarak düzenlenendi. Öncelikle sensörlerin gaz karışımılarına verdikleri tepkilerden elde edilen sinyallere Sliding Window algoritması uygulanarak geçerli datalar elde edildi. Bu işlemden sonra elde edilen datalar kullanılarak üç katmanlı YSA eğitildi ve daha sonra eğitiminde kullanılmayan sensör dizisine ait datalar YSA'ya uygulanarak testler yapıldı. Böylece YSA'nın başarısı test edildi.



Şekil 6. 1. TUBİTAK-MAM'da kullanılan deney düzeneğinin şematik görünümü

Data logger her bir sensör için frekans farkını her 3-4 saniyede kaydedmektedir. Buradaki Δf ölçülen sensörün üretmiş olduğu frekans ile referans sensörünün üretmiş olduğu frekans arasındaki farktır. Deneylerde her sensör için data toplama yoluyla çok büyük bir data dizisi oluşturulmaktadır. Örneğin şekil 6.3. sensör 5'in, şekil 6.4 ise sensör 3'ün aseton ve trikloretilene karışımına karşı vermiş olduğu tepkileri göstermektedir. Şekil 6.3'teki ve şekil 6.4'teki her bir yüksek Δf değeri farklı orandaki gaz karışımılarını ifade ediyor; düşük Δf 'ler sensörün kuru hava ile temizlendiği yerleri göstermekte ve yüksek Δf değerleri ise gaz karışımının sensörlere uygulandığı yerleri ifade etmektedir.



Şekil 6. 2. Etanol sabit tutularak asetonun değiştirilmesi ile farklı oranlarda elde edilen karışımlar.

Gaz karışımı sensörlere uygulandığında her sensörün gaza tepki olarak verdiği frekans cevabı kendi merkez frekansından (f_0) farklıdır. Sensörlerin yıkama fazlarındaki frekansları base line olarak adlandırılır. Her sensör için base line frekansı farklıdır. Örneğin üçüncü sensör için base line frekansı 2340 Hz'dır. Grafiklerdeki Δf_s sensör frekansları ile 10 MHz.'lik referans sensörünün frekansı arasındaki farkı gösteriyor.

6.1.TUBİTAK Marmara Araştırma Merkezi'nden alınmış datalog ve özellikleri.

Tablo 6. 1Aseton ve Trikloretilen gazlarına ait karışım oranları ve dosya isimleri

| | | TRIKLORETILEN | | | | |
|--------|---------------------|---------------|--------------|--------------|--------------|--------------|
| | dosya adı | tceaset1.txt | tceaset2.txt | tceaset3.txt | tceaset4.txt | tceaset5.txt |
| ASETON | konsantrasyon (ppm) | 1000 | 1500 | 2000 | 2500 | 3000 |
| | 250 | + | + | + | + | + |
| | 500 | + | + | + | + | + |
| | 1000 | + | + | + | + | + |
| | 2000 | + | + | + | + | + |
| | 3000 | + | + | + | + | + |

Tablo 6. 2 Aseton ve Trikloretilen gazları için ölçüm ortam şartları.

| Dosyalar | karışım sıcaklığı (C) | ortam sıcaklığı (C) | ortam nemi (RH) |
|--------------|-----------------------|---------------------|-----------------|
| tceaset1.txt | -11 | 25 | 34% |
| tceaset2.txt | -11 | 25 | 31% |
| tceaset3.txt | -11 | 22 | 32% |
| tceaset4.txt | -11 | 21 | 31% |
| tceaset5.txt | -11 | 19 | 33% |

Tablo 6. 3 Aseton ve Trikloretilen gazları için ölçüm özellikleri

| | |
|---|--|
| 1 | Her ölçüm 11 menü den oluşmaktadır. (6 yıkama ve 5 gaz menüsü) |
| 2 | Her menüde ölçüm hücresinden 200 sccm gaz geçmektedir. |
| 3 | Ölçüm hücresinde yıkama menülerinde Kuru hava kullanılmaktadır. |
| 4 | Kuru hava aynı zamanda taşıyıcı gaz olarak kullanılmaktadır. |
| 5 | Her ölçüm öncesi sistem 15-30 dk kuru hava ile ön yıkamaya tabi tutuldu. |

Tablo 6. 4 Etanol ve Trikloretilen gazlarına ait karışım oranları ve dosya isimnleri

| | | TRIKLORETILEN | | | | |
|--------|---------------------|---------------|--------------|--------------|--------------|--------------|
| | dosya adı | tceetan0.txt | tceetan2.txt | tceetan3.txt | tceetan4.txt | tceetan5.txt |
| ETANOL | konsantrasyon (ppm) | 550 | 1650 | 2200 | 2750 | 3300 |
| | 250 | + | + | + | + | + |
| | 500 | + | + | + | + | + |
| | 1000 | + | + | + | + | + |
| | 2000 | + | + | + | + | + |
| | 3000 | + | + | + | + | + |

Tablo 6. 5 Etanol ve Trikloretilen gazları için ölçüm ortam şartları.

| Dosyalar | karışım sıcaklığı (C) | ortam sıcaklığı (C) | ortam nemi (RH) |
|--------------|-----------------------|---------------------|-----------------|
| tceetan0.txt | -15 | 21 | 31% |
| tceetan2.txt | -13 | 22 | 32% |
| tceetan3.txt | -13 | 25 | 33% |
| tceetan4.txt | -13 | 25 | 33% |
| tceetan5.txt | -13 | 23 | 32% |

Tablo 6. 6 Etanol ve Trikloretilen gazları için ölçüm özellikleri

| | |
|---|--|
| 1 | Her ölçüm 11 menü den oluşmaktadır. (6 yıkama ve 5 gaz menüsü) |
| 2 | Her menüde ölçüm hücresinden 200 sccm gaz geçmektedir. |
| 3 | Ölçüm hücresinde yıkama menülerinde Kuru hava kullanılmaktadır. |
| 4 | Kuru hava aynı zamanda taşıyıcı gaz olarak kullanılmaktadır. |
| 5 | Her ölçüm öncesi sistem 15-30 dk kuru hava ile ön yıkamaya tabi tutuldu. |

Tablo 6. 7 Aseton ve Etanol gazlarına ait karışım oranları ve dosya isimnleri

| | | ETANOL | | | | |
|--------|---------------------|--------------|--------------|--------------|--------------|--------------|
| | dosya adı | etanase1.txt | etanase2.txt | etanase3.txt | etanase4.txt | etanase5.txt |
| ASETON | konsantrasyon (ppm) | 1000 | 1500 | 2000 | 2500 | 3000 |
| | 250 | + | + | + | + | + |
| | 500 | + | + | + | + | + |
| | 1000 | + | + | + | + | + |
| | 2000 | + | + | + | + | + |
| | 3000 | + | + | + | + | + |

Tablo 6. 8 Aseton ve Etanol gazları için ölçüm ortam şartları.

| Dosyalar | karışım sıcaklığı (C) | ortam sıcaklığı (C) | ortam nemi (RH) |
|--------------|-----------------------|---------------------|-----------------|
| etanase1.txt | -11 | 24 | 24% |
| etanase2.txt | -11 | 22 | 24% |
| etanase3.txt | -11 | 16 | 29% |
| etanase4.txt | -11 | 19 | 25% |
| etanase5.txt | -11 | 18 | 25% |

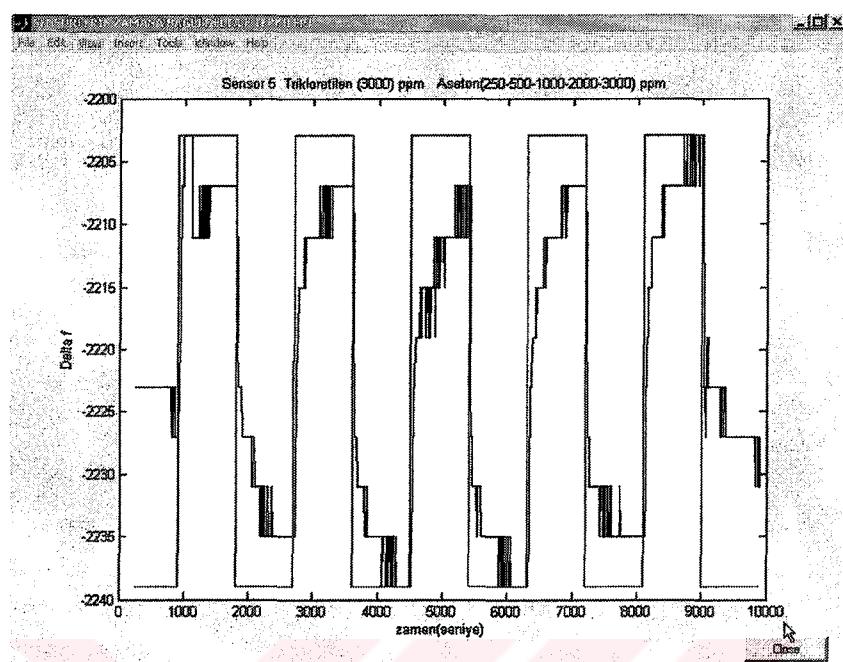
Tablo 6. 9 Aseton ve Etanol gazları için ölçüm özelliklerı

| | |
|---|--|
| 1 | Her ölçüm 11 menü den oluşmaktadır. (6 yıkama ve 5 gaz menüsü) |
| 2 | Her menüde ölçüm hücresinden 200 sccm gaz geçmektedir. |
| 3 | Ölçüm hücresinde yıkama menülerinde Kuru hava kullanılmaktadır. |
| 4 | Kuru hava aynı zamanda taşıyıcı gaz olarakta kullanılmaktadır. |
| 5 | Her ölçüm öncesi sistem 15-30 dk kuru hava ile ön yıkamaya tabi tutuldu. |

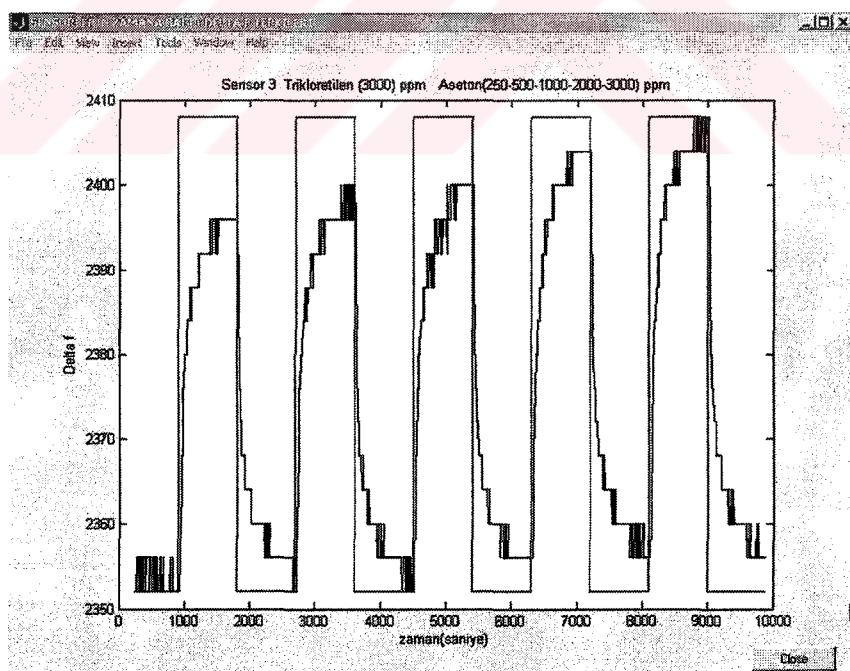
Her dosya her sensöre ait 1555 satırlık veri içermektedir. Toplam 8 sensörden ölçüm alındığından her dosya; (8×1555) 'lik bir matristen oluşmaktadır. Fakat bu matrislerdeki tüm bilgi, gaz oranlarını bulmak için kullanılacak yararlı bilgiyi içermemektedir. Bir şekilde bu dataların içinden yaralı olabilecek datalar, seçilerek gereksizdatalardan ayıralmamalıdır. Bu amaçla Sensör Analiz programı kullanılarak her dosya için, farklı olmak üzere her sensöre ait grafikler çizildi. Şekil 6.3. ve şekil 6.4. Trikloretilen (300) ppm ve Aseton (250, 500, 1000, 2000, 3000) ppm karışım oranları için sensör 5 ve sensör 3'e ait çizilmiş grafikleri göstermektedir.

Şekil 6.3. ve şekil 6.4.'den de görüldüğü gibi sensör normal davranışının dışında bazı yerlerde pik yapmıştır. Bu pikler sensörün istenilen ölçüm aralığında ulaştığı maksimum değerinin bulmamasını güçlendirmektedir. Bu yüzden datanın filtrelenerek gereksiz piklerden temizlenmelidir. Bu amaçla Sliding Window algoritması kullanılarak data filtrelenmiştir.

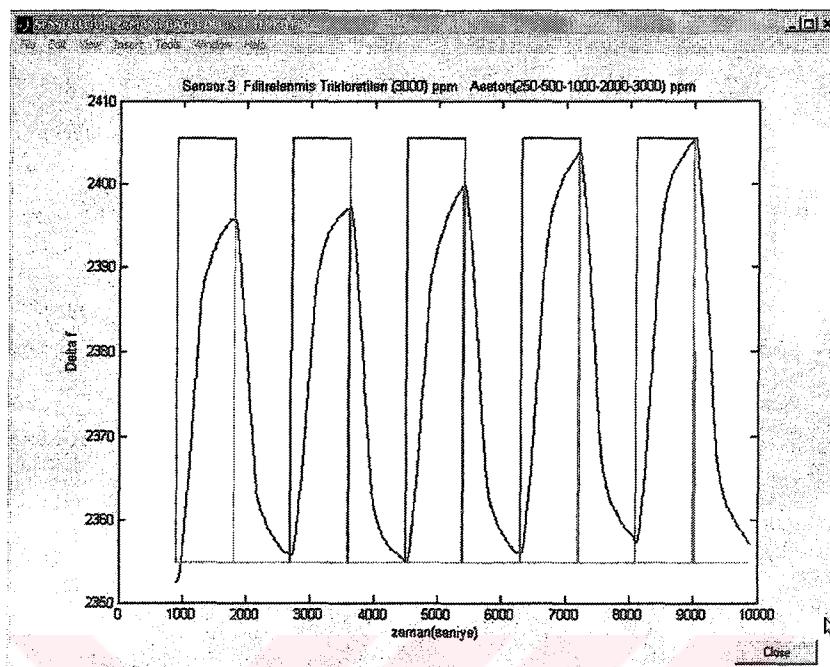
Bir sonraki adımda her karışım için Δf 'in maksimum değeri hesaplanmıştır ve bu maksimum değerlerin karışımındaki gaz oranlarını temsil ettiği kabul edildi. Çünkü yapılan birçok ölçümde sensörler grafiklerinin farklı gaz karışımılar için farklı maksimum değerlere ulaştığını ve sonra doyuma (saturation) ulaşmaktadır. Sensörlerin karışımlara verdiği tepkilerden her bir karışım için bir maksimum değer elde edilmiştir Her deneyde her sensörden datalar filtrelendikten sonra (şekil 6.5. ve şekil 6.6.) toplam beş maksimum değer elde edilmiştir.



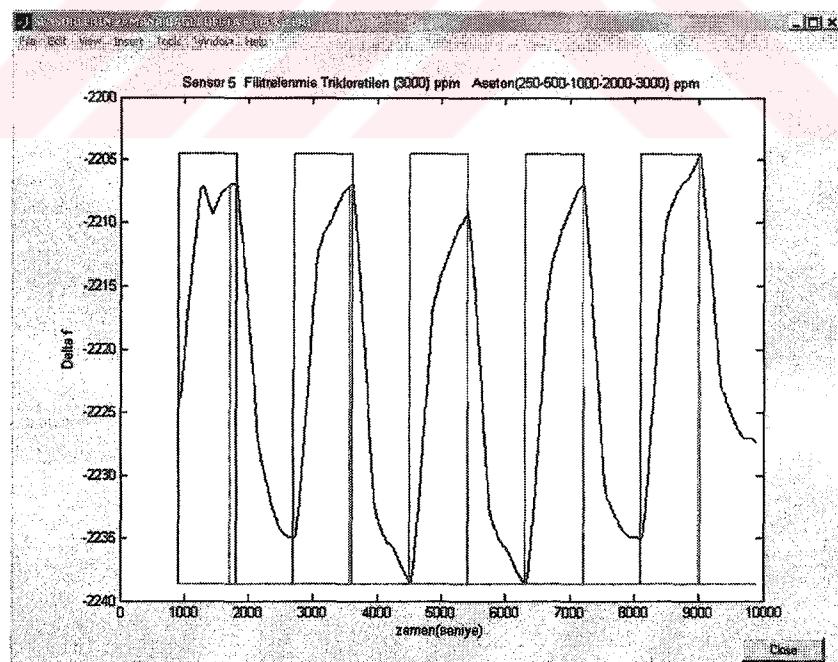
Şekil 6. 3 Filtrelenmemiş sensör 5'in aseton ve trikloretilen gaz karışımılarına verdiği tepki.



Şekil 6. 4 Filtrelenmemiş sensör 3'ün aseton ve trikloretilen gaz karışımılarına verdiği tepki.



Şekil 6. 5 Filtrelenmiş sensör 5'in aseton ve trikloretilen gaz karışımılarına verdiği tepki.

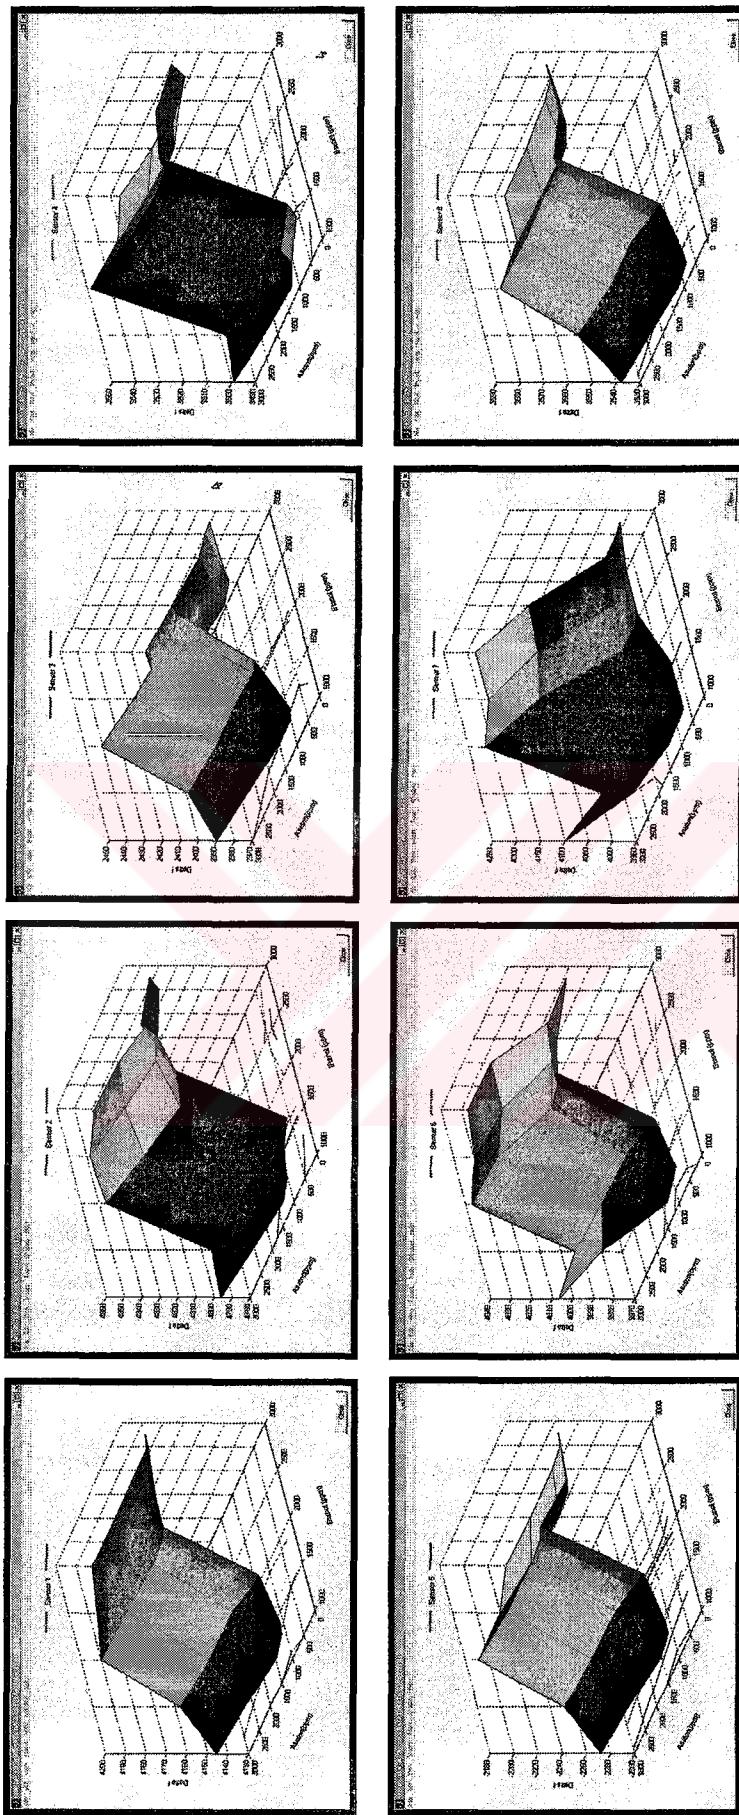


Şekil 6. 6 Filtrelenmiş sensör 3'ün aseton ve trikloretilen gaz karışımılarına verdiği tepki.

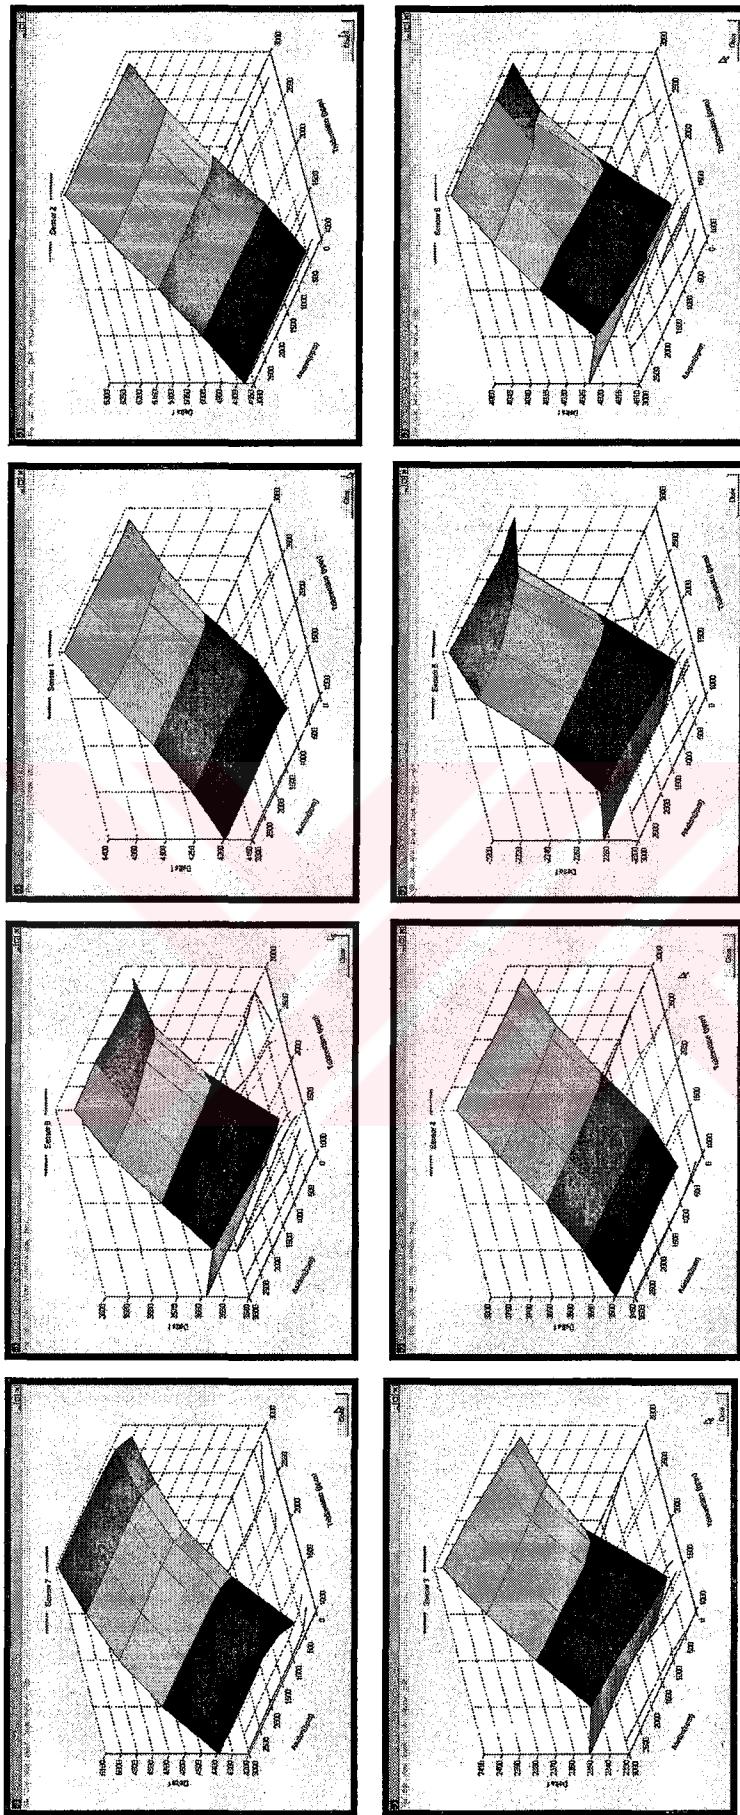
Filtrelenmiş sensör grafikleri şekil 6.5 ve şekil 6.6'da görülmektedir. Her bir sensörden her bir karışım için vermiş olduğu maksimum tepkiler (Δf_s) toplanıldı ve bu datalar kullanılarak her bir sensör için üç boyulu grafikler oluşturuldu. Şekil 6.9 etanol ve aseton , şekil 6.7. etanol ve trikloretilen şekil 6.8. aseton ve trikloretilen için çizilmiş bu grafikler görülmektedir.

Bu grafiklerin x ekseni gazlardan birinin yoğunluğunu (ppm), y ekseni diğer gazın yoğunluğunu(ppm) ve z ekseni sensör tepkisini (Δf) gösteriyor. Bu grafikler sensör tepkileri hakkında bize çok önemli bilgiler vermektedirler. Bu bilgiler göre sensörler tepkilerinin doğrusal olmadıkları gözlenmektedir. Böylece doğrusal sistemler kullanılarak bu verilerin yorumlanması sakınca olabilir.

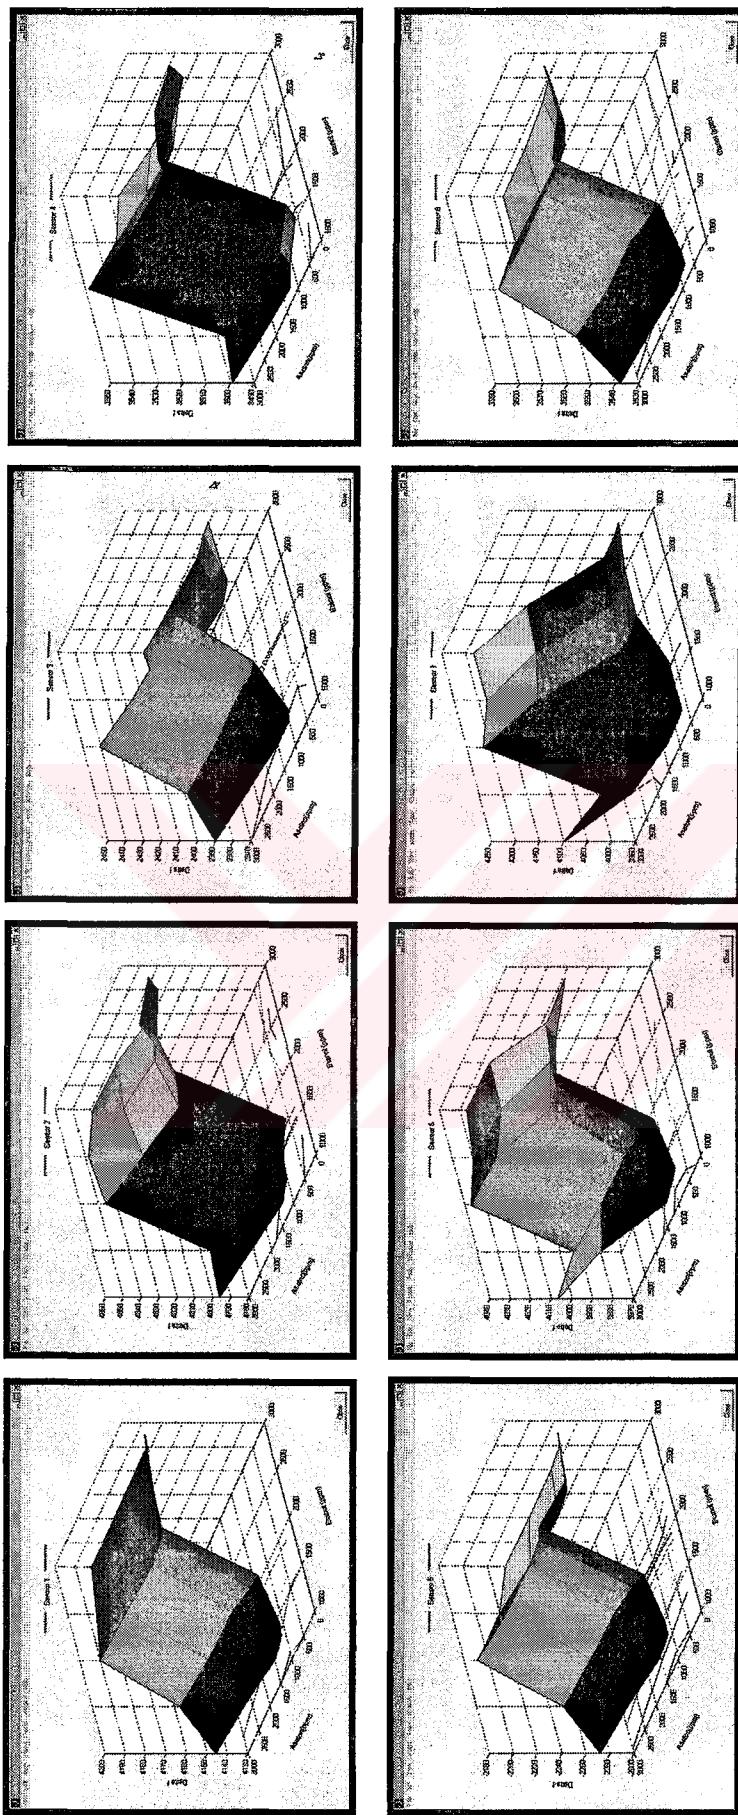




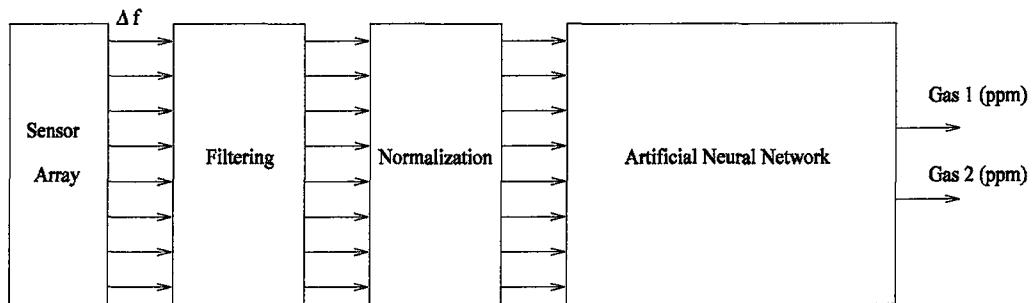
Şekil 6.9 8 sensörün etanol ve aseton gaz karışımımlarına tepkilerin 3D grafikleri.



Sekil 6.8 8 sensörün aseton ve trifluoretilen gaz karışıntılarına verdiği tepkilerin 3D grafiğleri.



Sekil 6.9 8 sensörün etanol ve aseton gaz karışımılarına tepkilerini 3D grafikleri.



Şekil 6. 10. Data işleme sisteminin blok şeması

Bu bilgileri yorumlamak için Yapay Sinir Ağrı (YSA) kullanılmıştır. Kullanılacak datalar çok büyük olduğu için YSA'yı kararsızlığa götürmekteler. Bundan dolayı her farklı gaz karışımının ölçüm datalarından oluşan giriş datası, aynı matrisin maksimum değerli elemanına bölünerek giriş datası 0 ile 1 arasına çekilmiştir. Ayrıca çıkış datasını oluşturan matrislerin tüm elemanları da 1000 sayısına bölünerek 3.3 ile 0 arasına çekilmiştir. Bu datalar tablo 6.11 ,tablo 6.13.,tablo 6.15. ve tablo 6.17.'de görülmektedir.

YSA için Geri Yayılımlı Yapay Sinir Ağrı modeli (Feer-forward backprop) kullanılmıştır. Kullanılan YSA 3 katmandan oluşmaktadır. Giriş katmanı kullanılan sensör datasına göre değişmektedir, gizli katmanda 30 ve çıkış katmanında da 2 nöron bulunmaktadır. Gizli katman ile çıkış katmanı arasında Log-sigmoid transfer fonksiyonu ve çıkış katmanında da purelin transfer fonksiyonu kullanılmıştır.

Öncelikle şuna karar verilmeliydi. Bütün sensörler YSA'da kullanılmalı mı?. Yoksa sadece gaz değişimlerine linere yakın tepkiler veren sensörler mi kullanılmalı. Her iki durum için de her gaz karışımı için YSA'lar oluşturulup eğitimleri ve testleri yapılmıştır.

Her gaz karışımı için farklı olmak üzere bütün sensör dataları kullanılarak eğitilmiş YAS'lar, seçilmiş sensör dataları ile eğitilmiş YSA'lardan daha iyi sonuçlar verdiği gözlenmiştir.

Tablo 6.29 Aseton ve trikloretilen gaz karışıntıları için hatalar.

| | | | |
|----------|----------|----------|-----------|
| 0 . 0086 | 0 . 0125 | 0 . 036 | 0 . 00001 |
| -1 . 62 | -2 . 72 | -0 . 089 | 0 . 059 |

Tablo 6.30 Aseton ve trikloretilen gaz karışıntıları için 1., 2., 4. ve 7. sensördataları kullanılarak eğitilmiş YSA'nnn test sonuçları.

| | | | |
|----------|----------|----------|----------|
| 1470 . 5 | 1976 . 9 | 2513 . 2 | 3009 . 6 |
| 1551 . 6 | 532 . 92 | 2774 . 3 | 2250 . 9 |

Tablo 6.31 Aseton ve trikloretilen gaz karışıntıları için 1., 2., 4. ve 7. sensördataları kullanılarak eğitilmiş YSA hataları.

| | | | |
|----------|----------|-----------|----------|
| 0 . 019 | -0 . 011 | -0 . 0052 | 0 . 0032 |
| -5 . 206 | 0 . 065 | 1 . 77 | 0 . 125 |

Tablo 6. 25 Etanol ve aseton gaz karışımı için 1., 2., 5. ve 7. sensör dataları kullanılarak eğitilmiş YSA'nın test sonuçları.

| | | | |
|---------|--------|--------|--------|
| 1459.6 | 2102.7 | 2623.7 | 2589.9 |
| -939.94 | 469.45 | 767.39 | 1940.9 |

Tablo 6. 26 Etanol ve aseton gaz karışımı için 1., 2., 5. ve 7. sensör dataları kullanılarak eğitilmiş YSA hataları.

| | | | |
|-------|--------|--------|-------|
| 0.026 | -0.051 | -0.049 | 0.136 |
| -2.75 | 0.061 | 0.23 | 0.029 |

Tablo 6. 27 Aseton ve trikloretilen gaz karşımları için test çıkış dataları

| | | | |
|------|------|------|------|
| 1500 | 2000 | 2500 | 3000 |
| 250 | 500 | 1000 | 2000 |

Tablo 6. 28 Aseton ve trikloretilen gaz karşımları için test sonuçları.

| | | | |
|--------|--------|--------|--------|
| 1487 | 1974.7 | 2409 | 2997.2 |
| 655.22 | 1864.5 | 1089.2 | 1881.2 |

Tablo 6. 21 Etanol ve trikloretilen gaz karışımları için 1., 2., 4. ve 7. sensör dataları kullanılarak eğitilmiş YSA hataları.

| | | | |
|---------|----------|---------|----------|
| 0 . 37 | 0 . 073 | 0 . 049 | -0 . 002 |
| -4 . 47 | -1 . 307 | 0 . 162 | 0 , 25 |

Tablo 6. 22Etanol ve aseton gaz karışımı için test çıkış dataları

| | | | |
|------|------|------|------|
| 1500 | 2000 | 2500 | 3000 |
| 250 | 500 | 1000 | 2000 |

Tablo 6. 23 Etanol ve aseton gaz karışımları için test sonuçları.

| | | | |
|-----------|----------|----------|----------|
| 1631 . 2 | 2128 . 3 | 2286 . 4 | 2809 . 5 |
| -1160 . 2 | 587 . 51 | 908 . 56 | 782 . 75 |

Tablo 6. 24 Etanol ve aseton gaz karışımı için hatalar.

| | | | |
|----------|---------|---------|---------|
| -0 . 087 | 0 . 064 | 0 . 085 | 0 . 063 |
| -3 . 64 | 0 . 17 | 0 . 091 | 0 . 602 |

Tablo 6.17 Etanol ve trikloretilen gaz karışmları için 0 ile 1 arasına çekilmiş test giriş datası

| | | | |
|----------|----------|----------|----------|
| 0.42563 | 0.43159 | 0.43219 | 0.43567 |
| 0.50445 | 0.51545 | 0.51641 | 0.52529 |
| 0.23825 | 0.24118 | 0.24166 | 0.24213 |
| 0.3607 | 0.36942 | 0.36876 | 0.37607 |
| -0.22447 | -0.22028 | -0.22261 | -0.22002 |
| 0.40319 | 0.40401 | 0.40359 | 0.40427 |
| 0.4766 | 0.49447 | 0.49714 | 0.50634 |
| 0.35674 | 0.35821 | 0.35699 | 0.35794 |

Tablo 6.18 Etanol ve trikloretilen gaz karışmları için test sonuçları.

| | | | |
|--------|--------|--------|--------|
| 1734.6 | 2248.5 | 2802.8 | 3281 |
| 354.62 | 743.75 | 1030.8 | 1753.8 |

Tablo 6.19 Etanol ve trikloretilen gaz karışmları için hatalar.

| | | | |
|---------|--------|---------|--------|
| -0.0512 | -0.022 | -0.0192 | 0.0057 |
| -0.418 | -0.487 | -0.0308 | 0.123 |

Tablo 6.20 Etanol ve trikloretilen gaz karışmları için 1., 2., 4. ve 7. sensör dataları kullanılarak eğitilmiş YSA'nın test sonuçları.

| | | | |
|--------|--------|--------|--------|
| 1026.4 | 2037.3 | 2614.2 | 3308.9 |
| 1368.3 | 1153.5 | 837.11 | 1487.1 |

Tablo 6.15 Etanol ve trikloroetilen gaz karışımları için 0 ile 1 arasına çekilmiş eğitim giriş dataseti

| | | | | | | | | | | | | | | |
|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|------------------|
| 0.430 96 | 0.431 59 | 0.432 19 | 0.431 99 | 0.425 14 | 0.426 74 | 0.426 16 | 0.430 6 | 0.432 96 | 0.431 19 | 0.432 99 | 0.431 14 | 0.434 2 | 0.435 1 | 0.436 18 |
| 0.514 5 | 0.515 45 | 0.516 41 | 0.517 61 | 0.514 73 | 0.504 72 | 0.505 35 | 0.506 6 | 0.514 5 | 0.516 41 | 0.517 61 | 0.514 73 | 0.515 5 | 0.517 45 | 0.523 61 |
| 0.240 52 | 0.241 18 | 0.242 66 | 0.242 8 | 0.238 37 | 0.238 8 | 0.239 57 | 0.240 34 | 0.241 52 | 0.240 66 | 0.242 8 | 0.240 52 | 0.241 18 | 0.242 8 | 0.240 55 |
| 0.353 89 | 0.354 08 | 0.355 34 | 0.355 14 | 0.361 96 | 0.361 14 | 0.362 96 | 0.363 69 | 0.368 81 | 0.363 48 | 0.370 5 | 0.372 2 | 0.367 34 | 0.369 87 | 0.370 13 |
| - 0.215 63 | - 0.215 57 | - 0.214 32 | - 0.214 02 | - 0.224 23 | - 0.224 52 | - 0.223 32 | - 0.222 69 | - 0.222 15 | - 0.220 75 | - 0.219 84 | - 0.217 57 | - 0.217 85 | - 0.223 48 | - 0.222 13 |
| 0.402 06 | 0.402 14 | 0.402 31 | 0.402 43 | 0.403 34 | 0.403 5 | 0.403 6 | 0.403 94 | 0.403 6 | 0.403 94 | 0.404 4 | 0.404 13 | 0.404 38 | 0.403 13 | - 0.222 34 |
| 0.435 26 | 0.438 78 | 0.441 08 | 0.443 29 | 0.445 22 | 0.481 26 | 0.483 18 | 0.484 35 | 0.483 11 | 0.487 66 | 0.497 4 | 0.498 76 | 0.496 8 | 0.495 11 | 0.497 91 |
| 0.356 2 | 0.356 26 | 0.356 34 | 0.356 46 | 0.356 56 | 0.356 87 | 0.356 99 | 0.357 04 | 0.357 12 | 0.358 36 | 0.357 12 | 0.356 36 | 0.357 94 | 0.356 79 | 0.357 84 |
| | | | | | | | | | | | | | | |

Tablo 6.16 Etanol ve trikloroetilen gaz karışımları için test giriş dataseti

| | | | |
|---------|---------|---------|---------|
| 2240.5 | 2271.9 | 2275.1 | 2293.4 |
| 2655.4 | 2713.3 | 2718.4 | 2765.1 |
| 1254.1 | 1269.6 | 1272.1 | 1274.6 |
| 1898.7 | 1944.6 | 1941.2 | 1979.6 |
| -1181.6 | -1159.5 | -1171.8 | -1158.2 |
| 2122.4 | 2126.7 | 2124.5 | 2128.1 |
| 2508.8 | 2602.9 | 2616.9 | 2665.4 |
| 1877.9 | 1885.6 | 1879.2 | 1884.2 |

Tablo 6.14 Etanol ve trikloretilen gaz karışımı için eğitim giriş datasetı

| | | | | | | | | | | | | | | | | | | |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 2268. | 2271. | 2275. | 2279. | 2269. | 2241. | 2243. | 2245. | 2268. | 2275. | 2279. | 2269. | 2271. | 2268. | 2279. | 2285. | 2287. | 2290. | 2296. |
| 6 | 9 | 1 | 3 | 5 | 1 | 3 | 5 | 6 | 1 | 3 | 5 | 6 | 9 | 3 | 5 | 6 | 5 | 3 |
| 2708. | 2713. | 2718. | 2724. | 2709. | 2656. | 2660. | 2662. | 2666. | 2708. | 2718. | 2724. | 2709. | 2708. | 2713. | 2724. | 2709. | 2755. | 2759. |
| 3 | 3 | 4 | 7 | 5 | 8 | 2 | 5 | 7 | 3 | 4 | 7 | 5 | 3 | 7 | 5 | 7 | 1 | 7 |
| 1266. | 1269. | 1272. | 1278. | 1274. | 1254. | 1257 | 1261. | 1265. | 1266. | 1272. | 1278. | 1274. | 1266. | 1269. | 1278. | 1274. | 1265. | 1266. |
| 1 | 6 | 1 | 1 | 3 | 8 | 1 | 2 | 1 | 1 | 1 | 1 | 3 | 1 | 6 | 1 | 3 | 1 | 3 |
| 1862. | 1863. | 1865. | 1869. | 1873. | 1901. | 1905. | 1909. | 1915. | 1939. | 1950. | 1959. | 1949. | 1936. | 1937. | 1946. | 1950. | 1964. | 1967. |
| 9 | 9 | 3 | 4 | 8 | 1 | 4 | 2 | 1 | 7 | 3 | 3 | 4 | 5 | 8 | 5 | 9 | 7 | 4 |
| - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | -1164 | - | -1167 | - |
| 1135. | 1131. | 1129. | 1128. | 1126. | 1180. | 1176. | 1170. | 1161. | 1164. | 1156. | 1146. | 1145. | 1178. | 1176. | 1145. | 1154. | 1173. | 1147. |
| 1 | 8 | 5 | 2 | 6 | 3 | 6 | 3 | 7 | 1 | 8 | 7 | 3 | 4 | 4 | 4 | 6 | 3 | 8 |
| 2116. | 2116. | 2116. | 2117. | 2118. | 2123. | 2124. | 2124. | 2126. | 2126. | 2128. | 2127. | 2123. | 2123. | 2124. | 2124. | 2124. | 2125. | 2126. |
| 1 | 4 | 9 | 8 | 4 | 2 | 6 | 6 | 3 | 7 | 8 | 3 | 4 | 7 | 6 | 7 | 6 | 2 | 4 |
| 2291. | 2309. | 2321. | 2333. | 2343. | 2533. | 2543. | 2545. | 2548. | 2565. | 2616. | 2625. | 2611. | 2586. | 2609. | 2620. | 2622. | 2631. | 2653. |
| 2 | 8 | 8 | 5 | 7 | 2 | 9 | 7 | 4 | 8 | 1 | 7 | 7 | 1 | 7 | 4 | 1 | 5 | 6 |
| 1875 | 1875. | 1875. | 1876. | 1878. | 1879. | 1879. | 1879. | 1879. | 1885. | 1886. | 1887. | 1884. | 1878. | 1878. | 1878. | 1879. | 1880. | 1881. |
| 3 | 8 | 4 | 9 | 6 | 2 | 5 | 2 | 4 | 7 | 2 | 4 | 7 | 1 | 2 | 4 | 5 | 4 | 4 |

Tablo 6. 10 Etanol ve trikloretilen gaz karışımları için çıkış eğitim datasetı

| | | | | | | | | | | | | | | |
|-----|-----|------|------|------|------|------|------|------|------|------|------|------|------|------|
| 550 | 550 | 550 | 550 | 550 | 1650 | 1650 | 1650 | 1650 | 2200 | 2200 | 2750 | 2750 | 3300 | 3300 |
| 250 | 500 | 1000 | 2000 | 3000 | 500 | 1000 | 2000 | 3000 | 250 | 1000 | 2000 | 3000 | 250 | 500 |

Tablo 6. 11 Etanol ve trikloretilen gaz karışımları için 0 ile 3.3 arasına çekilmiş çıkış eğitim datasetı

| | | | | | | | | | | | | | | |
|------|------|------|------|------|------|------|------|------|------|-----|------|------|------|-----|
| 0.55 | 0.55 | 0.55 | 0.55 | 0.55 | 1.65 | 1.65 | 1.65 | 1.65 | 2.2 | 2.2 | 2.75 | 2.75 | 3.3 | 3.3 |
| 0.25 | 0.5 | 1 | 2 | 3 | 0.5 | 1 | 2 | 3 | 0.25 | 1 | 2 | 3 | 0.25 | 0.5 |

Tablo 6. 12 Etanol ve trikloretilen gaz karışımları için çıkış test datasetı

| | | | |
|------|------|------|------|
| 1650 | 2200 | 2750 | 3300 |
| 250 | 500 | 1000 | 2000 |

Tablo 6. 13 Etanol ve trikloretilen gaz karışımları için 0 ile 3.3 arasına çekilmiş çıkış test datasetı

| | | | |
|------|-----|------|-----|
| 1.65 | 2.2 | 2.75 | 3.3 |
| 0.25 | 0.5 | 1 | 2 |

7. SONUÇ

Endüstride, gazın bileşimindeki gazların belirlenmesi ve oranlarının belirlenmesi sıkça önemli bir problemdir. Çevresel ve endüstriyel işlemlerde çeşitli gazların belirli oranlarda karıştırılması ile elde edilen ürünlerin, üretim sürecinde yapılacak deneylerde bu tür ölçümler sıkılıkla yapılmaktadır. Bu işlemler pahalı ve zaman alan işlemlerdir. Ancak günümüz teknolojisi, bu zahmetli ve tehlikeli işlemleri kimyasal işlemler yapmadan yapmayı olanaklı kılmıştır. Bu ölçümler için günümüz teknolojisinde elektronik burunlar kullanılmaya başlanılmıştır. Elektronik burun, üzerindeki sensör dizileri yardımı ile gazların datalarını, tanı programları kullanılarak bu sinyallerden gazların türleri ve oranlarını tespit etmeye çalışmaktadır.

Bu çalışmada; TUBİTAK Marmara Araştırma Merkezi, Malzeme Teknolojileri Enstitüsü’nde Sensör Gurubu’nda geliştirilmiş QCM ölçüm sistemi kullanılarak üç farklı gazın ikişerli karışımlarından oluşan gaz karışımındaki gazları ve oranlarını bulan bir program tasarlanmıştır. Gaz karışımı olarak; (Etanol – Aseton), (Etanol – Trikloretilen) ve (Aseton – Trikloretilen) kullanılarak dataları alınmıştır. Bu karışımlar, sanayide sıkça kullanılan yaygın gazlardır. Sistemde her karışım için ortamın nemi, sıcaklığı, basıncı ve gazının akış hızı sabit tutularak dатalar alınmıştır. Belirlenen her gaz karışımından önce sensörler kuru hava kullanılarak base-line oluşturulmuş ve daha sonra karışımındaki gazların oranlar değiştirilerek dатalar oluşturulmuştur. Her data da 15 dakikalık temizleme ve 15 dakikalık gaz ölçümünden oluşmaktadır. Deneylerde; 8 adet sensörden alınan Δf dатaları PC kullanılarak kaydedilmiştir. Bu ölçüm algoritması şeķli 6.10'da görülmektedir.

Bu program tasarılanırken, amacımız elde taşınabilir bir gaz belirleme sistemi geliştirilmesinde kullanılabilecek bir tanı programı geliştirmekti. Bunun için, öncelikle YSA'yı PC'de gerçeklemek yerine donanımda gerçeklemeye çalıştık. Bu çalışma için Xilinx Spartan-II Field Programmable Gate Array (FPGA) çip setli Xess Board kullanarak daha büyük tasarımlara olanak sağlayacak bir YSA gerçekledik. Bu YSA; 4 girişli tek çıkışlı ve ağırlık değerleri dışardan yüklenen bir yapıya sahipti. Gerçeklenen bu sistemin hızı ve performansı tatmin edici olmasına rağmen, sensörlerin bazı karakteristik özelliklerinden dolayı kullanılmamıştır. Çünkü; sensör tepkileri bu sistem için oldukça yavaş. Bir ölçümü tamamlaması yaklaşık olarak 25 dakika alıyor. Ayrıca gerçek ortamda sensörler ortamındaki ısı, nem, ve basınçtan etkileniyorlar. Gerçek dатalar için bu parametrelerin sabit tutulması gerekmektedir.

Yaptığımız deneylerde, 8 sensöden de gelen datalar kullanılarak eğitilen YSA'ların, sadece gazlara linere yakın tepki veren sensörlerle ait datalar seçilerek eğitilen YSA'lardan daha iyi performans gösterdikleri gözlendi. Bu deneylerde kullanılan datalar ve sonuçlarına tablo6.18 ve tablo 6.31 arasında tablolardan bakılabilir.

Sensörlerden gelen sinyalleri kullanarak gazları tanımak için 8 giriş 30 çıkış ve 2 çıkış olmak üzere üç katmanlı geri yayılımlı yapay sinir ağı kullanıldı. Matlab'ın nntool aracını kullanılarak gerçekleşen bu YSA girişine uygulanan datalardan, gazların karışımındaki oranlarının bulunması amaçlanmaktadır.

Deneyselde elde edilen datalardan, sensör karakteristiklerinin analiz edilmesi için Matlab'da hazırlanan "Sensör Analiz Programı" kullanıldı. Bu program yardımı ile her sensörün farklı gazlara ve farklı karışım oranlarına vermiş olduğu tepkilere ait grafikleri çizildi. Bu grafiklerde, sensör tepkilerinin liner olmadığı anlaşıldı. Liner olmayan sistemleri tanımlamak için Yapay Sinir Ağları en çok kullanılan yöntemlerden biridir.

Elde edilen grafiklerden her deneyde grafiğin maksimum ulaşabildiği noktanın gaz oranları için tanımlayıcı bir bilgi olduğu görüldü. Her gaz karışımı için her sensöre ait 25 maksimum değerinden oluşan matrisler elde edildi. Bu matrisler yardımı ile X düzlemi 1. gaz Y düzlemi 2. gaz ve Z düzlemi Δf olacak şekilde sensörlerin 3 boyutlu tepki grafikleri çizildi. Bu grafiklerden sensör tepkilerinin bir yüzeye benzediğini gördük. Bu yüzeyi kullanarak YSA'yı eğittiğimizde bu yüzeyin dışındaki bir alanda bulunan bir noktanın YSA'nın bulması gerekiyordu. Bu varsayımda çalışmamızdaki hareket noktamızdı. YSA'nın eğitiminde kullanılmayan bazı datalar YSA'nın eğitiminden sonra YSA'ya uygulandığında YSA gerçek sonuçlara yakın değerler veriyorsa bu YSA'nın eğitiminde kullanılan yüzeyin dışındaki bir nokta için de doğru sonuçları bulacağı anlamına geliyor.

YSA eğitildikten sonra gaz karışımı için testler yaptı. YSA'ının sonuçları tahmin etme başarısı karışımından karışımıma faktalık gösterdi. Programın karışımındaki gaz oranlarını bulma başarısı gazların ppm değeri büyündükçe artıyor. Tablo6.18, tablo6.20, tablo6.23, tablo6.25, tablo6.28 ve tablo6.30'da görülmektedir. Ağın performansı Mean squared error (mse) kullanılarak bulunduğu, bulunan performansı kullanılabılır değil. En iyi performansı Etanol ve trikloretilen gaz karışımının, 8 sensör datası kullanılarak eğitilen YSA veriyor. Bu ağın performansı 160. YSA'nın kullanılabilmesi için sıfırın altında bir hata performansına sahip olması gerekiyor. YSA'daki bu performans düşüklüğü eğitimde kullanılan datanın az olmasında kaynaklanıyor. Data sayısını artırılması ile YSA tekrar eğitildiğinde günlük hayatı kullanılan sistemlerde kullanıla bilir bir sistem elde etmek mümkün olacaktır.

KAYNAKLAR DİZİNİ

- [1] <http://www.bme.boun.edu.tr>
- [2] <http://www.tubitak.gov.tr/>
- [3] Matlab Help
- [4] Gardner, J.W., Detection of vaporous and odors from a multi-sensor array using pattern recognition. Part 1. Principal component and cluster analysis. Sensors and Actuators B. Vol. 4 (1991) 109-115
- [5] Dutta, R., Hines, E.L., Gardner, J.W., Kashwan, K.R., Bhuyan, M., Tea Quality Prediction Using a Tin Oxide-based Electronic Nose, An Artificial Intelligence Approach. Sensors and Actuators B. Vol. 94 (2003) 228-237
- [6] Haykin, S.: Neural networks, a comprehensive foundation. Prentice Hall. (1999)
- [7] J.D. Winefordner Chemical Analysis volume 125
- [8] W.Jeffrey Hurst, Ph.D., Faic Electronic Nose and Sensor Array Based System Desing and Applications
- [9] www.yapay-zeka.org,2004

Ek1: HARDWARE IMPLEMENTATION OF A NEURON-MODEL

Ahmet Özmen

e-mail: ozmen@dumlupinar.edu.tr

Ferzende Tekçe

e-mail: ferzendetekce@dumlupinar.edu.tr

Kadir Vardar

e-mail: kvardar@dumlupinar.edu.tr

Dumlupınar University, Faculty of Engineering,

Department of Electrical & Electronics Engineering, Kütahya, Türkiye

Key words: Artificial Intelligence, Neural Network, Fuzzy Logic, Field Programmable Gate Array

ABSTRACT

This paper describes the hardware implementation of a neuron-model using Xess Boards with Xilinx Spartan-II Field Programmable Gate Array (FPGA). The neuron-model, implemented in hardware using Xilinx foundation tools, has four inputs and one output each operating at 8 bit resolution. The internal computation is performed at higher resolution to eliminate errors due to overflow. The neuron-weights are trained offline, and then stored to the registers implemented in the FPGA at a precision of 8 bit for multiplication. The various elements of the model and the complexity of the synthesized hardware are presented with our conclusions on the viability for its wider use on neural networks.

I. INTRODUCTION

Neural computing can be implemented in software and hardware. Since software implementations are easier and cheaper comparing to that of hardware, neural algorithms are usually implemented in software for low-rate applications. The performance of conventional processors, e.g. the Intel Pentium series, continues to improve dramatically but they are still far away from the required performance. Even the fastest sequential processor can not provide real-time response for networks with large number of neurons and synapses. Therefore speed becomes the primary reason of hardware neural network implementations. Another reason for hardware implementation is handy instruments; e.g., a smell detector built for detecting explosive gases. Such devices are real-time neural applications and better to be implemented small in size. These constraints guide us to design and build custom hardware for neural applications.

The advantages of FPGA over a microprocessor chip for neural computing can be listed as [6]:

- Developing hardware systems using design tools for FPGAs is as easy as developing a software system.
- FPGAs can be re-programmed on the fly.
- The new FPGAs on the market support hardware that requires more than 1 million gates (a small scale processor can be implemented using such an FPGA)
- A custom circuit built on an FPGA operates faster than a microprocessor chip.

These advantages make FPGAs now viable alternatives to other technology implementations for high-speed neural applications. The structure of a FPGA can be described as an array of blocks connected together via programmable interconnections. The amount of logic that each logic block can implement depends on which family of FPGAs is being used. The most important

advantage of FPGAs is the flexibility that they provide. An engineer can change and refine his design by exploiting the device's re-programmability.

This paper introduces a hardware implementation of a generic neuron-model using Xess Boards with XCS250 FPGA which is a member of Spartan II family. The neuron-model, implemented in hardware using Xilinx foundation tools, has four inputs and one output each operating at 8 bit resolution. Due to simplicity learning is performed off-line. The computed weights are loaded into the system beforehand and then the output is computed for samples obtained from inputs. Minimum sampling interval the neuron model is 36 clock cycles.

The various elements of the model, use of simulation and synthesis tools and the complexity of the synthesized hardware are presented with our conclusions on the viability for the model's wider use on neural networks.

II. THE ARCHITECTURE OF THE NEURON-MODEL

The study of artificial neuron and neural networks has been inspired in part by observation of human brain which is build of very complex webs of interconnected neurons. The artificial neuron-model designed to mimic some of the characteristics of the biological neuron was first proposed by McCulloch and Pitts [1]. Figure 1 presents this model implemented in this paper. The model has four inputs and one output. A weight analogous to synaptic strength of a biological neuron is assigned to each input. All inputs are multiplied by their weights and then are summed to determine the activation level of the neuron.

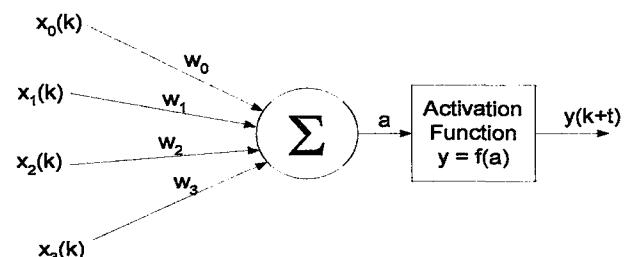


Figure 1. The architecture of the artificial neuron-model.

The output y can be produced as

$$y(k+t) = f(a), \text{ where} \quad (1)$$

$$a = \sum_{i=0}^3 x_i(k)w_i \quad (2)$$

t is the computational delay to obtain output for the k th samples.

2.1 Data Representation

In the architecture, the inputs and weights are designed to be real numbers in the region of 0 to 1. These numbers are represented digitally in 8 bit to simplify the circuit. Digital 8 bit representation of these numbers results in fast parallel operations.

The encoding technique used in this paper is described in [2] for the range of -8 to 8. The technique basically uses digital values as a means to represent the respective data. Table 1 shows the principal values employed with this technique. As can be seen from Table 1 floating point numbers are easily accommodated in this system.

Table 1. Data Representation

| Value | Data representation |
|------------|---------------------|
| 0.5 | 1000 0000 |
| 0.25 | 0100 0000 |
| 0.125 | 0010 0000 |
| 0.0625 | 0001 0000 |
| 0.03125 | 0000 1000 |
| 0.015625 | 0000 0100 |
| 0.0078125 | 0000 0010 |
| 0.00390625 | 0000 0001 |
| 0 | 0000 0000 |

Table 2 shows how various numbers are represented simply by adding some of the principal values from Table 1 together. There are slight inaccuracies between the true value and its digital representation. However, it is reported that reduced accuracy does not have significant impact during the operative phase of neural systems [2].

Table 2. Representing values

| Value | Data representation | Encoded value |
|------------|---------------------|---------------|
| 0.28534547 | 0100 1001 | 0.28515625 |
| 0.54120351 | 1000 1010 | 0.53906250 |
| 0.81504492 | 1101 0000 | 0.81250000 |

2.2 Multiplier

The multiplier is an essential component and the most currently used arithmetic operation in neural applications. For the neuron-model presented here, 8 bit digital inputs are multiplied with their weights and the results are summed in a register (see Figure 4). Many serial, parallel and serial-parallel hybrid multiplier models have been developed for FPGAs under considerations of performance or place limits [3, 4]. For simplicity, a serial multiplier similar to one described in Mano [5] is implemented in behavioral level in this work. Since the operands are 8 bit unsigned binary numbers, the output the multiplier becomes 16 bit binary number.

2.3 Activation Function (sigmoid):

The activation function, which is usually a sigmoid, converts 16 bit multiplier output to 8 bit neuron output. Because limited width of data busses, the output range of a neuron must be the same as the input range for digital systems; otherwise an overflow occurs. Equation 3 shows the traditional non-linear activation function.

$$y = \frac{1}{(1 + e^{-a})} \quad (3)$$

As it can be seen from the formula, the traditional activation function is not suitable for direct digital implementation because it consists of an infinite exponential series. Some implementations utilize digital circuitry techniques to approximate the sigmoid functions [2, 8]. The others uses memory for the same purpose. Both techniques are based on piece wise linear polynomial approximation.

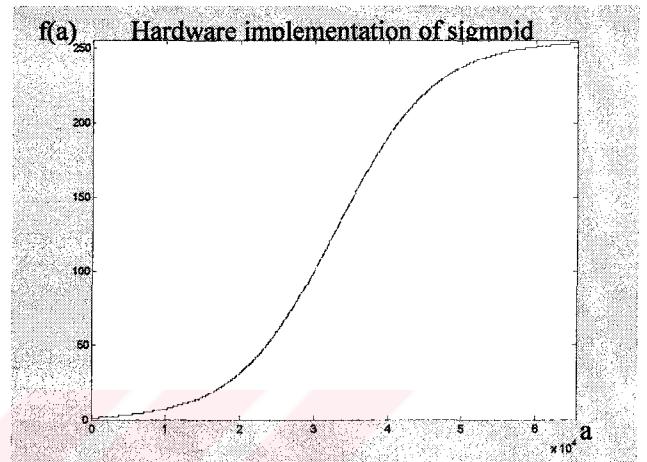


Figure 2. Sigmoid function implemented in hardware

Since the multiplier output is 16 bit wide in our design and Xess board provides of a 256 Kbytes Flash RAM, we have utilized this memory to realize the approximated activation function. Figure 2 shows piece wise linear approximation to the sigmoid. X-axis shows the addresses and the Y- axis show memory contents (or output of the neuron).

First column of Table 3 shows address and the second column shows the memory contents of the flash RAM in decimal. Since piece wise continuity, 64 K space is divided into 8 regions. Then each region is divided into 32 blocks that each block contains the same data. This binary data is generated by a computer program and then down loaded into the flash RAM in the board. Interconnections from FPGA to the flash memory are handled by the foundation tools provided by the producer.

Table 3. Approximation to the sigmoid with piece wise linear polynomial functions

| INPUT | OUTPUT |
|----------------|------------|
| 0 .. 20012 | 0 .. 31 |
| 20013 .. 25568 | 32 .. 63 |
| 25569 .. 29420 | 64 .. 95 |
| 29421 .. 32767 | 96 .. 127 |
| 32768 .. 36115 | 128 .. 159 |
| 36116 .. 39967 | 160 .. 191 |
| 39968 .. 45520 | 192 .. 223 |
| 45521 .. 65536 | 224 .. 255 |

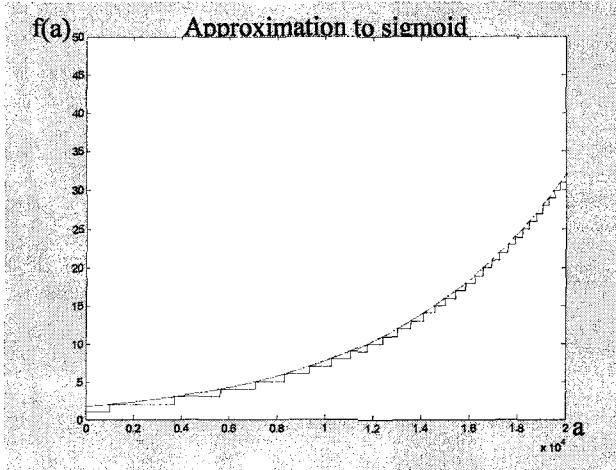


Figure 3. A part of the sigmoid function and hardware approximation

Figure 3 shows the comparison between the sigmoid and the hardware approximation in part. The graph shows that the hardware realization of the sigmoid function provides reasonable approximation for this function.

III. IMPLEMENTATION THE NEURON MODEL

The complete data path shown in Figure 4 corresponds to our neuron-model. Significant effort is put to the design to be modular and parametric so it can be easily expanded to a neural network. The design includes the following logic blocks: 8 bit multiplier, 16 bit adder, registers (W_0, W_1, W_2, W_3), 16 bit registers, 8 way 4 to 1 multiplexers, a decoder, a counter and a controller. We accommodate everything except activation function in Spartan II FPGA. Our implementation consumes a significant amount of resources but maintains speed. Activation function is implemented in the flash RAM located near the FPGA in the board.

The implementation platform was XSA-50 board produced by Xess Corporation. The board comes with two programmable chips on it: Xilinx Spartan 2 – XC2S50 FPGA and Xilinx XC9572 complex programmable logic device (CPLD). The board also includes 8 Mbytes SDRAM, 128 Kbytes flash RAM, 100 MHz. programmable oscillator, 4 DIP switches, 7 segment display and standard ports (parallel, PS/2 and VGA ports) to connect to a PC. Figure 4 shows the board. These FPGA, CPLD, oscillator, flash and SDRAM can be reached to download or upload from a PC via parallel port.

Most of the design was done in Verilog-HDL in gate level. Only the multiplier is designed in behavioral level. All individual parts of the design; registers, multiplier, adder, multiplexers, decoder and controller have been compiled and simulated separately. The control circuitry consists of a state machine that was designed through state flow diagrams (shown in Figure 5).

Resource allocation has been a central issue during the implementation because choices have to be made to optimize the design for both space and performance. Many researchers have chosen to focus on space efficiency to allow for larger circuits using serial processing schemes [7]. We concentrated on performance because XC2S50 FPGA provides 50,000 gates and

384 configurable logic blocks (CLB) that is more than what we needed. The number of IO for the model is 56 and available user IO pins for the FPGA is 176. Although some IO pins are lost due to board but it did not cause any problem to the implementation.

Before synthesizing the circuitry, the simulation is carried out by the Xilinx foundation software ModelSim XE. With the aid of this simulation tool, input values are defined for each module and the final result is observed at the last block. Figure 6 shows signals from different modules during the simulation.

Finally, the design was synthesized using Xilinx Project Navigator. This software does the fitting, place and route, timing, and generates the bit-stream that is used to program the chip. The design easily fit into XC2S50 FPGA using nearly 35% of the chip resources.

The maximum delay between flip-flops determines the clock frequency. Project Navigator provides this number for the designer based on the chip selected and the way the software did the place and route part of the design. The maximum clock frequency for this design is 74.305 MHz.

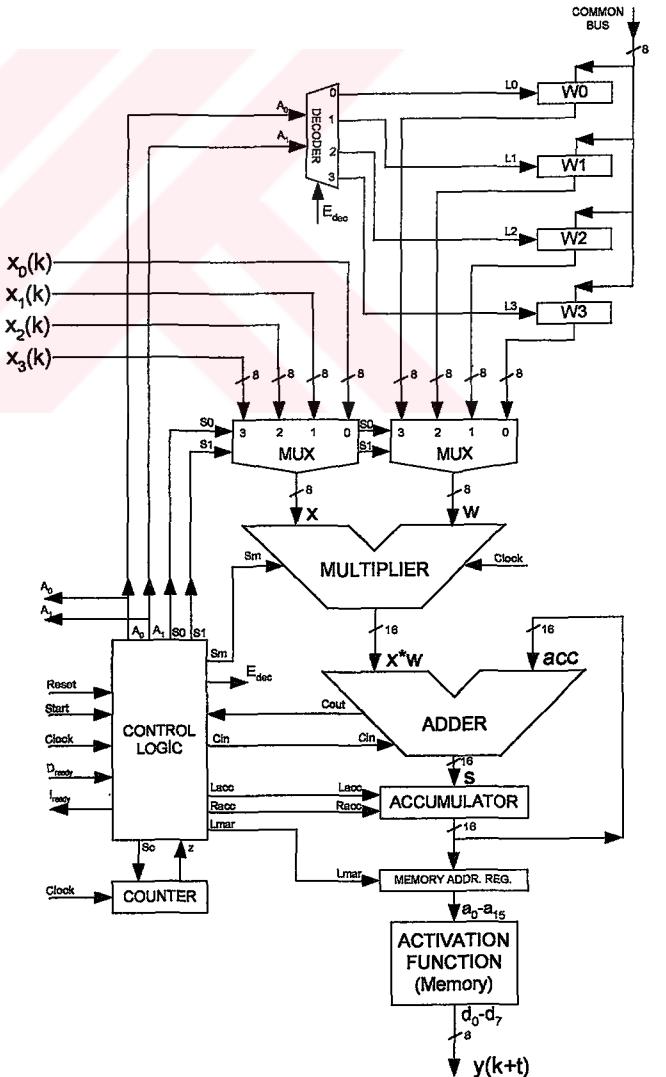


Figure 4. The data path of the neuron model.

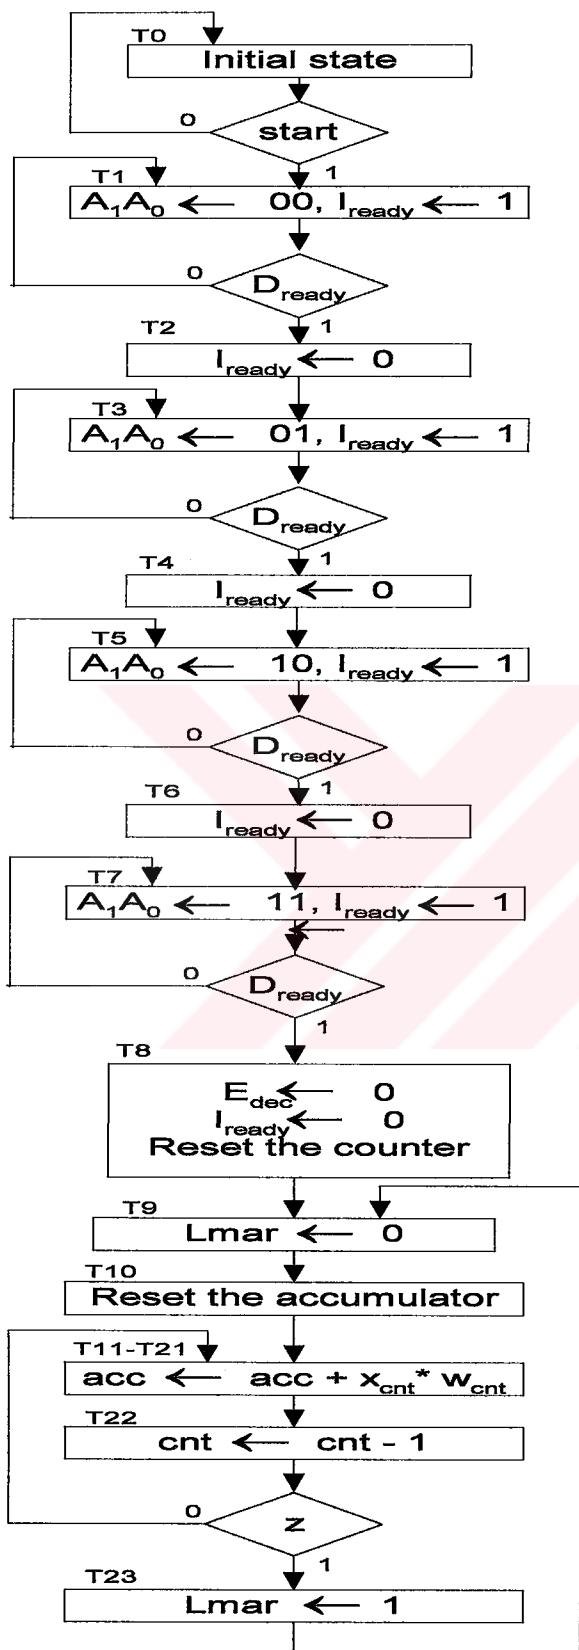


Figure 5: State flow diagram for controller

IV. CONCLUSION

In this work the neuron model is designed simulated and synthesized in Xilinx Spartan 2, XC2S50 FPGA. This is achieved using Xilinx foundation software packages and XSA-50 boards that instrumented with download and upload utilities. Design, simulations, programming the chip and refinements performed on the fly, and a complete working neuron model obtained.

Since learning achieved off line the system complexity dropped dramatically. However, a neuron can be trained off-line and then computed weights can be downloaded into chip before using it. The dedicated hardware with these weights will perform the desired functionality. New training can be done many times and each time a different functionality will be obtained.

Maximum effort is consumed to create a modular neuron model to be able to implement a neural network. Currently, we are working on fitting multiple neurons into one chip. We are planning to utilize more resources (e.g. flash RAM, SDRAM, and CPLD) on the Xess boards on next attempts. Our future research will continue in two ways:

1. Explore a way to implement learning algorithm(s) in the FPGA chips.
2. Explore technology and algorithms and find a way to implement multiple neurons in one FPGA.

ACKNOWLEDGEMENTS

This work has been carried out donated software and hardware (foundation software and Xess boards) by Xilinx.

REFERENCES

1. W.S. McCulloch, W. Pitts, A Logical Calculus of the Ideas Imminent in Nervous Activity. *Bulletin of Mathematical Biophysics*, vol: 5, pp:115-133, 1943.
2. J.J. Blake, L.P. Maguire, T.M. McGinnity, B. Roche, L.J. McDaid, The Implementation of Fuzzy Systems, Neural Networks and Fuzzy Neural Networks using FPGAs, *Information Sciences*, vol: 112, pp. 151-168, 1998.
3. M.A. Ashour, H.I. Saleh, An Implementation Guide for Some Different Types of Serial-Parallel Multiplier structures, *Microelectronics Journal*, vol: 31, pp. 161-168, 2000.
4. H. Lee, G.E. Sobelman, Performance Evaluation and Optimal Design for FPGA-based Digit-Serial DSP Functions, *Computers and Electrical Engineering*, vol: 29, pp. 357-377, 2003.
5. M.M. Mano, *Digital Design*, Prentice/Hall International Inc., New Jersey, 1984
6. M. McKenna, B. Wilamowski, Implementing a Fuzzy System on a Field Programmable Gate Array, *International Joint Conference on Neural Networks (IJCNN'01)*, pp. 189-194, Washington DC, July 15-19, 2001.
7. M. Gschwind, V. Salapura, O. Maisberger, Space Efficient Neural Net Implementation, In Proc. Of the Second International ACM/SIGDA Workshop on Field Programmable Gate Arrays, Berkeley, CA, Feb. 1994.
8. A. Nelson, T. Marcelo, Custom Architectures for Fuzzy and Neural Networks Controllers, *Journal of Computer Science and Technology*, Vol: 2, No:7, pp: 9-15, 2002.

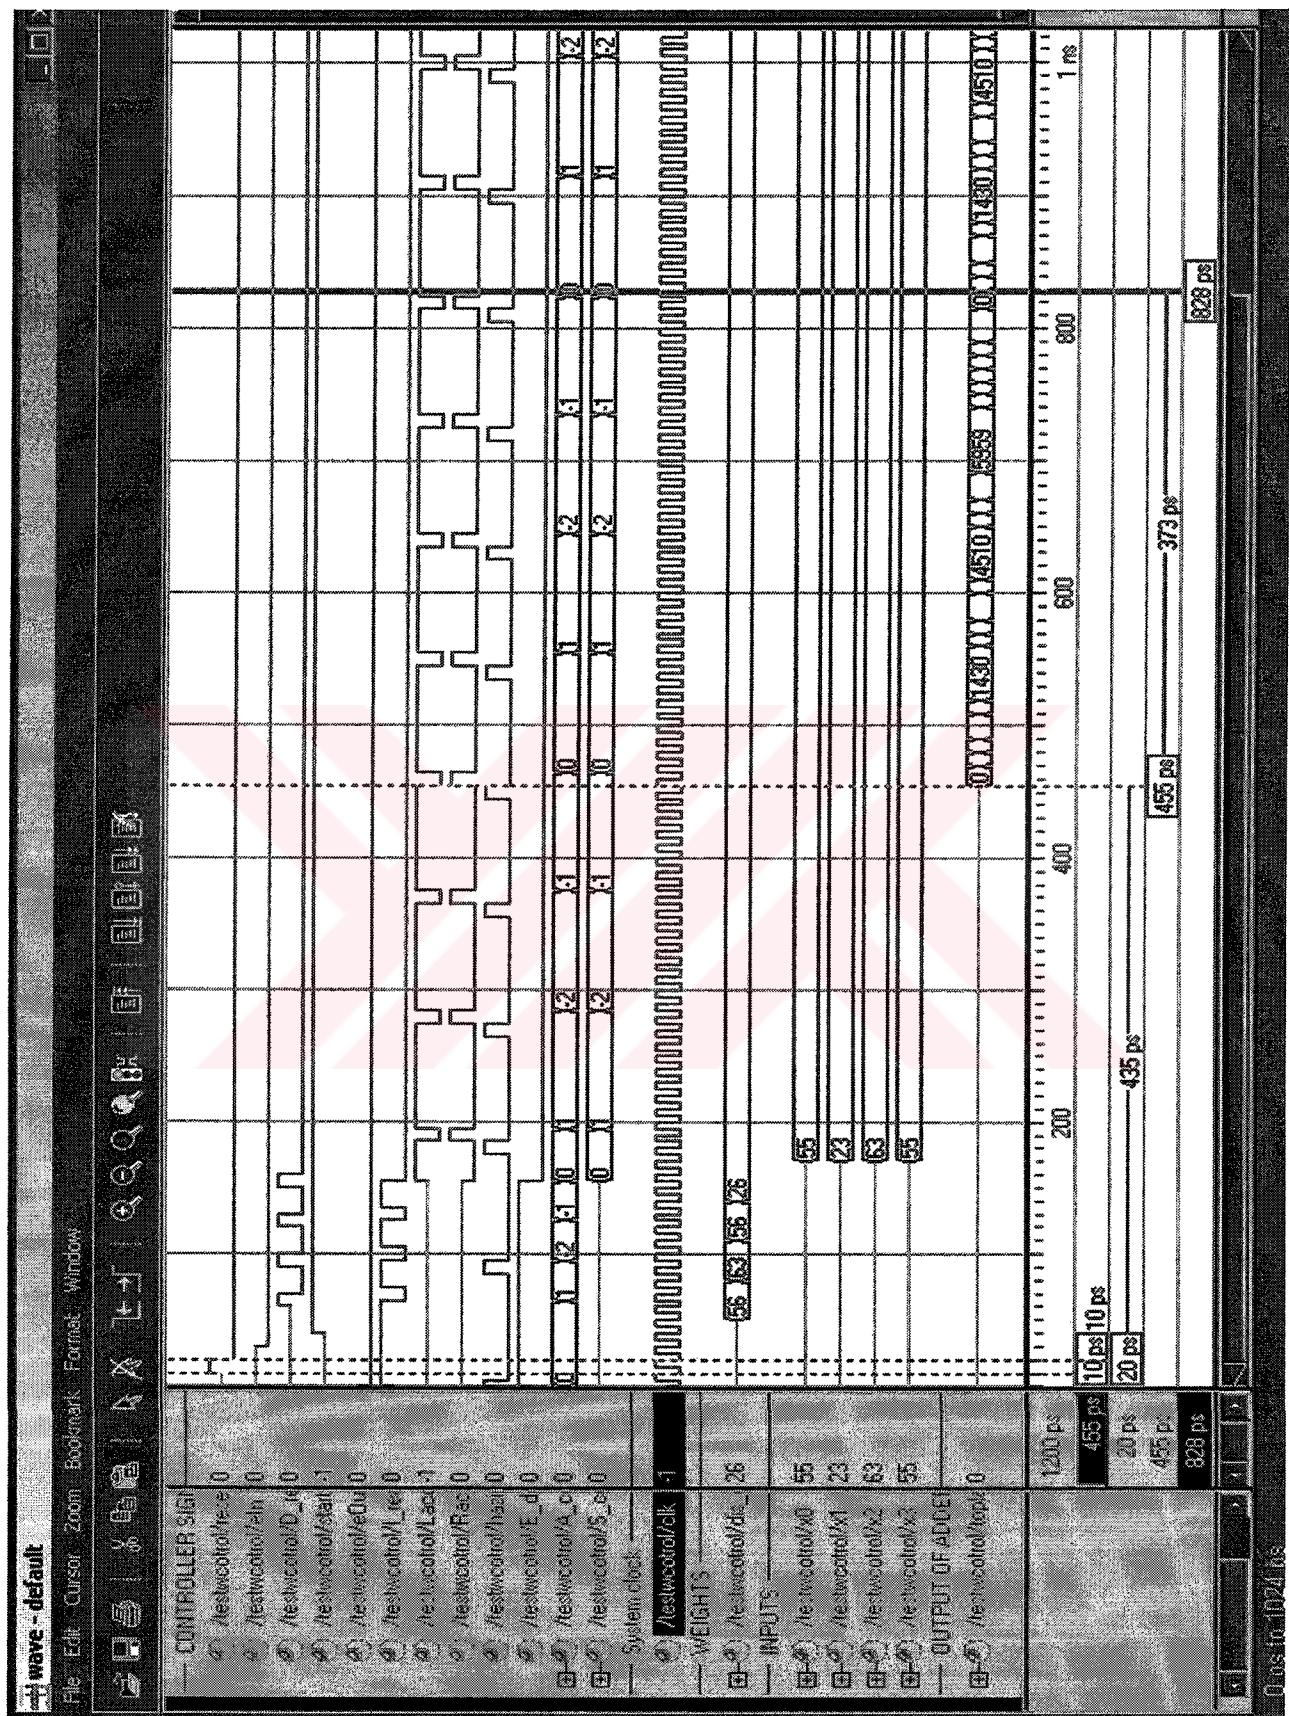


Figure 6. Timing diagram of the neuron model simulation.

Ek2: Finding the Composition of Gas Mixtures by a Phthalocyanine Coated QCM Sensor Array and an Artificial Neural Network

A. Özmen¹, F. Tekce¹, M. A. Ebeoglu^{1,3}, C. Taşaltn³ and Z.Z. Öztürk^{2,3}

¹Department of Electrical and Electronics Engineering, Dumlupınar University, Kütahya, 43100, TURKEY

²Department of Physics, Gebze Institute of Technology, PO Box 141, 41400 Gebze-Kocaeli, TURKEY

³TUBITAK, Marmara Research Center, Materials and Chemical Tech. Res. Inst.,
PO Box 21, 42470 Gebze-Kocaeli, TURKEY

Abstract

This paper presents a system which is made of an array of 8 phthalocyanine coated QCM sensors and an ANN to find the corresponding composition of a gas mixture. The digital data collected from the sensor responses were preprocessed by a sliding window algorithm, and then used to train a three layer ANN to determine the gas compositions. The system is tested with the following gas mixtures: (1) Ethanol-acetone, (2) Ethanol-trichloroethylene, (3) Acetone-trichloroethylene. The success rate of the system in identifying the constituent component amounts is 60.9% and 90.9%. Similarly, overall average prediction error is 24.1%.

1. Introduction

The analysis of a mixture of gases represents one of the main objectives of current research in the sensor field. The problem can be solved by either adopting highly selective sensors or using an array of sensors, which are scarcely selective, incorporated with a data-analysis technique. An array of Quartz Crystal Microbalances (QCM) also called acoustic sensors are widely used for detecting the change of resonant frequency of each sensor as a function of gasses. Over the past 15 years, a lot of important work has been done on developing gas recognition systems from its smell using pattern recognition algorithms, principal component analysis, neural networks and fuzzy logic systems [1, 2].

In this work, an array of eight Quartz Crystal Microbalances (QCM)s are used as sensor system to measure the mixed gas attributes. Firstly, signals from the sensor array in response to gas mixtures were preprocessed by a sliding window algorithm to obtain a valid data set. Then, this data is used to train a three layer artificial neural network (ANN), and later any digital data from sensor array is applied to the ANN to find the corresponding composition of the gas mixture. During the study, three different gas mixtures were analyzed: (1) ethanol and acetone, (2) ethanol and trichloroethylene, (3) acetone and trichloroethylene. Each experiment includes purging phase and application of gas mixture phase sequentially, which takes about 165 minutes for measurement of five different gas compositions. Figure 1 shows a schematic view of the experimental setup. The gas compositions were obtained changing one of the constituent gas amount in five times, and holding the other's fixed.

2. Experimental

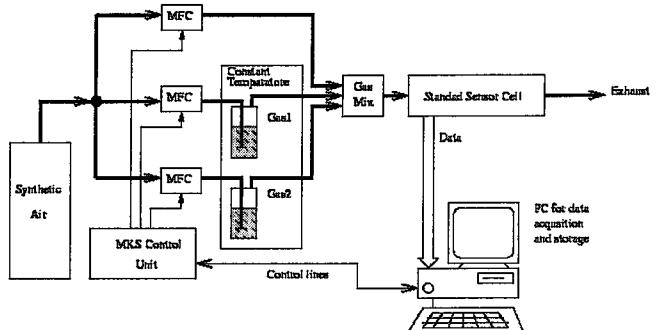


Figure 2. Schematic view of the experimental setup

Table 2 shows compositions of mixtures of ethanol, trichloroethylene and acetone used in this work. Some of the data shown in the Table 1. are used for training the artificial neural network and the rest is used for the determination of the success rate. Those without the t sign were used for the training of the network.

The data logger records the frequency differences Δf of each sensor in every 3-4 seconds in the system shown in Figure 1. A great amount of raw data is collected via sensor system for each experiment. As an example, Figure 1.1. shows the sensor-3 response for acetone and trichloroethylene mixture. In Figure 1.1., each ripple represents a different gas composition; lower level of the ripples show sensor cleaning phases (purging) and upper level show gas introduction phases.

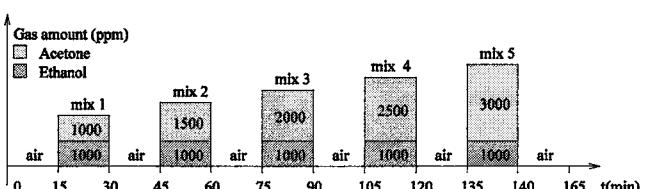


Figure 2.1. Obtaining different mixtures by holding the amount of ethanol fixed and changing the amount of acetone. Figure shows experiment 3 in Table 2

When a gas mixture is introduced, each sensor responds in a characteristic way by drifting from its center frequency. This drift shows differences among the sensors even in purging phase, which is called "base line". Hence, each sensor has a different base line: For example, the sensor-3 has a baseline around 2340 Hz. Δfs shown in the Figures are distance to the 10 MHz. center frequencies of the sensor crystals.

Table 2. Compositions of three different gas combinations: (i) Acetone and Ethanol, (ii) Acetone and Trichloroethylene, (iii) Ethanol and Trichloroethylene

| Experiment (i) | (ii) | Gas Composition (ppm) | | <i>(i) Acetone : Ethanol</i> | |
|-------------------|------|------------------------|-----------|---|------------------------|
| | | | | <i>(ii) Acetone : Trichloroethylene</i> | |
| 1 | 6 | 250:1000 | 250:1500 | 250:2000 | 250:2500 |
| 2 | 7 | 500:1000 ^t | 500:1500 | 500:2000 | 500:2500 ^t |
| 3 | 8 | 1000:1000 | 1000:1500 | 1000:2000 | 1000:2500 |
| 4 | 9 | 2000:1000 ^t | 2000:1500 | 2000:2000 | 2000:2500 ^t |
| 5 | 10 | 3000:1000 | 3000:1500 | 3000:2000 | 3000:2500 |
| <i>(iii)</i> | | | | | |
| 11 | | 250:550 | 250:1650 | 250:2200 | 250:2750 |
| 12 | | 500:550 ^t | 500:1650 | 500:2200 | 500:2750 ^t |
| 13 | | 1000:550 | 1000:1650 | 1000:2200 | 1000:2750 |
| 14 | | 2000:550 ^t | 2000:1650 | 2000:2200 | 2000:2750 ^t |
| 15 | | 3000:550 | 3000:1650 | 3000:2200 | 3000:2750 |

The data shown in Figure 3 is spiky and includes purging phase of sensors which must be removed to obtain valid data. The spikes are rounded using a sliding window algorithm with a window size of 50. The sliding window is an iterative approach, and holds 50 samples at a time from a sequence of interest. The sequence is made up with sensor data for our experiments. While the window slides from left to the right hand side over the sequence, it calculates the moving average of the samples except purging phases. The Figure 4 shows the filtered sensor responses.

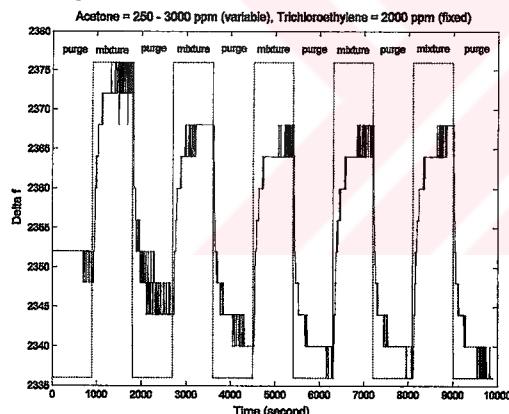


Figure 3. Sensor 3 response for variable concentration of acetone and fixed trichloroethylene

in x axis, and the other gas in y axis and Δf in z axis. An example plot is shown in Figure [5]. These figures contain behavioral information about the sensor responses, and they are important to decide whether sensor outputs are linear or not according to constituent gas amounts. After examination, it is seen that the surfaces are not linear and can not be parameterized in any way.

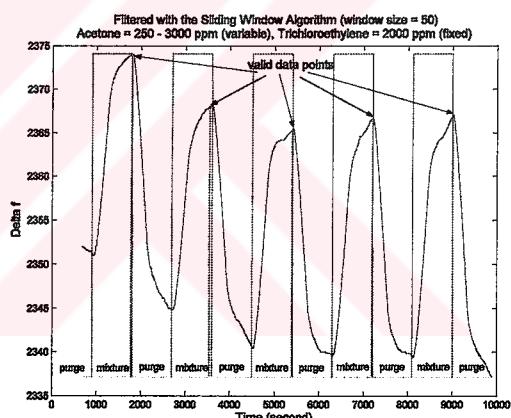


Figure 4. . Sensor 3 response with the sliding window algorithm with a size of 50

Sensor 3 response (Δf) for variable ppm amounts of acetone versus trichloroethylene

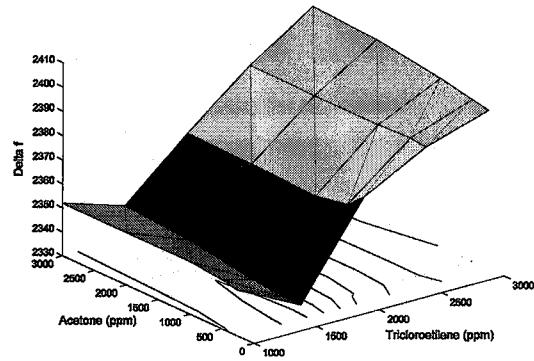


Figure 5. The sensor-3 output is plotted according to different gas mixtures and different compositions.

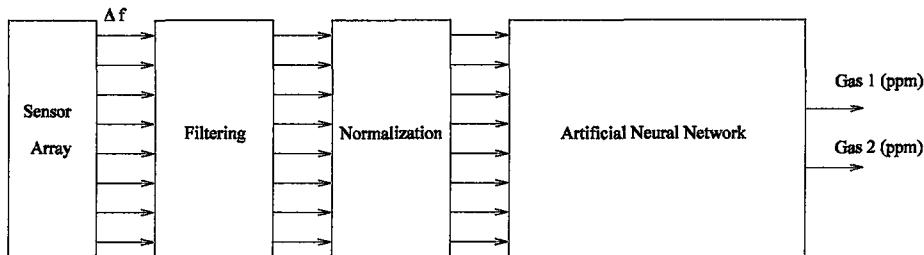


Figure 6. Data processing system.

Table 2. Test results: ANN predictions and errors for the predictions.

| Acetone | Gases in mixture(ppm) | | | ANN Predictions (ppm) | | Prediction Error | |
|---------|-----------------------|------------|--|-----------------------|---------|------------------|-------|
| | Ethanol | Trichloro. | | Gas 1 | Gas 2 | Gas 1 | Gas 2 |
| - | 500 | 550 | | 546.74 | 531.04 | 9.5% | 3.5% |
| 500 | 1000 | - | | 770.05 | 971.11 | 54% | 2.89% |
| 500 | - | 1000 | | 549.85 | 1183.30 | 9.9% | 18.3% |
| - | 500 | 2200 | | 562.14 | 2133.90 | 3.0% | 12.4% |
| 500 | 2500 | - | | 1268.80 | 2563 | 153.7% | 2.5% |
| 500 | - | 2500 | | 434.71 | 2579.00 | 13.1% | 3.2% |
| - | 2000 | 550 | | 2095.40 | 527.22 | 4.8% | 4.1% |
| 2000 | 1000 | - | | 5252.00 | 1309.80 | 162.6% | 31.0% |
| 2000 | - | 1000 | | 2101.50 | 1081.20 | 5.1% | 8.1% |
| - | 2000 | 2200 | | 2286.00 | 2283.90 | 3.8% | 14.3% |
| 2000 | 2500 | - | | 2998.60 | 2443.30 | 49.9% | 2.3% |
| 2000 | - | 2500 | | 2001.70 | 2681.90 | 0.1% | 7.3% |

3. Results and Discussion

Since artificial neural networks are non-parametric methods and do not require linearity of sensor responses, a back propagation neural network was used composed one hidden layer to discriminate between different samples. The number of neurons in the input, hidden and the output layers are 8, 30 and 2 respectively. The training data for the ANN is obtained from sensor system during the experiments given in Table 1. When the data examined, it is seen that Δf takes values between 2340 – 2408 Hz. for this particular example. However, the level of the inputs to the ANN should be arranged between 0 and 1, hence, a level adjustment for each sensor response was performed by dividing them with the maximum Δf . Figure 6 shows data processing system used in this work.

4. Conclusions

As a result, we have demonstrated that finding the compositions of gas mixtures using an array of QCM sensors and ANN is possible. The success rate in identifying the constituent component amounts of the approach 60.9% for gas 1, 90.9% for gas 2. Similarly, average prediction errors are 39.1% for gas 1, 9.1% for gas 2 and 24.1% overall. The test results are shown in Table 2.

Although the system developed in this work is applicable only when a gas mixture belongs to the certain specified categories, however, it can be expanded toward the successful identification of gas species and

determination of its concentration in a gas mixture by using different kinds of sensor arrays.

Acknowledgments

Place acknowledgments here, if needed.

References

1. Gardner, J.W., Detection of vaporous and odors from a multi-sensor array using pattern recognition. Part 1. Principal component and cluster analysis. Sensors and Actuators B. Vol. 4 (1991) 109-115
2. Dutta, R., Hines, E.L., Gardner, J.W., Kashwan, K.R., Bhuyan, M., Tea Quality Prediction Using a Tin Oxide-based Electronic Nose, An Artificial Intelligence Approach. Sensors and Actuators B. Vol. 94 (2003) 228-237.