

**YAPAY SINIR AđI TASARIMI: EđİTİM SÜRECİNİN  
OPTİMİZASYONU VE GIDA MÜHENDİSLİđİ  
ALANINDA UYGULANMASI**

**DESIGNING OF ARTIFICIAL NEURAL NETWORK:  
OPTIMIZATION OF TRAINING PERIOD AND  
APPLICATION IN FOOD ENGINEERING**

**KIVANÇ KILIÇ**

Hacettepe Üniversitesi

Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliđinin

Gıda Mühendisliđi Anabilim Dalı İçin Öngördüđü

**YÜKSEK LİSANS TEZİ**

olarak hazırlanmıřtır.

2007

Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Bu çalışma jürimiz tarafından **GIDA MÜHENDİSLİĞİ ANABİLİM DALI'nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Başkan :.....  
Prof. Dr. M. Mehmet MUTLU

Üye :.....  
Doç Dr. Nihal AYDOĞAN

Üye (Danışman) :.....  
Doç Dr. İsmail Hakkı BOYACI

ONAY

Bu tez 24/05/2007 tarihinde Enstitü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından kabul edilmiştir.

...../...../2007

Prof. Dr. Erdem YAZGAN  
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

# YAPAY SİNİR AĞI TASARIMI: EĞİTİM SÜRECİNİN OPTİMİZASYONU VE GIDA MÜHENDİSLİĞİ ALANINDA UYGULANMASI

Kıvanç KILIÇ

## ÖZ

Yapay sinir ağı (YSA) eğitim süreci ağın performansını belirleyen en önemli aşamadır. Ağ parametrelerinin fazla olması nedeniyle uygun ağ parametrelerini kullanarak daha doğru tahmin kapasitesine sahip ağın seçilmesi her zaman mümkün olamamaktadır. Uygun ağ parametrelerinin seçiminin tek yolu mümkün olan tüm parametre kombinasyonlarında ağın eğitilmesi, test edilmesi ve sonrasında en iyi eğitilmiş ağın seçilmesidir. Çalışma kapsamında yapay sinir ağı eğitim sürecinde parametre optimizasyonunda kullanılabilecek bir yazılım geliştirilmiş ve farklı veri grupları için test edilmiştir. Geliştirilen yazılım kullanılarak eğitim, validasyon ve test verileri sisteme beslenebilmekte ve sonrasında farklı ağ parametrelerinde eğitim gerçekleştirilebilmektedir. Yüksek doğrulukta tahmin gücüne sahip ağ, tahmin edilen değerler ile gerçek değerler arasındaki istatistiksel skorlara (ortalama mutlak sapma (OMS), regresyon katsayısı ( $R^2$ ) ve hata kareler ortalaması (HKO)) bakılarak seçilebilmektedir. Geliştirilen yazılım beş farklı veri grubu ( $y=e^x$  veri grubu, kinetik veri grubu, enzimatik reaksiyon hızı veri grubu, absorpsiyon- $L*a*b^*$  veri grubu ve RGB- $L*a*b^*$  veri grubu) için test edilmiştir. Herhangi bir deneysel hata içermeyen ve matematiksel olarak üstel fonksiyon kullanılarak üretilen birinci veri grubu için çok yüksek doğrulukta tahmin yeteneğine sahip ağ eğitilebilmiştir. Ağın ürettiği değerler gerçek değerler ile karşılaştırılarak istatistiksel skorlar OMS: % 0.004,  $R^2$ : 1.000 ve HKO: 0.00263 olarak saptanmıştır. Enzimatik reaksiyon parametrelerinin (substrat derişimi ve ortam pH'sı) enzimatik reaksiyon hızına etkilerinin incelendiği kinetik veri grubunda sınırlı sayıda veri kullanılarak eğitim gerçekleştirilmiş ve en iyi ağ seçilmiştir. Seçilen ağın kullanılmasıyla OMS: % 9.29;  $R^2$ : 0.965 ve HKO: 0.0071 istatistiksel skor değerleri saptanmıştır. Zaman-derişim verilerinin kullanılmasıyla elde edilen veri grubunda ise aynı istatistiksel değerler için sırasıyla % 0.73, 0.994 ve 0.124 olarak elde edilmiştir. Ayrıca bu aşamada YSA'nın mühendislik uygulamalarında matematiksel eşitlik yerine kullanılabilirliği de gösterilmiştir. Absorpsiyon- $L*a*b^*$  veri grubu için aynı yazılım kullanılarak genel kullanım amaçlı bir spektrofotometrenin sıvı örnekler için  $L*a*b^*$  formatında veri üretmesi mümkün kılınmıştır. Her üç renk değeri de yüksek doğrulukta tahmin edilebilmiştir. Son veri grubu için ofis ekipmanları kullanılarak renk ölçüm düzeneği hazırlanmış tarayıcıda alınan dijital görüntüler tez kapsamında hazırlanan yazılım sayesinde işlenerek YSA ile birlikte RGB renk değerlerinden  $L*a*b^*$  renk değerlerinin tahmin edilmesi sağlanmıştır. Bu sayede renk homojenliğine ve düzgün bir şekilde sahip olmayan gıda örnekleri için renk ölçümü basit ekipmanlarla yapılabilir hale getirilmiştir. Çalışma kapsamında geliştirilen yazılım yapay sinir ağı eğitim parametrelerinin optimizasyonu ve uygun ağın seçilmesi sürecinde tüm veri gruplarında yüksek başarı sağlamıştır.

**Anahtar kelimeler:** Yapay sinir ağı, ağ parametreleri, optimizasyon, gıda uygulamaları

Danışman: Doç. Dr. İsmail Hakkı Boyacı, Hacettepe Üniversitesi, Gıda Mühendisliği Bölümü, Gıda Mühendisliği Anabilim Dalı

# DESIGNING OF ARTIFICIAL NEURAL NETWORK: OPTIMIZATION OF TRAINING PERIOD AND APPLICATION IN FOOD ENGINEERING

Kıvanç KILIÇ

## ABSTRACT

The training process of an Artificial Neural Network (ANN) is the most important constituent of performance-determining step. Choosing a better estimating network using proper network parameters is not always possible because of large number of network parameters. The only way of choosing proper network parameters is to train and test the network in all possible combinations first, then picking the best-trained network. In this study, software was developed for the optimization of parameters in the training process and tested in the food engineering applications. The training can be performed in different network parameters and their all possible combinations after feeding validation and test data to the system using the developed software.

A network with strong estimation power is selected based on comparison of some statistical scores such as Average Absolute Deviation (AAD), Correlation Coefficient ( $r^2$ ), and Mean Square Error (MSE) of estimated data and “true” data. The developed software was tested for five different data sets:  $y=e^x$  data set, kinetic data set, enzymatic reaction rate data set, absorbance- $L^*a^*b^*$  data set, and RGB- $L^*a^*b^*$  data set. A trained network with very high estimation skill was selected for the first data set including no experimental error and produced by an exponential mathematical function. Statistical scores in between true values and the estimated values such as AAD,  $r^2$ , and MSE are % 0.004, 1.000, and 0.00263 respectively for the test data. In the kinetic data set where the effects of enzymatic reaction parameters (substrate concentration and pH) on the enzymatic reaction rate was studied, training was performed using limited number of data and the best performing network was selected. Using the selected network, statistical scores of AAD: % 9.29,  $r^2$  : 0.965 , and MSE: 0.0071 were obtained. The same statistical criteria were obtained as % 0.73, 0.994, and 0.124 respectively using concentration-time data. Additionally, it was shown that ANN can be used instead of a mathematical equilibrium in engineering applications. It was made possible for a general purpose spectrophotometer to produce data in  $L^*a^*b^*$  format for liquid samples using the same software of absorbance- $L^*a^*b^*$  data set. All three color values were estimated with high accuracy. The digital images obtained in the prepared color measurement apparatus using an office equipment for the last data set was processed by the developed software and  $L^*a^*b^*$  color values were estimated from ANN and RGB color values

It was also made possible to measure the color of the food samples without color homogeneity and a certain shape using simple office equipment. The software developed in this study was highly successful in the optimization of artificial neural network training parameters and selection of the proper network processes for the all data sets.

**Keywords:** Artificial neural network, network parameters, optimization, food application

Advisor: Assoc. Prof. Dr. İsmail Hakkı BOYACI, Hacettepe University, Department of Food Engineering, Food Engineering Section

## TEŞEKKÜR

Bu çalışmanın planlanması, yürütülmesi ve sonuçlandırılmasında bilgisi ve deneyimi ile bana yol gösteren, karşılaştığım sorunların çözümünde yardımlarını esirgemeyen değerli danışmanım Sayın Doç.Dr. İsmail Hakkı Boyacı'ya,

Yüksek lisans eğitimim boyunca desteğini esirgemeyen Sayın Prof. Dr. Mehmet Mutlu'ya,

Deneyisel çalışmalarında ve karşılaştığım sorunların çözümünde desteklerini esirgemeyen Dr. Özcan Ceylan, Dr. Esra Acar Soykut, Yük. Müh. Deniz Baş, Yük. Müh. Fahriye Ceyda Dudak ve Yük. Müh. Esen Sokullu'ya,

Bu tezin hazırlanmasında bana her türlü çalışma olanağını sağlayan Hacettepe Üniversitesi Gıda Mühendisliği Bölümü'ne ve tüm personeline,

Hayatımın her döneminde verdikleri sevgi ve destek ile yanımda olan başta sevgili annem Şermin Kılıç'a ve tüm aileme en içten teşekkürlerimi sunuyorum.

## İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
<b>ÖZ</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>İÇİNDEKİLER DİZİNİ</b> .....	<b>iv</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>vi</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>x</b>
<b>SİMGE VE KISALTMALAR DİZİNİ</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. GENEL BİLGİLER</b> .....	<b>4</b>
2.1. Yapay Sinir Ağları .....	4
2.1.1. Yapay sinir ağlarının yapısı ve temel elemanları .....	5
2.1.1.1. Biyolojik sinir sistemi ve sinir hücresi .....	5
2.1.1.2. Yapay sinir ağı hücresi.....	7
2.1.2. Yapay sinir ağ yapıları.....	9
2.1.3. Yapay sinir ağlarının eğitilmesi .....	10
2.1.4. Yapay sinir ağlarının tasarımı .....	11
<b>3. MATERYAL VE METOT</b> .....	<b>13</b>
3.1. Yapay Sinir Ağının Oluşturulması .....	13
3.1.1. Aktarım fonksiyonu .....	13
3.1.2. Eğitim fonksiyonu.....	13
3.1.3. Gizli katman Nöron Sayısı .....	14
3.1.4. Eğitim süreci iterasyon sayısı .....	15
3.2. Optimizasyon Algoritmasının Oluşturulması ve Matlab Kodunun Yazılması.....	15
3.3. Veri Setleri ve Verilerin Elde Edilmesi.....	16
3.3.1 e <sup>x</sup> veri grubu.....	17
3.3.2 Kinetik veri grubu-I.....	18
3.3.3 Kinetik veri grubu-II.....	19
3.3.4 Absorbans-renk veri grubu.....	21

## İÇİNDEKİLER DİZİNİ (devam ediyor)

	<u>Sayfa</u>
3.3.5 RGB-L *a*b* veri grubu.....	22
3.4. Ağ Performansının İstatistiksel Olarak Değerlendirilmesi .....	23
<b>4. DENEYSEL SONUÇLAR VE TARTIŞMA .....</b>	<b>26</b>
4.1. Yapay Sinir Ağlarının Optimizasyonu.....	27
4.2. e <sup>x</sup> Veri Grubu ve Ağ Optimizasyonu.....	28
4.3. Kinetik Veri Grubu-I ve Ağ Optimizasyonu.....	31
4.3. Kinetik Veri Grubu-II ve Ağ Optimizasyonu .....	36
4.4. Absorbans-renk veri grubu.....	40
4.5. RGB-L *a*b* veri grubu.....	48
<b>5. TARTIŞMA VE YORUM .....</b>	<b>58</b>
<b>KAYNAKLAR.....</b>	<b>60</b>
<b>EK .....</b>	<b>62</b>
<b>ÖZGEÇMİŞ .....</b>	<b>65</b>

## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1	Biyolojik sinir sisteminin blok gösterimi ..... 5
Şekil 2.2	Biyolojik sinir hücresi ve bileşenleri ..... 6
Şekil 2.3.	Temel yapay sinir ağı hücresi. .... 7
Şekil 2.4.	Aktivasyon fonksiyonu örnekleri a) eşik değer fonksiyonu, b) doğrusal fonksiyon, c) sigmoid fonksiyonu. .... 8
Şekil 2.5.	İleri beslemeli yapay sinir ağı..... 10
Şekil 2.6.	Geri beslemeli yapı..... 10
Şekil 3.1	Ağ optimizasyonu için kullanılan bilgisayar algoritması. .... 16
Şekil 4.1	Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). .... 29
Şekil 4.2	Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların $R^2$ değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). .... 29
Şekil 4.3.	Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). .... 30
Şekil 4.4.	Eğitilmiş ağın ürettiği değerlerin gerçek değerler ile karşılaştırılması ..... 32
Şekil 4.5.	Kinetik veri grubu-I ile eğitilmiş ağların OMH değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). .... 33
Şekil 4.6.	Kinetik veri grubu-I ile eğitilmiş ağların $R^2$ değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). .... 33



## ŞEKİLLER DİZİNİ (devam ediyor)

### Sayfa

Şekil 4.7. Kinetik veri grubu-I ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	34
Şekil 4.8. Eğitilmiş ağın üretmiş olduğu değerlerin gerçek değerler ile karşılaştırılması. ....	35
Şekil 4.9. Kinetik veri grubu-II veriler ile eğitilmiş ağların OMS değer dağılımları ..... (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	36
Şekil 4.10. Kinetik veri grubu-II ile eğitilmiş ağların R <sup>2</sup> değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	37
Şekil 4.11. Kinetik veri grubu-I ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	37
Şekil 4.12. Birinci ağın üretmiş olduğu değerlerin deneysel değerler ile karşılaştırılması. ....	39
Şekil 4.13. İkinci ağın üretmiş olduğu değerlerin deneysel değerler ile karşılaştırılması .....	40
Şekil 4.14. Absorbans-L *a*b* veri grubu ile eğitilmiş ağlar için L* renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	41
Şekil 4.15. Absorbans-L *a*b* veri grubu ile eğitilmiş ağlar için L* renk değeri için R <sup>2</sup> değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	42
Şekil 4.16. Absorbans-L *a*b* veri grubu ile eğitilmiş ağlar için L* renk değeri için HKO değer dağılımları ..... (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, x: On nöron).....	42

## ŞEKİLLER DİZİNİ (devam ediyor)

### Sayfa

- Şekil 4.17. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 43
- Şekil 4.18. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 44
- Şekil 4.19. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 44
- Şekil 4.20. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 45
- Şekil 4.21. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 46
- Şekil 4.22. Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 46
- Şekil 4.23. RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 49
- Şekil 4.24. RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 49
- Şekil 4.25. RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron). ..... 50

## ŞEKİLLER DİZİNİ (devam ediyor)

Sayfa

Şekil 4.26. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için a* renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	51
Şekil 4.27. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için b* renk değeri için R <sup>2</sup> değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	51
Şekil 4.28. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için b* renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	52
Şekil 4.29. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için b* renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	53
Şekil 4.30. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için b* renk değeri için R <sup>2</sup> değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	53
Şekil 4.31. RGB-L*a*b* veri grubu ile eğitilmiş ağlar için b* renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).....	54
Şekil 4.32. RGB renk değerlerinin L*a*b* renk değerlerine dönüştürmek için geliştirilen yazılım ara yüzeyi .....	56

## ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 3.1. Tez kapsamında kullanılan eğitim algoritmaları .....	14
Çizelge 4.1. Üstel fonksiyon veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri .....	31
Çizelge 4.2. Kinetik-I veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	35
Çizelge 4.3. Kinetik-2 veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	38
Çizelge 4.4. Absorbans-L veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	43
Çizelge 4.5. Absorbans-a* veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	45
Çizelge 4.6. Absorbans-b* veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	47
Çizelge 4.7. RGB-L* veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	50
Çizelge 4.8. RGB-a* veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	52
Çizelge 4.9. RGB-b* veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri. ....	55
Çizelge 4.10 Gıda örnekleri için ölçülen ve tahmin edilen renk değerleri .....	57

## SİMGELER VE KISALTMALAR DİZİNİ

A	Sabit katsayı
AKT	Artık kareler toplamı
b	Aktivasyon fonksiyonunun eşik değeri
CIE	Confédération Européenne de l'Immobilier
D	Sabit katsayı
DKT	Deneme kareler toplamı,
$f(\dots)$	Fonksiyon
HKO	Hata kareler ortalaması
k	Sabit katsayı
$L^*a^*b^*$	Renk formatı
n	Değer sayısı
RGB	Renk formatı
OMS	Ortalama mutlak sapma
o	Çıktı değeri
P	Ürün derişimi, mM
$R^2$	Regresyon katsayısı
S	Substrat Derişimi, mM
t	Zaman
T	Sıcaklık,
TKT	Toplam kareler toplamı
x	Bağımsız değişken
$X_{i,gerçek}$	Gerçek değer
$X_{i,pre}$	Tahmin edilen değer
v	Reaksiyon hızı, $\mu\text{mol/dk/mg}$ enzim
y	Bağımlı değişken

## **SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)**

YSA	Yapay sinir ağı
w	Ağırlık değeri
$\Delta E$	Ortalama renk değeri
$\Delta t$	Zaman artışı, s
$\beta$	Sabit katsayı

## 1. GİRİŞ

İnsanođlu tarih boyunca dođayı ve evreni anlamaya alıřmıř, bu konuda ortaya ıkan bilgiler fizik, kimya, biyoloji ve astronomi gibi temel bilim dallarının geliřmesini sađlamıřtır. Elde edilen bilgilerin gn getike sayısının artması ve karmařıklařması, bunların deđerlendirilmesinde, uygun řekilde grev yapacak sistemlerin geliřtirilmesini zorunlu kılmıřtır. Bu amala, geliřtirilen sistemler ierisinde en nemlisi, geen yzyıla damgasını vuran ve pek ok alanda bařarı ile kullanılabilen yapay zeka uygulamalarıdır (Karabođa, 2004).

Yapay zeka, insan zekasının ilk kez karřılařılan yada ani olarak geliřen bir olaya uyum sađlayabilme, anlama, đrenme, analiz yeteneđi, beř duyunun, dikkatin ve dřncenin yođunlařtırılması gibi zelliklerinin yazılım veya tmleřik yongalarla taklit edilmesidir (Elmas, 2003). Yapay zeka uygulamaları arasında pek ok bilim dalında ve mhendislik alanında yaygın olarak kullanılan ve bařarı ile uygulanan yapay sinir ađları (YSA) olduka nemlidir.

Yapay sinir ađları, insan beyninin zelliklerinden olan đrenme yolu ile yeni bilgiler tretebilme, yeni bilgiler oluřturabilme ve keřfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik gerekleřtirmek amacı ile geliřtirilen bilgi iřlem teknolojisidir (ztemel, 2003). Yapay sinir ađları, bu yetenekleri ile geleneksel programlama yntemleri ile gerekleřtirilmesi zor veya mmkn olmayan problemlerin zlmesinde, analiz edilmesinde olduka bařarılı olmaktadır. Diđer bir deyiřle, YSA normalde bir insanın dřnme ve gzlemlemeye ynelik dođal yeteneklerini gerektiren problemlere zm retmektedir.

Yapay sinir ađları, insan beyninin fonksiyonel zelliklerine benzer řekilde; đrenme, iliřkilendirme, sınıflandırma, genelleme, zellik belirleme ve optimizasyon gibi konularda bařarılı bir řekilde uygulanmaktadır (ztemel, 2003).

Bu kapsamda, YSA mühendislik dalları, tıp, savunma, sanayi, uzay ve havacılık, telekomünikasyon, üretim ve otomasyon, bankacılık, finans, robot uygulamaları, güvenlik ve lojistik gibi birbirinden çok farklı dallarda çok fazla sayıda uygulama alanı bulmaktadır.

Gıda maddeleri yapıları gereği karmaşık sistemler olduğundan, gıda bilimi ve teknolojisi alanında elde edilen verilerin incelenmesi, modellenmesi ve optimizasyonu amacı ile YSA oldukça başarılı sonuçlar elde edilmesine olanak tanımaktadır. Gıda bilimi ve teknolojisi alanında yapılan YSA uygulamaları, gıda işlenmesinde basınç uygulamaları ve ısı işlemler (Torrecilla et al., 2004), bakterilerin ısı inaktivasyonu (Lou et al. 2001), psikometrik tahminler (Mittal et al., 2003), antioksidan etkinin incelenmesin (Buciński et al., 2004), sütün ultrafiltrasyon performansının belirlenmesi (Razavi et al., 2003), bitkisel yağların sınıflandırılmasında (Brodnjak-Vončina et al., 2005), gıdalarda yüksek basınç uygulamalarının modellenmesinde (Torrecilla et al.,2005), yumurtaların tazeliğinin belirlenmesin (Dutta et al., 2003), peynirlerin nem miktarının tahmin edilmesinde (Jimenez-Marquez et al., 2005), konserve gıdalarda sterilizasyon etkinliğinin belirlenmesi (Gonçalves et al., 2005) enzimatik reaksiyon hızlarının herhangi bir kinetik model olmadan saptanması (Baş et al., 2007) olarak sıralanabilmektedir.

Yapay sinir ağları ile ilgili çok fazla çalışma olmasına rağmen ağ optimizasyonu pek çok çalışmada göz ardı edilmiş; sınırlı sayıda ağ denenmiş ve bu ağlar arasından başarılı olan ağ seçilmiştir. Ağ performansını etkileyen pek çok parametre bulunmaktadır. Bu parametrelerinin tamamının denenmesi mümkün olmamakla birlikte bilgisayar teknolojisini kullanarak maksimum düzeyde ağ parametresi denenebilmektedir. Bu tez kapsamında ağ performansını etkileyebilecek parametreler göz önünde bulundurularak maksimum sayıda ağ



oluřturulması, eđitilmesi ve farklı veri setleri kullanılarak test edilmesi hedeflenmiřtir. Bu hedef dođrultusunda öncelikle bilgisayar ortamında belirtilen ařamaları gerçekteřtirebilecek bir algoritma hazırlanmıř, MATLAB programı kullanılarak bu algoritmayı takip eden bir yazılım oluřturulmuř ve son ařamada yazılımın iřlevselliđi farklı veri grupları kullanılarak test edilmiřtir. alıřma kapsamında kullanılan veri setleri;

- $y=e^x$  veri grubundan elde edilen veriler kullanılarak yapay sinir ađının eđitilmesi
- Enzimatik reaksiyon parametreleri kullanılarak enzimatik reaksiyon hızın tahmin edilmesi
- Zaman-deriřim verileri kullanılarak enzimatik reaksiyon hızının tahmin edilmesi ve tahmin edilen hız deđerlerinin mühendislik uygulamalarında kullanılması
- Yađ örneklerinin absorbands spektrumları kullanılarak  $L*a*b$  renk deđerlerinin elde edilmesi
- Gıda örneklerinin bir tarayıcı yardımıyla elde edilen görüntülerinin  $L*a*b$  renk deđerlerinin tahmin edilmesinde kullanılması

olmak üzere özetlenebilmektedir.

## 2. GENEL BİLGİLER

### 2.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninden esinlenilerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır (Elmas, 2003).

Yapay sinir ağları, insan beyninin fonksiyonel özelliklerine benzer şekilde, (i) öğrenme, (ii) ilişkilendirme, (iii) sınıflandırma, (iv) genelleme, (v) özellik belirleme ve (vi) optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır (Öztemel, 2003). Yapay sinir ağları, örneklerden elde edilen bilgiler ile kendi deneyimlerini oluşturmakta ve benzer konularda benzer kararları vermektedirler. Ayrıca, bilgi sınıflama ve bilgi yorumlamasının da içinde bulunduğu çok değişik problemlerin çözümünde kullanılmaktadırlar.

Yapay sinir ağlarının, doğrusal olmayan, çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin olması ve problemin çözümü için özellikle bir matematik modelin ve algoritmanın bulunmaması hallerinde yaygın olarak kullanıldıkları görülmektedir. Genel olarak, YSA uygulamaları şu fonksiyonları yerine getirmektedir (Öztemel, 2003).


- ↳ fonksiyon kestirimleri
- ↳ doğrusal olmayan sistem modelleme
- ↳ optimizasyon
- ↳ sınıflandırma
- ↳ ilişkilendirme veya örüntü eşleştirme
- ↳ zaman serileri analizleri
- ↳ görüntü tanıma
- ↳ doğrusal olmayan sinyal işleme

### 2.1.1. Yapay sinir ağlarının yapısı ve temel elemanları

Yapay sinir ağları daha önce de değinildiği gibi biyolojik sinir sistemi ve sinir hücresinden esinlenilerek geliştirilmiştir. Bu noktada, YSA'nın yapısı ve bileşenleri hakkında daha fazla bilgi vermeden önce biyolojik sinir sistemi ile ilgili bilgi verilmesi, aradaki benzerliklerin daha net bir şekilde anlaşılması açısından faydalı olacaktır.

#### 2.1.1.1. Biyolojik sinir sistemi ve sinir hücresi

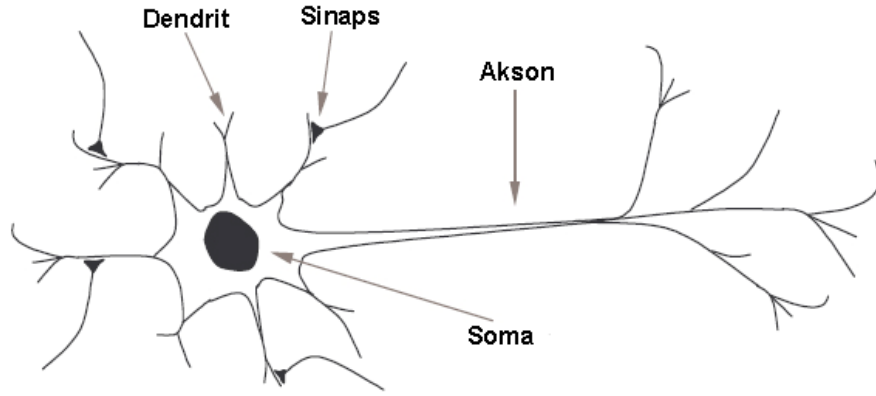
Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir sistemi) bulunduğu üç katmanlı bir sistem olarak açıklanmaktadır (Şekil 2.1). Alıcı sinirler algıladıkları uyarıları, beyine bilgi ileten elektriksel sinyallere dönüştürmekte, tepki sinirleri ise, beyinin ürettiği elektriksel darbeleri bu uyarılara cevap olacak şekilde uygun tepkilere dönüştürmektedir. Merkezi sinir sisteminde, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilmekte ve bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin özelliklerini taşımaktadır.



Şekil 2.1. Biyolojik sinir sisteminin blok gösterimi

Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron). Sinir hücresi; hücre gövdesi (soma), dendritler ve aksonlar olmak üzere üç bileşenden meydana

gelmektedir. Dendritler, diğ er hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletmektedir. Aksonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşımakta ve aksonların bitimi, ince yollara ayrılmakta ve bu yollar, diğ er hücreler için dendritleri oluşturmaktadır. Bunlara ek olarak, akson-dendrit bağlantı bölgesi sinaps olarak adlandırılmaktadır. Biyolojik sinir hücresi ve bileşenleri, Şekil 2.2’de verilmektedir.



Şekil 2.2. Biyolojik sinir hücresi ve bileşenleri


Sinapsa gelen ve dendritler tarafından alınan bilgiler genellikle elektriksel darbelerdir ve sinapsdaki kimyasal ileticilerden etkilenmektedir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değeri ulaştığında hücre bir tepki üretmekte, hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak adlandırılmaktadır

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğ u göz önüne alındığında, sinir sisteminin son derece karmaşık ve etkin bir yapıya sahip olduğ u görülmektedir. Diğ er taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyu sal bilgileri son derecede hızlı değ erlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleşt irme, uyarılma ve genelleşt irme yeteneğ i nedeniyle son derece karmaşık,

doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir (Haykin, 1994).

### 2.1.1.2. Yapay sinir ağı hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücrelerine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli aşağıdaki şekilde görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişim etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlineer) bir fonksiyondur. Şekilde görülen  $b$  bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir (Haykin, 1999; Öztemel, 2003; Baş, 2005).



Şekil 2.3 Temel yapay sinir ağı hücresi.

Nöron çıkışı Eşitlik 2.1 ile ifade edilmektedir.

$$o = f(W.X + b) \quad (2.1)$$

Burada; W ağırlıklar matrisi, X ise girişler matrisidir. n giriş sayısı olmak üzere;

$$W = w_1, w_2, w_3, \dots, w_n \quad (2.2)$$

$$X = x_1, x_2, x_3, \dots, x_n \quad (2.3)$$

Şeklinde yazılabilir. Formülize edersek;


$$net = \sum_{i=1}^n w_i x_i + b \text{ ve } o = f(net) \quad (2.4)$$

$$o = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2.5)$$


şeklinde de yazılabilir.

Eşitlik 2.5'de f, aktivasyon fonksiyonunu ifade etmektedir. Aktivasyon fonksiyonu, hücreye gelen net girdiği işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Genelde nonlineer olan aktivasyon fonksiyonunun çeşitli tipleri vardır (Şekil 5.4).


a)



b)



c)



Şekil 2.4. Aktivasyon fonksiyonu örnekleri a) eşik değer fonksiyonu, b) doğrusal fonksiyon, c) sigmoid fonksiyonu.

Eşik değer fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değerini vermektedir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir ve  $f(x)=x$  şeklinde ifade edilmektedir. Sürekli

çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir. Sigmoid transfer fonksiyonu ise Eşitlik 2.6 ile ifade edilmektedir.

$$f(x) = \frac{1}{1 + \exp(-\beta x)} \quad (2.6)$$


Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir böylece daha sonraki bölümlerde görülecek olan geri yayınlı ağlarda kullanmak mümkün olabilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir (Eşitlik 2.7).

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.7)$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir.

### **2.1.2. Yapay sinir ağ yapıları**

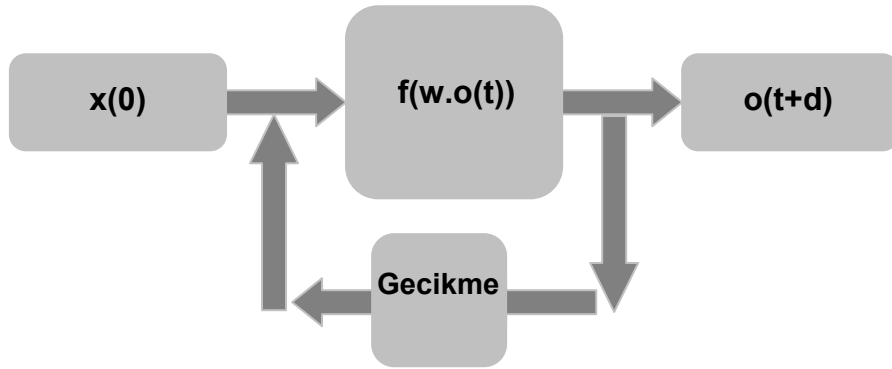
En basit ve en genel yapay sinir ağları tek yönlü sinyal akışını kullanırlar. Yapay sinir ağı yapıları temel olarak iki grupta toplanmaktadır. İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları. İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenir.



Şekil 2.5. İleri beslemeli yapay sinir ağı

Geri beslemeli yapay sinir ağlarında (Şekil 2.6) ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli nöral ağ, çıkışlar girişlere bağlanarak ileri beslemeli bir ağdan elde edilir. Ağın  $t$  anındaki çıkışı  $o(t)$  ise,  $t + d$  anındaki çıkışı ise  $o(t+d)$ 'dir. Buradaki  $d$  sabiti sembolik anlamda gecikme süresidir. İleri beslemeli yapay sinir ağları notasyonu kullanılarak  $o(t+d)$  Eşitlik 2.8'de olduğu gibi ifade edilmiştir. Dikkat edilmesi gereken nokta başlangıç anında  $x(t)$ 'ye ihtiyaç duyulmasıdır. Başlangıç anında  $o(0) = x(0)$ 'dir.

$$o(t+d) = f [w.o(t)] \quad (2.8)$$



Şekil 2.6. Geri beslemeli yapı

### 2.1.3. Yapay sinir ağlarının eğitilmesi

İnsan beyni doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. Yaşadıkça beyin gelişir ve deneyim kazanmakta ve artık olaylar karşısında nasıl



tepki göstereceğini çoğu zaman bilmektedir. Fakat hiç karşılaşmadığı bir olay karşısında yine tecrübesiz kalabilmektedir. Yapay sinir ağlarının öğrenme sürecinde de, merkezi sinir sisteminde uyarılara karşı tepkilerin oluşturulmasına benzer şekilde, alınan girişler aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Ağ tarafından elde edilen çıkış, tecrübe ile elde edilen diğer bir deyişle gerçek çıkışla karşılaştırılarak her bir çıkış için hata değeri hesaplanmaktadır. Çeşitli öğrenme algoritmalarının kullanılması ile hata azaltılıp gerçek çıkış ile uyumu en yüksek çıkış değerinin elde edilmesi amaçlanmaktadır. Bu amaçla, sistem içerisinde ağırlık her bir çevrimde yenilenerek hata azaltılmaya çalışılmaktadır. Eğer yapay sinir ağı verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir. Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilip, sinir ağı çıkışıyla gerçek çıkışı yaklaşımları incelenir. Eğer yeni verilen örneklere de doğru yaklaşıyorsa sinir ağı öğrenmiş demektir.

#### **2.1.4. Yapay sinir ağlarının tasarımı**

Yapay sinir ağının geliştirilmesi sürecinde ağın yapısına ve işleyişine ilişkin şu kararların verilmesi gerekir.

- Ağ mimarisinin seçilmesi ve yapı özelliklerinin belirlenmesi (katman sayısı, katmandaki nöron sayısı gibi)
- Nörondaki fonksiyonların karakteristik özelliklerinin belirlenmesi,
- Öğrenme algoritmasının seçilmesi ve parametrelerinin belirlenmesi,
- Eğitim ve test verisinin oluşturulması

Uygun parametrelerle tasarlanan bir ağ sürekli olarak kararlı ve istikrarlı sonuçlar üretecektir. Kullanılacak ağa ait tüm parametrelerin belirlenmesi bir anda tek bir

parametrenin deęiştirilmesi ile gerçekleştirilmekte, bu da oldukça fazla zaman ve emek harcanmasına neden olmaktadır. Ayrıca, bu işlemlerin sistematik bir şekilde yapılması ve her aşamada aęın etkin bir şekilde eğitilip eğitilmedięi gerçek veriler ile aędan elde edilen verilerin birbirleriyle kıyaslanması ile kontrol edilmelidir. Eğitim ve test verileri sabit tutulsa bile dięer parametrelerin fazlalığı göz önüne alındığında iyi eğitilmiş bir aęın elde edilmesi oldukça zaman ve emek yoğunluklu olmaktadır. Sonuç olarak, bu tez kapsamında yüksek doğrulukta tahmin kapasitesine sahip yapay sinir aęının maksimum sayıda aęın denenmesiyle mümkün olabileceęi düşünülerek bu aşamada kullanılabilir bir yazılımın geliştirilmesi ve farklı veri grupları kullanılarak test edilmesi amaçlanmıştır.

### **3. DENEYSEL ÇALIŞMALAR**

Çalışma kapsamında yapay sinir ağlarının eğitim sürecinde etkili olan parametrelerin optimizasyonuna yönelik bir algoritma geliştirilmiş, MATLAB programında kodun yazılmış ve gıda alanında gerçekleştirilen deneysel çalışmalar sonucu elde edilen veriler kullanılarak test edilmiştir. Gerçekleştirilen aşamalar aşağıda anlatılmıştır.

#### **3.1. Yapay Sinir Ağının Oluşturulması**

Çalışma kapsamında gıda alanında yoğunlukla kullanılan ileri beslemeli yapay sinir ağı tez çalışmasında kullanılmış ağ tasarımında önemli olan aktarım fonksiyonu, eğitim algoritması, iterasyon sayısı ve gizli katmandaki nöron sayısı incelenmiştir. İncelenen parametre özellikleri aşağıda verilmiştir.

##### **3.1.1. Aktarım fonksiyonu**

Yapay sinir ağlarının oluşturulmasında üç farklı (tansig, logsig ve purelin) aktivasyon fonksiyonu kullanılmıştır. Bu fonksiyonlar kullanılarak dış ortamdan gelen girdiler ağırlık ve bias değerleri ile etkileştirildikten sonra bir sonraki katmana bu fonksiyonlarla işlendikten sonra gönderilmiştir. Veri grubunun kaynağına bağlı olarak eğitim sürecinde aktarım fonksiyonunun etkili olduğu bilinmektedir. Ağ oluşturulurken bu fonksiyonların tüm kombinasyonları denenerek en uygun aktarım fonksiyonu kombinasyonu saptanmaya çalışılmıştır.

##### **3.1.2. Eğitim fonksiyonu**

Eğitim algoritması eğitim başarısını belirleyen en önemli kriterlerden bir tanesidir. Bu nedenle çalışma kapsamında 12 farklı eğitim algoritması denenmiştir. Çizelge 3.1.'de kullanılan eğitim algoritmaları verilmiştir.

Çizelge 3.1. Tez kapsamında kullanılan eğitim algoritmaları

No#	Eğitim Algoritması Adı	Eğitim Algoritması Kısaltması
1	Basit gradiyent düşürücü algoritması	traingd
2	Gradyent düşürücü algoritması	traingdm
3	Adaptif Öğrenme Oranı algoritması	traingdx
4	Geri yayılmacı algoritması	trainrp
5	Fletcher-Reeves Konjuge gradyent algoritması	traincgf
6	Polak Ribieri Konjuge gradyent algoritması	traincgb
7	Konjige- gradyent algoritması	trainscg
8	Guasi-Newton algoritması	trainbfg
9	Tek basamaklı sekans algoritması	trainoss
10	Levenberg – Marguard algoritması	trainlm
11	Bayesian algoritması	trainbr
12	Powel Beal giradiyen algoritması	traincgp

### 3.1.3. Gizli katman Nöron Sayısı

Yapay sinir ağlarında girdi katmanı ve çıktı katmanı harici ağ öğrenme sürecini iyileştirmek amacıyla girdi ve çıktı katmanları arasında gizli katman yerleştirilmektedir. Gizli katman sayısı ve her bir gizli katmanda yer alan nöronların sayıları da kurulan ağın eğitilip eğitilmemesinde önemli rol oynamaktadır. Genel olarak gizli katman sayısının ve neron sayısının artması ağ performansını olumlu yönde etkilemesi beklenmektedir. Fakat belirtilen parametrelerin arttırılması ile her zaman başarı elde edilememektedir. Dolayısıyla bu parametrelerinde optimizasyonu gerekmektedir. Çalışma kapsamında gizli katman yokken ve gizli

katman sayının bir olması durumunda nöron sayısı 1-10 arasında değiştirilerek ağ performansının ne yönde değişeceği incelenmiştir.


#### **3.1.4. Eğitim süreci iterasyon sayısı**

Yapay sinir ağlarının eğitim sürecinde iki önemli kavram yer almaktadır. Bunlardan birincisi ağın eğitilmesi ve diğeri ise ağın ezberlemesidir. Bir çocuğun eğitilmesi gibi sisteme yetersiz veri verilmesi durumunda sistem eğitilememekte ve tahmin etmesi istendiğinde doğru tahmin edememektedir. Böyle bir durumda sisteme daha fazla veri sağlanarak sistemin eğitim süreci iyileştirilebilir. Gereğinden fazla veri yüklenmesi veya aynı (birbirine yakın) veri gruplarının sisteme tekrar tekrar yüklenmesi sistemin ezberlemesine neden olmaktadır. Sistemin ezberlemesi durumunda sistem eğitim sürecinde kullanılan girdi değerleri verilmesi ve çıktıların tahmin edilmesi istendiğinde doğru tahmin etmekte fakat eğitim sürecinde hiç karşılaşmadığı veri grubu girdi olarak yüklenmesinde çok farklı çıktı değerleri tahmin edilebilmektedir. Yapay sinir ağının ezberleme durumunu eğitim sürecinde gerçekleştirilen iterasyon sayısının çok yükseltilmesi durumunda da karşılaşılabilmektedir. Aynı veri grubu ile düşük iterasyon değerlerinde sistem daha iyi eğitilebilirken iterasyon sayısının artırılmasıyla ezberlemeye başlayabilmektedir. Bu nedenden dolayı eğitim sürecinde gerçekleştirilen iterasyon sayısı optimize edilmelidir. Çalışma kapsamında iterasyon sayısı 100 ile 1000 arasında denerek optimize edilmiştir.

#### **3.2. Optimizasyon Algoritmasının Oluşturulması ve Matlab Kodunun Yazılması**

Ağ parametrelerinin ve bu parametrelerin kombinasyonlarının çok fazla olmaları nedeniyle eğitim sürecinde denenmesi gereken çok sayıda ağ oluşmaktadır.

Çalışma kapsamında incelenen her bir iterasyon için toplam 930 farklı ağ oluşmaktadır. 930 farklı ağın her hangi bir bilgisayar kodu çalıştırılmaksızın teker teker denenmesi mümkün olmayacağı düşünüldüğü için tüm parametrelerin incelendiği bir algoritma hazırlanmış ve Matlab programı kullanılarak kodlanmıştır. Şekil 3.1’de hazırlanan bilgisayar algoritması ve EK 1 de bilgisayar kodu verilmiştir.



Şekil 3.1 Ağ optimizasyonu için kullanılan bilgisayar algoritması.

### 3.3. Veri Setleri ve Verilerin Elde Edilmesi

Yapay sinir ağı uygulamalarında her veri grubu için aynı eğitim parametreleri uygulanmamaktadır. Bir veri grubu için kullanılan ve yüksek başarı elde edilen ağ eğitim parametreleri farklı bir veri grubunda kullanılması durumunda iyi sonuç

alınmamaktadır. Bu nedenle çalışma kapsamında geliştirilen algoritma üç farklı veri grubu kullanılarak test edilmiştir. Her bir veri grubu için eğitim süreci tekrarlanmış yüksek başarıya sahip eğitilmiş ağ üretilmiştir. Veri grupları seçilirken lineer davranış göstermeyen dolayısıyla basit bir eşitlikle ifade edilemeyen nitelikte olmasına dikkat edilmiştir. Birinci veri grubu  $y = e^x$  eşitliği kullanılarak yapay olarak üretilmiştir. Üssel ifade pek çok biyokimyasal proseste karşılaşılabildiği için ilk aşamada kullanılmıştır. İkinci ve üçüncü veri grupları ise deneysel olarak amiloglukozidaz enziminin reaksiyonu takip edilerek elde edilmiştir. Veri grupları, eğitim, validasyon ve test verileri olarak üç parçaya ayrılmış ve yapay sinir ağlarının eğitilmesi ve test edilmesinde kullanılmıştır. Eğitim sürecinde validasyon verileri kullanılarak ön durdurma yöntemine göre eğitim gerçekleştirilmiştir.


### 3.3.1 $e^x$ veri grubu

Pek çok biyolojik proses üssel eşitlik ( $e^x$ ) ile tanımlanmaktadır. Mikroorganizmaların besiyeri içerisindeki çoğalması, virüslerin yayılması üssel eşitliklerle ifade edilen biyolojik proseslere örnek olarak verilebilir. Biyolojik proseslere ilave olarak bazı mühendislik problemlerinde de (örneğin Newton'un soğuma kanunu;  $T = A + De^{-kt}$ , T: sıcaklık, t: zaman, A, D ve k katsayı) üssel eşitlikleri içeren denklemler kullanılmaktadır. Tez kapsamında kullanılmak üzere veri grubu "x" değerlerinin 0-5.9 aralığında 0.1 artırılarak üretilmiştir. Veri grubunun % 50'si eğitim, % 25'i validasyon ve % 25'i test veri grubu olarak rasgele ayrılmıştır.

### 3.3.2 Kinetik veri grubu-I

Kinetik veri grubu üretilmesinde kullanılan kimyasallar: Maltoz, glukoz, amiloglukozidaz (*Rhizopus sp.*, E.C. 3.2.1.3), H<sub>2</sub>SO<sub>4</sub> ve 4-aminoantipirin Sigma (A.B.D.), glukoz oksidaz (*Aspergillus niger* E.C..1.1.3.4) ve peroksidaz enzimleri (horseradish, E.C. 1.11.1.7) Biozyme Laboratories Lim. (İngiltere) ve fenol J.T. Baker (Hollanda).

Başlangıç reaksiyon hızının saptanması pek çok araştırmancının konusu olmuştur. Bu çalışma kapsamında reaksiyon parametrelerinden substrat derişimi ve ortam pH'sının enzimatik reaksiyon hızına etkisinin incelenmesi ve her hangi bir reaksiyon ortamında reaksiyon hızının yapay sinir ağı kullanılarak doğru bir şekilde tahmin edilmesi hedeflenmiştir. Bu amaçla amiloglukozidaz enziminin maltoz ile verdiği reaksiyon model reaksiyon olarak seçilmiş ve belirlenen reaksiyon parametrelerinde reaksiyon gerçekleştirilerek enzimatik reaksiyon hızı saptanmıştır. İzlenen enzimatik reaksiyon aşağıda verilmiştir.



Enzimatik reaksiyon, 10 ml reaksiyon hacminde gerçekleştirilmiş ve ortam pH'sı fosfat tamponu ve substrat derişimi stok maltoz çözeltisi (100 mM) kullanılarak istenen değerlere ayarlanmıştır. Ortamdaki enzim derişimi 2 mg/ml olacak şekilde enzim ilave edilerek reaksiyon başlatılmıştır. Reaksiyon, sıcaklığı 37°C'ye ayarlanmış çalkalamalı su banyosunda (Stuart Scientific Model: SBS30, Staffordshire, İngiltere) gerçekleştirilmiştir. Maltoz hidrolizi, reaksiyon sonucunda oluşan glukoz miktarının ölçülmesi ile takip edilmiştir. Bunun için, belirli zaman aralıklarında ortamdaki 0.5 ml örnek alınıp, reaksiyonu durdurmak için örneğin üzerine 20 µl 0.4 N H<sub>2</sub>SO<sub>4</sub> ilave edilmiştir. Glukoz derişimi ise Glukoz Analiz Kiti (Biosis Ltd Şti, Ankara) kullanılarak ölçülmüştür. Zaman karşılık glukoz derişimleri



ölçülerek enzimatik reaksiyon hızı  $\mu\text{mol}$  maltoz/dk mg enzim olarak saptanmıştır. Beş farklı reaksiyon pH'sı (2.7, 3.2, 4.5, 5.8 ve 6.3) ve beş farklı substrat derişimi (1.0, 2.9, 5.2, 7.5, 9.8, 12.1 ve 14 mM) olmak üzere toplam 35 noktada deney yapılmış ve enzimatik reaksiyon hızları saptanmıştır. Otuz beş verinin 13 tanesi yapay sinir ağının eğitiminde diğer 18 veri ise eşit oranlarda validasyon ve eğitilmiş ağın test edilmesinde kullanılmıştır.

### **3.3.3 Kinetik veri grubu-II**

İkinci kinetik veri grubu farklı substrat ve ürün derişimlerinde enzimatik reaksiyon hızının tahmin edilmesi ve sonrasında tahmin edilen hız değerleri kullanılarak enzimatik reaksiyon süreci için zaman substrat derişimi grafiğinin elde edilmesidir. Bu amaçla 15 farklı başlangıç maltoz (2-16 mM) ve glukoz (0-10 mM) derişiminde maltozun amiloglukozidaz enzimi ile parçalanması takip edilmiş ve reaksiyon sürecinde zaman-derişim grafikleri elde edilmiştir. Bu grafikleri kullanılarak farklı maltoz ve glukoz derişimlerine için reaksiyon hız değerleri türetilmiştir. Toplam 15 farklı zaman-derişim grafiği içinde yer alan toplam 150 farklı maltoz ve glukoz derişimi için hız değeri saptanmış. Veri grubu 75'i eğitim, 35'i validasyon ve 40'ı test amacıyla elde edilmiştir.

Kinetik çalışmalarda substrat ve/veya ürün derişimini enzimatik reaksiyon hızına ilişkilendiren eşitlikler türetilmekte ve bu eşitlikler farklı mühendislik uygulamalarında kullanılmaktadır. Yapay sinir ağlarının en belirgin dezavantajı her hangi bir model eşitlik oluşturmamasıdır. Bu dezavantajı kısmen ortadan kaldırmak amacıyla eğitilmiş yapay sinir ağı kinetik eşitlik yerine mühendislik problemlerinde kullanılabilirliği araştırılmış ve zaman derişim grafiği geliştirilen yazılım kullanılarak

türetilmiştir. Türetilen derişim-zaman grafiđi deneysel zaman-derişim grafiđi ile karşılaştırılmıştır.

Eđitilmiş ađ kullanılarak belirli maltoz ve glukoz derişimlerinde enzimatik reaksiyon hızının tahmin edildikten sonra enzimatik reaksiyon hızı kesikli reaktör için yazılan eşitliđin sayısal olarak çözümlenmesinde kullanılmıştır. Kesikli reaktörün modelleme aşaması aşağıda verilmiştir.

$$r = -\frac{dS}{dt} \quad (3.2)$$

r: reaksiyon hızı

$dS/dt$  türev ifadesi Eş. 3.3'de gösterildiđi gibi yazılabilir.

$$\frac{dS}{dt} = \frac{S_i - S_{i+1}}{\Delta t} \quad (3.3)$$

Aynı ifade merkezi farklar yaklaşımı kullanılarak Eş.3.4'de olduđu gibi yazılabilir.

$$\frac{dS}{dt} = \frac{S_{i-1} - S_{i+1}}{2\Delta t} \quad (3.4)$$

Başlangıç anında ( $t=0$ )  $S_{i=1}=S_0$ ,  $P_{i=1}=P_0$  ve  $\Delta t=0.1$  olmak üzere  $r_i$  deđeri tahmin edilmiş ve Eş. 3.5 ve Eş. 3.6 kullanılarak  $S_{i=2}$  ve  $P_{i=2}$  deđerleri hesaplanmıştır.

$$S_{i=2} = S_{i=1} - r_{i=1} \times \Delta t \quad (3.5)$$

$$P_{i=2} = P_{i=1} + 2 \times r_{i=1} \times \Delta t \quad (3.6)$$

Hesaplanan maltoz ve glukoz derişimleri eđitilmiş ađa verilerek tekrar reaksiyon hız deđerleri tahmin edilmiştir.  $i>1$  deđerleri için merkezi farklar yaklaşımını temel alan eşitlikler (Eş. 3.7 ve Eş. 3.8) kullanılarak  $S_i$  ve  $P_i$  deđerleri hesaplanmıştır.

$$S_{i=i+1} = S_{i=i-1} - 2 \times r_{i=i} \times \Delta t \quad (3.7)$$

$$P_{i=i+1} = P_{i=i-1} + 4 \times r_{i=i} \times \Delta t \quad (3.8)$$

Hesaplamalar sonlu reaksiyon süresince tekrarlanarak zaman karşılık substrat ve ürün derişimleri hesaplanmış ve grafikleri çizilmiştir. Hesaplanan zaman-derişim

grafiği gerçek zaman derişim grafiği ile karşılaştırılarak sistemin başarısı incelenmiştir.

#### **3.3.4 Absorbans-L\*a\*b\* veri grubu**

Renk önemli bir kalite kriteri olmakla birlikte özellikle gıdaların tüketilebilirliği, kalitesi, olgunluğu v.b. özellikler hakkında tüketiciye bilgi vermesi nedeniyle gıdalar için büyük bir önem arz etmektedir. Renk ölçümü için özel olarak tasarlanmış renk ölçüm sistemleri kullanılmaktadır. Renk ölçüm sistemlerinin pahalı olması nedeniyle yaygın olarak kullanılamamaktadır. Ayrıca pek çok renk ölçüm sistemi sıvı örneklerde başarısız olabilmektedir. Başarısızlıklarının en önemli nedeni uygun örnekleme sisteminin olmaması ve arka plan renklerin saydam sıvı örnek renkleriyle karıştırılmasıdır. Bilindiği gibi renk ışığın bazı dalga boylarının obje tarafından absorplanması bazılarının ise yansıtılması ve yansıyan dalga boylarının karışımı olarak oluşmaktadır. Renk ölçüm sistemleri yansıyan dalga boylarının saptanmasıyla gerçekleşmektedir. Saydam ve homojen örneklerde absorplanan ışın dalga boylarını ve absorplanma şiddetinin pek çok laboratuarda yaygın olarak kullanılan görünür spektrofotometre ile saptamak mümkündür.

Sıvı yağda renk önemli bir kriter olmakla birlikte kızartma yağlarında yağın kullanılabilirliğinin bir ölçüsüdür. Ayçiçeği ve benzeri yağlarda açık sarı renk tercih edilirken zeytin ve susam benzeri yağlarda yağların karakteristik renkleri istenmektedir. Çalışma kapsamında sekiz rafine yağ (ayçiçeği, zeytin, fındık, kanola, susam, pamuk, mısır, soya yağları) ve bunların karışımlarından oluşan toplam 100 farklı renk değerine sahip yağ karışımları hazırlanmıştır. Karışımların renk değerleri Minolta Spektrofotometre CM-3600d (Minolta Camera Co., Japonya) kullanılarak L\*a\*b  $\Delta E$  formatında saptanmıştır. Spektrofotometre siyah ve

beyaz kalibrasyon blokları kullanılarak kalibre edilmiş ve sonrasında beyaz blok kullanılarak sıfır okuması gerçekleştirilmiştir. Renk ölçümleri 10 mm ışık yoluna ve 13 mL örnek hacmine sahip çözücü dirençli küvetler içerisinde gerçekleştirilmiştir. Her örneklemeden önce küvetler HPLC saflığında hekzan kullanılarak temizlenmiştir. Her bir yağ iki defa ölçülerek ortalaması çalışmada kullanılmıştır. Spektrofotometrede  $L^*$ ,  $a^*$  ve  $b^*$  değerleri okunmuş ve  $\Delta E$  değeri Eş.3.9 kullanılarak bu değerler üzerinden hesaplanmıştır.

$$\Delta E = \sqrt{(L^* - L^*_{sifir})^2 + (a^* - a^*_{sifir})^2 + (b^* - b^*_{sifir})^2} \quad (3.9)$$

Yağların absorbans değerleri Agilent 8453 UV-Visible Spektrofotometre (Agilent Technologies, Palo Alto, CA, ABD) kullanılarak ölçülmüştür. Yağ örneklerinin absorbans ölçümleri 3 mL'lik tek kullanımlı polistren (Işık yolu: 10 mm) küvetler içerisinde gerçekleştirilmiştir. Spektrofotometrenin sıfır ayarı saf su kullanılarak yapıldıktan sonra her bir örnek 380–700 nm dalga boyu aralığında spektrumları elde edilmiştir. Her bir örnek için paralel ölçüm gerçekleştirilmiştir.

### 3.3.5 RGB- $L^*a^*b^*$ veri grubu

CIE  $L^*a^*b^*$ , XYZ ve RGB formatları genel olarak kabul gören renk formatları olmakla birlikte uygulamalara göre farklı formatlar tercih edilebilmektedirler. CIE  $L^*a^*b^*$  renk formatı genel olarak endüstriyel üretim sürecinde tercih edilen renk formatı olmakla birlikte gıda endüstrisinde de kullanılmaktadır. Örneklerin CIE  $L^*a^*b^*$  renk değerleri özel renk ölçüm cihazları ile yapılmakta olup bu cihazların fiyatları oldukça yüksektir. RGB renk formatı ise genellikle bilgisayar ve bilgisayar destekli dijital ekipmanlarda (fotoğraf makinesi tarayıcı v.b.) kullanılmaktadır. Dijital ofis ekipmanlarının yaygınlaşması nedeniyle bu ekipmanların fiyatları önemli ölçüde azalmış ve bu sayede RGB formatında renk ölçümü kolaylıkla yapılabilir

hale gelmiştir. RGB formatındaki renk değerlerinin CIE  $L^*a^*b^*$  formatında renk değerlerine dönüştürmek için farklı eşitlikler geliştirilmiş olmasına rağmen bu çevrimin başarısı sınırlıdır.

Bu aşamada RGB formatındaki renk değerlerinin CIE  $L^*a^*b^*$  formatına dönüştürme amacıyla yapay sinir ağları kullanılmıştır. Çalışma kapsamında 456 farklı renge sahip renk kartelasından (Amerikan Federal Renk Standardı (Federal Standard 595a, 1984) elde edilen ve gerçek gıda örneğine ait renk değerleri kullanılmıştır. Kartela ve gerçek gıda örnekleri spektrofotometre (Minolta CM3600d, Minolta Camera Co, Japonya) kullanılarak ölçülmüştür. Aynı örneklerin dijital görüntüleri tarayıcı (HP 3890, Çin Halk Cumhuriyeti) kullanılarak alınmış ve bilgisayar ortamında Matlab programı kullanılarak renk değerleri (RGB formatında) saptanmıştır. İki farklı renk formatında ölçülen renk verileri yapay sinir ağının eğitilmesinde, validasyonunda ve test edilmesinde kullanılmıştır. Ayrıca gerçek gıda örneklerin renk değerleri her iki formatta saptanmış, RGB değerleri eğitilmiş ağa beslenerek çıktı olarak CIE  $L^*a^*b^*$  renk değerleri üretilmiştir. Üretilen renk değerleri gerçek renk değerleri ile karşılaştırılarak sistemin başarısı incelenmiştir.

Bu aşamada geliştirilen MATLAB yazılımı MATLAB grafiksel kullanıcı ara yüzeyi ile birleştirilerek kullanıcının basit ofis ekipmanları ile renk ölçümünü yapabilecekleri bir program haline getirilmiştir.

### **3.4. Ağ Performansının İstatistiksel Olarak Değerlendirilmesi**

Eğitilmiş ağın tahmin ettiği verilerin doğruluğu gerçek değerlerle karşılaştırılacak incelenmiştir. Çalışma kapsamında hata kareler ortalaması (HKO), regresyon katsayısı ( $R^2$ ) ve ortalama mutlak sapma (OMS) değerleri hesaplanmıştır ve

kullanılmıştır. Her üç istatistiksel değerin hesaplanmasında kullanılan matematiksel eşitlikler aşağıda verilmiştir.

$$HKO = \frac{1}{n} \sum_{i=1}^n (x_{i,gerçek} - x_{i,tahmin\ edilen})^2 \quad (3.10)$$

$$OMS = \left\{ \left[ \sum_{i=1}^n \left( |x_{i,gerçek} - x_{i,tahmin\ edilen}| / x_{i,gerçek} \right) \right] / n \right\} \times 100 \quad (3.11)$$

Eq. (2)

$$R^2 = \frac{DKT}{TKT} = 1 - \frac{AKT}{TKT} \quad (3.12)$$

$x_{i,gerçek}$  : Gerçek değer

$x_{i,pre}$  : Tahmin edilen değer

$n$  : Değer sayısı

$DKT$  : Deneme kareler toplamı,

$TKT$  : Toplam kareler toplamı

$AKT$  : Artık kareler toplamı

Genellikle istatistiksel verilerin karşılaştırılmasında tek bir istatistiksel karşılaştırma yöntemi kullanılmasına karşın çalışma kapsamında eğitilmiş ağların performanslarının incelenmesinde her üç istatistiksel değer de kullanılmıştır. Bunun nedeni her bir istatistiksel karşılaştırma yönteminin farklı noktalardaki veri gruplarının uyumunu öne çıkarmasıdır. Hata kareler ortalaması değerinde büyük verilerin uyumu istatistiksel değer üzerinde önem arz ederken küçük değerlerin uyumsuzluğu yeterince izlenememektedir. Yapay sinir ağı ile ilgili pek çok çalışmada HKO değeri kullanılarak ağ eğitimi ve performans değerlendirmesi yapılmaktadır. Bu noktada sadece HKO değerinin kullanılmasının bir eksiklik olduğu düşünülmektedir. Ortalama mutlak sapma değeri en gerçekçi istatistiksel karşılaştırma yöntemi olarak değerlendirilmekte ve her bir noktada gerçek ve

tahmin edilen deęerler arasındaki varyasyon OMS deęeri ierinde izlenebilmektedir. Ortalama mutlak sapma deęerinin belirtilen avantajı bazı durumlarda dezavantaj olarak karřımıza ıkabilmektedir. Pek ok tahmin ynteminde olduęu gibi yapay sinir aęlarında kk ve byk veri deęerlerinde aynı doęrulukta tahmin edememektedir. rnek olarak gerek 1 ve 10 olan iki deęer iin sistem 0.1 birimlik sapmalarla tahmin yapması durumunda birinci veri iin % 10'luk, ikinci veride % 1'lik bir hata deęeri ile karřılařılabilmektedir. Dolayısıyla kk deęerlerde aynı miktarda yapılan hata OMS deęerinin nemli lde artmasına neden olmaktadır. Bu durum OMS deęerinin tek bařına kullanımını engellemektedir. Yayęın olarak  $R^2$  deęeri iki veri grubunun karřılařtırılmasında kullanılmaktadır. Pek ok alıřmada gz ardı edilmekle birlikte sadece  $R^2$  deęerinin tek bařına kullanması yanıltıcı olabilmektedir.  $R^2$  deęeri iki veri arasındaki lineer kolerasyonun gstergesi olmakla birlikte lineer eřitlięin eęimi ve kesim noktası da kolerasyonun iyi olup olmadıęına karar verilmesinde nemlidir. Eęim deęerinin 1'e kesim deęerinin ise 0'a yakın olması gerekmektedir. Kolerasyon katsayısı HKO'sında olduęu gibi kk deęerlerdeki hatayı gizlemekte byk deęerlerdeki hatayı ise byterek model eřitlięe ve  $R^2$  deęerine yansıtılmaktadır. alıřma kapsamında gerek deęerler eęitilmiş aęların retmiř olduęu deęerler ile karřılařtırılmış, her  istatistiksel deęer hesaplanmış ve bu deęerlerde en iyi skora sahip olan aę seilmiřtir. Bazı veri setleri iin farklı eęitilmiş aęlar yksek skora sahip olduęu gzlenmiř bu tr durumda veri grubunun zellięine gre en iyi aę seilmiřtir.

#### 4. DENEYSEL SONUÇLAR VE TARTIŞMA

Bir çocuğun eğitim sürecinde takip edilen yöntem eğitimin başarısını belirleyen en önemli etmenlerden bir tanesidir. İyi bir eğitim için farklı yöntemler geliştirilmiş olmakla birlikte yöntemler arasında en iyi henüz ortaya konmamış ve konulamamıştır. Bunun nedeni farklı eğitimler için farklı yöntemlerin kullanılma gerekliliği ve aynı zamanda bireylerin aynı yöntemle eşit düzeyde eğitilememesidir. Yapay sinir ağları da insanların eğitim sürecini taklit eden matematiksel uygulamalar olmaları nedeniyle tek bir ağ yapısı ile mutlak başarıya ulaşamamaktadır. Eğitim sürecinde kullanılacak veri grubuna bağlı olarak farklı ağ tasarımlarının yapılması farklı eğitim parametrelerinin ve algoritmalarının denenmesi gerekmektedir. Bir çocuğun eğitim sürecinde farklı durumlarla karşılaşılabilir. Bunlardan birincisi yetersiz veri grubu ile çocuğun eğitime çalışılmasıdır. Çocuk var olan veriyi öğrenmesine karşın eğitimin başarılı olduğunu söylemek mümkün olmamaktadır. Veri grubu artırılarak eğitimin başarısı artırılabilir. İkinci durum ise yeterli veri grubu varken yanlış eğitim yönteminin takip edilmesi nedeniyle çocuğun öğrenememesidir. Bu durumla sıkça rastlanmakta olup sınıftaki öğrencilerin bir kısmının veya tamamının aynı veri grubuyla eğitilememesidir. Öğrencilere bireysel olarak yaklaşılmasıyla ve farklı eğitim yöntemleriyle eğitimin yüksek başarılarla yapılabilmesidir. Üçüncü durum ise aynı veri grubunun tekrar tekrar eğitim sürecinde kullanılması ile çocuğun veri grubunu ezberlemesi, eğitimin başarı ile yapıldığının düşünülmesi fakat çocuğun eğitim sürecinde kullanılan veri grubu ile ilişkili farklı bir veri grubuyla karşılaştığında çocuğun cevap verememesidir. Bu durum da eğitimcilerin çok karşılaştıkları bir durumdur. Benzer durumlarla YSA'nın eğitim sürecinde de sıkça karşılaşılmaktadır. Yapay sinir ağları da yetersiz veri nedeniyle eğitilememekte



veya çok benzer veri gruplarının eğitim sürecinde çok tekrar edilmesiyle ezberleyebilmektedir. Önceki bölümlerde de ifade edildiği gibi çalışma kapsamında YSA'nın eğitim sürecinde kullanılan eğitim parametrelerinin, algoritmalarının ve ağ mimarilerinin eğitim başarısı üzerine etkileri incelenmiş ve farklı veri grupları için en uygun eğitim parametrelerinin saptanmasında kullanılabilecek bir yazılımın hazırlanmış ve farklı veri grupları için test edilmiştir. Bu bölümde elde edilen sonuçlar değerlendirilmiştir.

#### **4.1. Yapay Sinir Ağlarının Optimizasyonu**

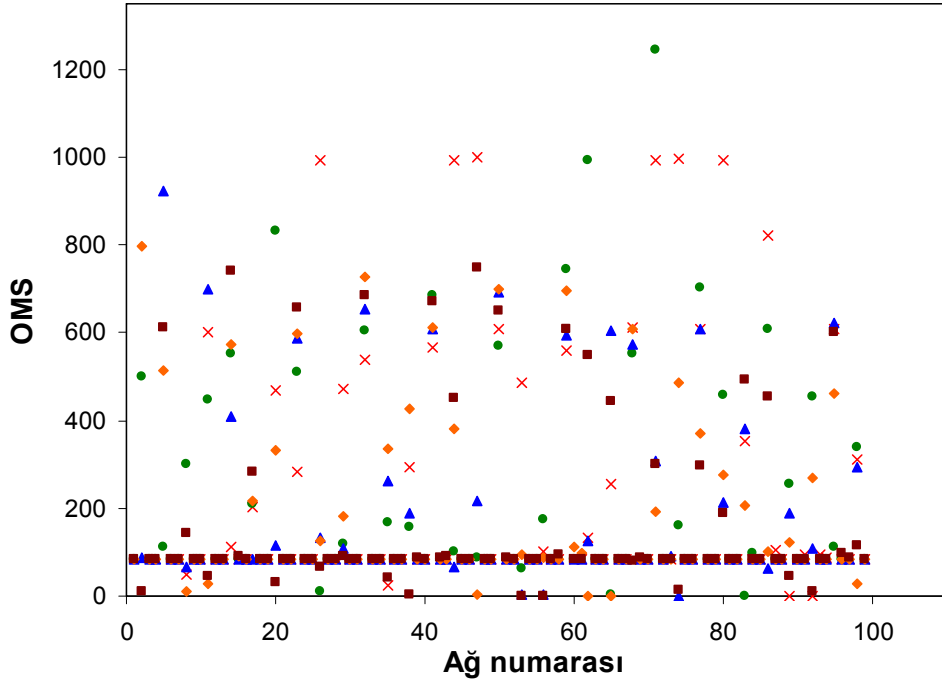
Yapay sinir ağ mimarisinin oluşturulmasında ve eğitim sürecinde etkili olacağı düşünülen aktarım fonksiyonu, eğitim algoritması, iterasyon sayısı ve gizli katmandaki nöron sayısı incelenmiş ve farklı veri gruplarında bu parametrelerin etkinliği saptanmıştır. Çalışma kapsamında geliştirilen algoritma kullanılarak MATLAB programında ağ optimizasyon yazılımı hazırlanmıştır. Hazırlanan yazılım ile her bir veri grubu için tek bir iterasyonda toplam 930 farklı ağ parametrelerinin kombinasyonları hazırlanmış ve her bir ağ eğitim sürecinde kullanılmış ve eğitim sürecinin başarısı gerçek verilerle ağın ürettiği verilerin karşılaştırılması ile incelenmiştir. Bu aşamada hata kareler ortalaması, regresyon katsayısı ve ortalama mutlak sapma değerleri hesaplanmış ve en yüksek başarıya sahip ağın seçilmesinde kullanılmıştır. Aşağıda detaylarıyla anlatıldığı gibi 930 farklı ağ yapısına bağlı olarak eğitilmiş ağlarda çok farklı sonuçlarla karşılaşmıştır. Dokuz yüz otuz ağın büyük bir kısmında istenen başarı sağlanamazken sadece az sayıda ağda başarılı sonuçlar elde edilebilmiştir. Bu durum yazılımın işlevini yeterli bir şekilde yerine getirdiğini incelenen parametreler dahilinde geliştirilen optimizasyon

yazılımının kullanılabilirliğini göstermiştir. Farklı veri grupları ile gerçekleştirilen optimizasyon sonuçları aşağıda detaylı bir şekilde anlatılmıştır.


#### **4.2. $e^x$ Veri Grubu ve Ağ Optimizasyonu**

Üstel eşitlikte “x” değerleri 0-5.9 aralığında 0.1 artırılarak “y” değerleri hesaplanmış, elde edilen veri grubu rasgele üç gruba ayrılmış yapay sinir ağlarının eğitilmesinde, validasyonunda ve test edilmesinde kullanılmıştır. Farklı ağ parametreleri için toplam 930 ağ oluşturulmuş ve eğitim veri grubu kullanılarak eğitilmiştir. Validasyon verileri kullanılarak eğitim süreci sonlandırılmıştır. Test veri grubu kullanılarak eğitilmiş ağlar test edilmiş; gerçek ve tahmin değerler karşılaştırılmış, istatistiksel değerler hesaplanmıştır. İstatistiksel değerlerde oldukça fazla bir dağılım saptanmıştır. Üstel ifade herhangi bir deneysel hata içermemesine ve yapay sinir ağı için kolay bir veri grubu olmasına karşın istatistiksel değerlere bakıldığında eğitilmiş ağların büyük bir çoğunluğunun eğitim sürecini başarı ile tamamlayamadığı 930 eğitilmiş ağ içerisinde sadece 33 tanesinde mutlak ortalama sapma değeri % 10’dan daha düşük olduğu, 33 ağ içerisinde sadece 20 tanesinde is % 1’in altında olduğu saptanmıştır. Ağlar için elde edilen istatistiksel değerler Şekil 4.1-4.3 arasında görülmektedir. Sadece dokuz ağın  $R^2$  değeri 0.99’un üzerinde ve sadece beş ağın üretmiş olduğu veriler ile gerçek veriler arasında hata kareler ortalaması 0.0002’nin altında olduğu saptanmıştır. En düşük HKO ve en yüksek  $R^2$  değeri aynı ağ için sırasıyla 1.000 ve 0.00004 olarak elde edilmiştir. Bu ağın parametreleri; 6 nöron, “trainlm” eğitim fonksiyonu, “logsig” and “purelin” transfer fonksiyonları olarak saptanmıştır. En düşük OMS değeri % 0.004 olarak 10 nöron sayısı, “trainlm” eğitim algoritması ve

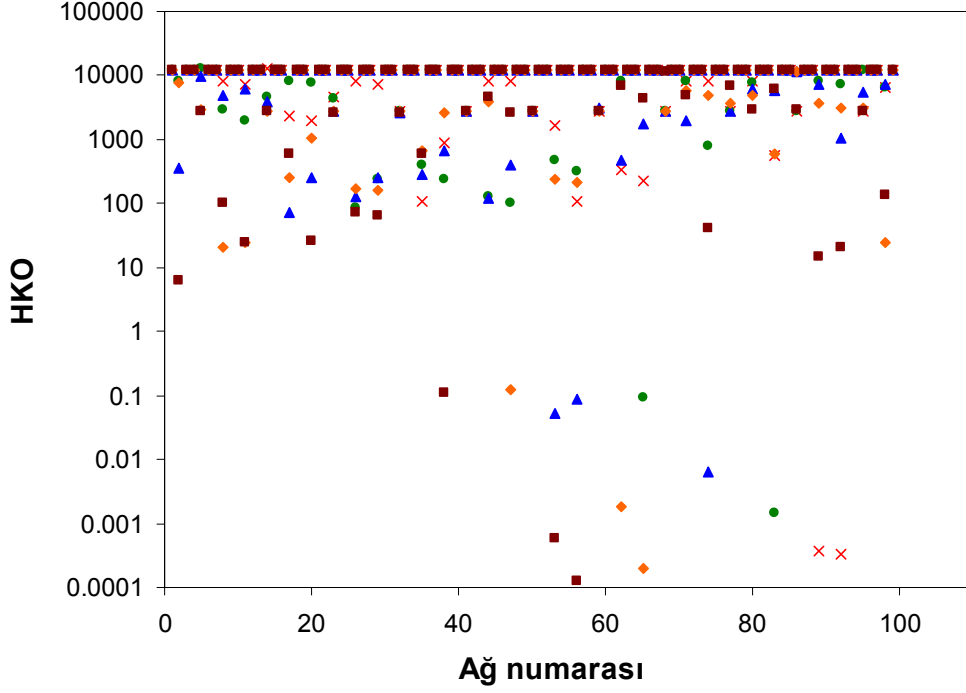
“logsig” ve “purelin” transfer fonksiyonu parametrelerinin kullanıldığı ağda elde edilmiştir.



Şekil 4.1 Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.2 Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların R<sup>2</sup> değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.3 Üstel fonksiyondan elde edilen veriler ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

Her bir istatistiksel değerlendirme için en iyi performans değerlerini veren beş ağ eğitim parametreleri ve bu ağların kullanılmasıyla elde edilen istatistiksel değerler Çizelge 4.1.'de verilmiştir. Çizelgede görüldüğü gibi performans değerlendirmesinde ilk beşe giren ağlar arasında en belirgin farkı OMS değeri vermektedir. Aynı  $R^2$  değerine sahip ağlar için % 0.004 ile % 0.106 OMS değeri elde edilebilmektedir. HKO değerlerine bakıldığında 0.00004 ile 0.00263 değerleri arasında değiştiği görülmektedir. Bu sonuçlara bakılarak iyi eğitilmiş ağın sadece tek bir istatistiksel veriye bakılarak seçilemeyeceği göstermektedir. İdeal durum seçilen ağın her üç istatistiksel değer için en iki skorlara sahip olmasıdır. Fakat ideal duruma her zaman ulaşılamamaktadır. En iyi olarak yukarıda belirtilen iki ağdan hangisinin seçileceğine veri grubu incelenerek karar verilmesi gerekmektedir. Fakat bu aşamada her iki ağında başarısı oldukça yüksek olduğu için her ikisinin de kullanılması mümkündür.

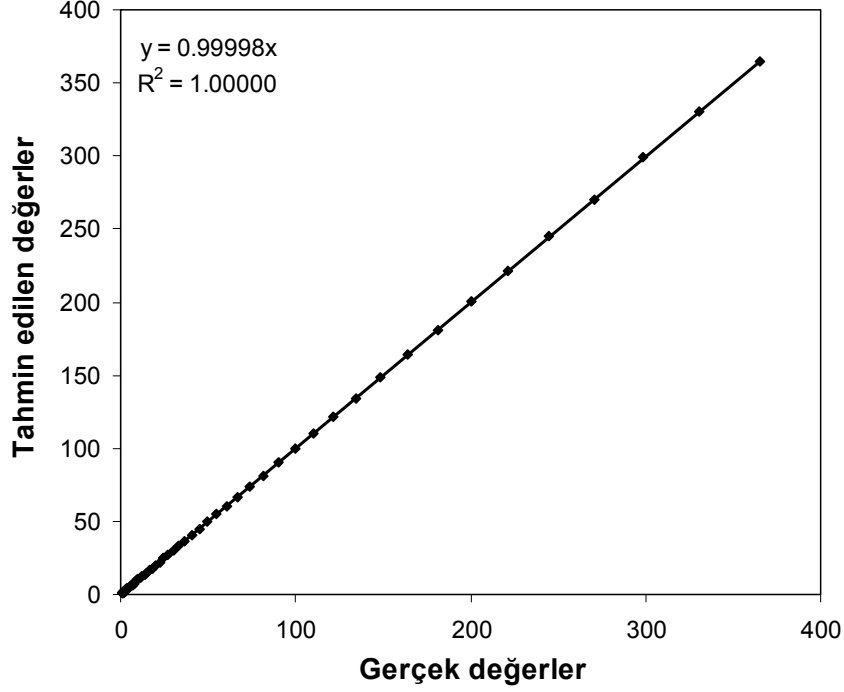
Çizelge 4.1 Üstel fonksiyon veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri

Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	R <sup>2</sup>	HKO	Performans sırası		
		#1	#2				OMS	R <sup>2</sup>	HKO
10	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.004	1.000	0.00263	1		
7	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.004	1.000	0.00072	2		
6	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	0.006	1.000	0.00004	3	1	1
9	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.007	1.000	0.00357	4		
10	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	0.009	1.000	0.00023	5		
5	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.028	1.000	0.00013		3	3
6	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.034	1.000	0.00012		2	2
7	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	0.042	1.000	0.00013		4	4
4	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	0.106	1.000	0.00020		5	5

En iyi ağ kullanılarak test verileri için veri üretmesi sağlanmış ve üretilen veriler geçek değerlerle ile karşılaştırılmıştır (Şekil 4.4). Bu karşılaştırma sonucunda veri grubuna en uygun ağların seçilebildiğini, ve ağların başarılı bir şekilde eğitildiğini göstermektedir. Bu veriler doğrultusunda geliştirilen yazılım etkin bir şekilde çalıştığı söylenebilir.

### 4.3. Kinetik Veri Grubu-I ve Ağ Optimizasyonu


Maltozun enzimatik hidrolizi takip edilerek farklı reaksiyon koşulları için enzimatik reaksiyon hızı saptanmış ve bu veriler kullanılarak YSA'nın eğitimi gerçekleştirilmiştir. Bu aşamada; kinetik verilerle en iyi eğitimi sağlamak ve sonrasında en iyi eğitilmiş ağ ile her hangi bir matematiksel eşitliğe gereksinim olmaksızın farklı ortam pH değerleri ve substrat içerikleri için enzimatik




Şekil 4.4 Eğitilmiş ağın ürettiği değerlerin gerçek değerler ile karşılaştırılması

reaksiyon hızını doğru bir şekilde tahmin etmek amaçlanmıştır.

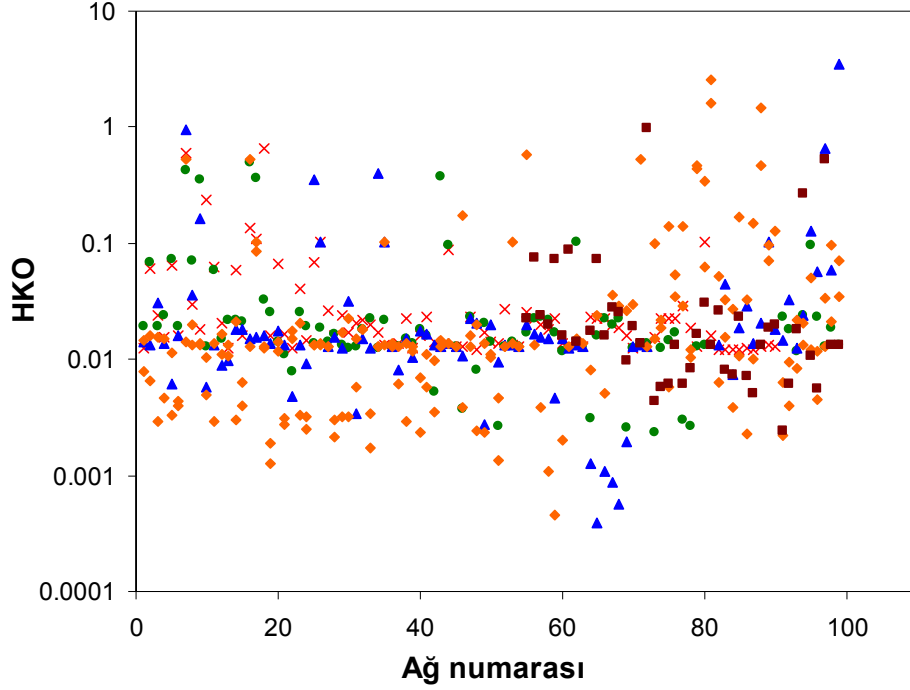
Yapay sinir ağlarının eğitiminde incelen parametrelerle oluşturulan toplam 930 ağ kullanılarak eğitim süreci gerçekleştirilmiş ve gerçek veriler ile eğitilmiş ağların tahmin ettiği veriler kullanılarak HKO,  $R^2$  ve OMS değerleri hesaplanmıştır. Hesaplanan değerlerin bazıları Şekil 4.5-4.7'de görülmektedir. Pek çok ağ için HKO değerleri 0.02,  $R^2$  değerleri 0.4 ve OMS değerleri % 100 civarında olduğu gözlenmiştir. Bu değerler kabul edilebilir düzeyde değildir. Dokuz yüz otuz ağ içerisinde sadece 6 tanesinde % 10'un altında OMS, sadece iki ağ % 7'nin altında OMS değerine sahiptir. Sadece 19 ağın 0.0015 den düşük HKO değerine ve 3 ağın 0.979'nin üzerinde  $R^2$  değerine sahip olduğu saptanmıştır.



Şekil 4.5 Kinetik veri grubu-I ile eğitilmiş ağların OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).



Şekil 4.6 Kinetik veri grubu-I ile eğitilmiş ağların  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



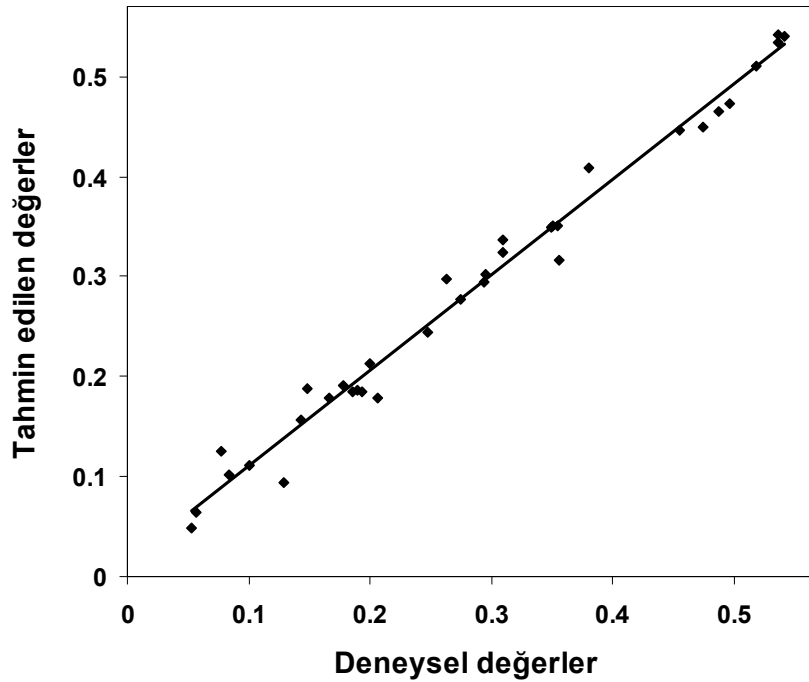
Şekil 4.7 Kinetik veri grubu-I ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

En iyi istatistiksel skora sahip beş ağın parametreleri ve istatistikse değerleri Çizelge 4.2.'de verilmiştir. Çizelge de görüldüğü gibi 8 gizli karman nöron sayısına, logsig, logsig transfer fonksiyonuna sahip ve trainlm eğitim algoritmasıyla eğitilmiş ağ en iyi OMS (% 6.36) ve  $R^2$  (0.984) değerlerine sahiptir. Üç gizli katman nöron sayısına, tansig, logsig transfer fonksiyonuna sahip ve trainlm eğitim algoritmasıyla eğitilmiş ağ en iyi HKO (% 0.0004) değerlerine sahiptir. En iyi olarak belirlenen ağın kullanılması ile test verileri için ağın üretmiş olduğu veriler gerçek değerlerle karşılaştırılmıştır (Şekil 4.8). Bu karşılaştırma sonucunda eğitim sonucu yüksek başarı sağlandığı fakat eğitilmiş ağların üretmiş olduğu veriler ile gerçek veriler arasında azda olsa fark olduğu görülmektedir. Bu durum deneysel verilerin hata içerdiği veya yetersiz veri nedeniyle eğitim başarısının düşük olduğu şeklinde açıklanabilir. Sonuç olarak geliştirilen yazılım hedeflendiği şekilde en uygun eğitim parametrelerinin seçilmesinde etkin bir şekilde kullanılmıştır.



Çizelge 4.2 Kinetik-I veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri


Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	R <sup>2</sup>	HKO	Performans sırası		
		#1	#2				OMS	R <sup>2</sup>	HKO
8	<i>trainlm</i>	<i>logsig</i>	<i>logsig</i>	6.36	0.984	0.0004	1	1	2
4	<i>trainlm</i>	<i>logsig</i>	<i>logsig</i>	6.50	0.980	0.0005	2	3	3
3	<i>trainlm</i>	<i>logsig</i>	<i>logsig</i>	7.26	0.977	0.0006	3	4	4
3	<i>trainlm</i>	<i>tansig</i>	<i>tansig</i>	7.28	0.945	0.0013	4		
3	<i>trainlm</i>	<i>tansig</i>	<i>logsig</i>	8.30	0.984	0.0004	5	2	1
6	<i>trainoss</i>	<i>tansig</i>	<i>logsig</i>	10.76	0.976	0.0006		5	5



Şekil 4.8 Eğitilmiş ağın üretmiş olduğu değerlerin gerçek değerler ile karşılaştırılması

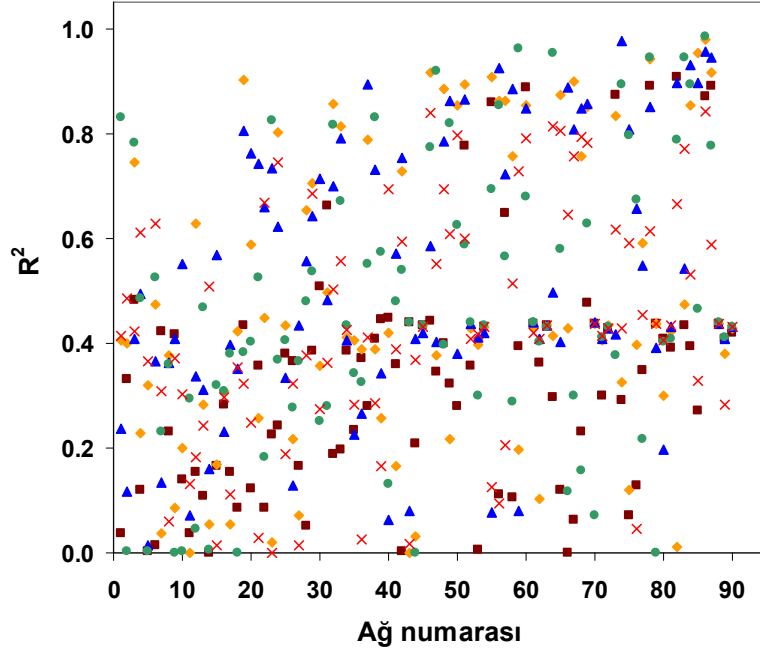
### 4.3. Kinetik Veri Grubu-II ve Ağ Optimizasyonu

Reaksiyon mühendisliği ile ilgili çalışmaların en önemli aşaması reaksiyon kinetiğinin çıkartılmasıdır. Özellikler enzimatik çalışmalarda Michalis-Menten enzim kinetiği başta olmak üzere benzeri veya daha kompleks ifadeler kullanılarak reaksiyon hız değerinin substrat ve ürün derişimi üzerinden hesaplanmasına amaçlanmaktadır. Ön çalışmalar ışığında farklı matematiksel yaklaşımlar kullanılarak en uygun matematiksel ifadeden türetilmekte ve sonrasındaki mühendislik uygulamalarında kullanılmaktadır. Biyokimyasal bir süreci matematiksel bir ifade ile açıklamak her zaman mümkün olamamakta ve bunun sonucu olarak matematiksel ifadelerin başarısı sınırlı kalmaktadır. Bu aşamada matematiksel bir ifade olmaksızın hız değerlerinin tahmin edilmesinin mümkün olup olmadığı bu çalışma kapsamında incelenmiştir. Öncelikle zaman-derişim veri grubu farklı başlangıç substrat ve ürün derişimlerinde saptanmış, bu veri grubu YSA'nın eğitim sürecinde kullanılmıştır. Eğitim sürecinde ağ parametrelerinin etkisi önceki çalışmalara benzer olarak 930




Şekil 4.9 Kinetik veri grubu-II verileri ile eğitilmiş ağların OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

farklı ağ kullanılarak denenmiş ve yüksek istatistiksel skorlara sahip ağlar saptanmıştır. Hesaplanan değerlerin bazıları Şekil 4.9 - 4.11'de görülmektedir. En yüksek istatistiksel skorlara sahip ağlar Çizelge 4. 3 de verilmiştir.



Şekil 4.10 Kinetik veri grubu-II ile eğitilmiş ağların  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.11 Kinetik veri grubu-II ile eğitilmiş ağların HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)


Çizelge 4.3 Kinetik-II veri grubu için istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri

Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	R <sup>2</sup>	HKO	Performans sırası		
		#1	#2				OMS	R <sup>2</sup>	HKO
10	<i>trainlm</i>	<i>tansig</i>	<i>tansig</i>	9.29	0.965	0.00071	1		
7	<i>trainlm</i>	<i>logsig</i>	<i>tansig</i>	9.94	0.968	0.00067	2		
4	<i>trainlm</i>	<i>tansig</i>	<i>tansig</i>	10.40	0.974	0.00056	3	4	5
7	<i>trainlm</i>	<i>logsig</i>	<i>logsig</i>	10.43	0.965	0.00075	4		
4	<i>trainlm</i>	<i>logsig</i>	<i>tansig</i>	10.48	0.967	0.00067	5		
4	<i>trainrp</i>	<i>tansig</i>	<i>logsig</i>	10.78	0.976	0.00049		1	1
3	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	10.89	0.974	0.00054		3	2
5	<i>trainlm</i>	<i>logsig</i>	<i>tansig</i>	10.98	0.974	0.00055		5	3
6	<i>trainlm</i>	<i>tansig</i>	<i>tansig</i>	13.34	0.975	0.00056		2	4

İstatistiksel skora bakıldığında iki ağın en yüksek performansa sahip olduğu görülmektedir. Bunlardan birincisi 10 gizli katman nöron sayısına, *tansig*, *tansig* transfer fonksiyonuna sahip ve *trainlm* eğitim algoritmasıyla eğitilmiş ağ olup en düşük OMS (% 9.29) değerine sahiptir. İkinci ağ ise 4 gizli katman nöron sayısına, *tansig*, *logsig* transfer fonksiyonuna sahip ve *trainrp* eğitim algoritmasıyla eğitilmiş ağ olup en iyi R<sup>2</sup> (% 0.976) ve HKO (0.00049) değerlerine sahiptir. Bu aşamada en iyi ağ seçmek oldukça zordur. Bu iki ağın ürettiği değerler ile gerçek değerlerin karşılaştırılması Şekil 4.12 ve Şekil 4.13'da görülmektedir.

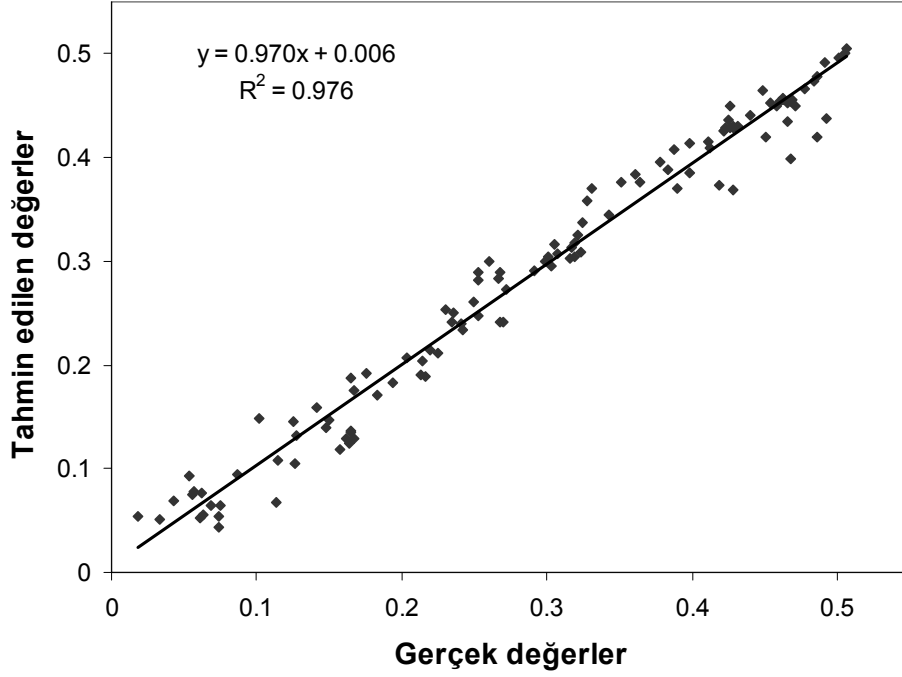
Şekillerde yer alan veriler 930 ağ içerisinde en yüksek skora sahip iki ağ tarafından üretilmiştir. Çalışma kapsamında geliştirilen yazılım kullanılmaksızın böyle bir ağ elde etmek mümkün görünmemektedir. Dolayısıyla yazılımın başarılı olduğu söylenilebilir. Fakat en iyi ağın hangisi olduğunu yazılım kullanılarak seçmek mümkün olmamıştır. Şekil 4.12 ve 4.13'a bakıldığında her iki ağında belirli

ölçüde başarılı olduğu görülmektedir. Şekil 4.12'de çizilmiş olan eğilim çizgisinin eğimi 1'e yakinken Şekil 4.13'de çizilen eğilim çizgisinin eğimi 0.970 olduğu görülmektedir. Bir diğer ifadeyle ikinci ağ genel olarak % 3'lük bir hata ile değerleri tahmin etmektedir. Ayrıca birinci eğilim çizgisinin kesim noktası 0.004 olup sıfıra oldukça yakın bir değerdir. Bu sonuçlar doğrultusunda OMS değerine göre seçilmiş ağın enzimatik reaksiyon hızını daha doğru tahmin ettiği söylenebilir.



Şekil 4.12 Birinci ağın üretmiş olduğu değerlerin deneysel değerler ile karşılaştırılması

Çalışmanın bu kısmında en yüksek istatistiksel skora sahip olan ağ mühendislik uygulamalarında matematiksel eşitlik yerine kullanılıp kullanılmayacağı incelenmiştir. Deneysel çalışmalar kısmında verilen sayısal çözümlere gerçekleştirilmiş model denklemlerde matematiksel hız ifadesi yerine yapay sinir ağının üretmiş olduğu veriler kullanılmış ve zaman-derişim grafiği üretilmiştir.



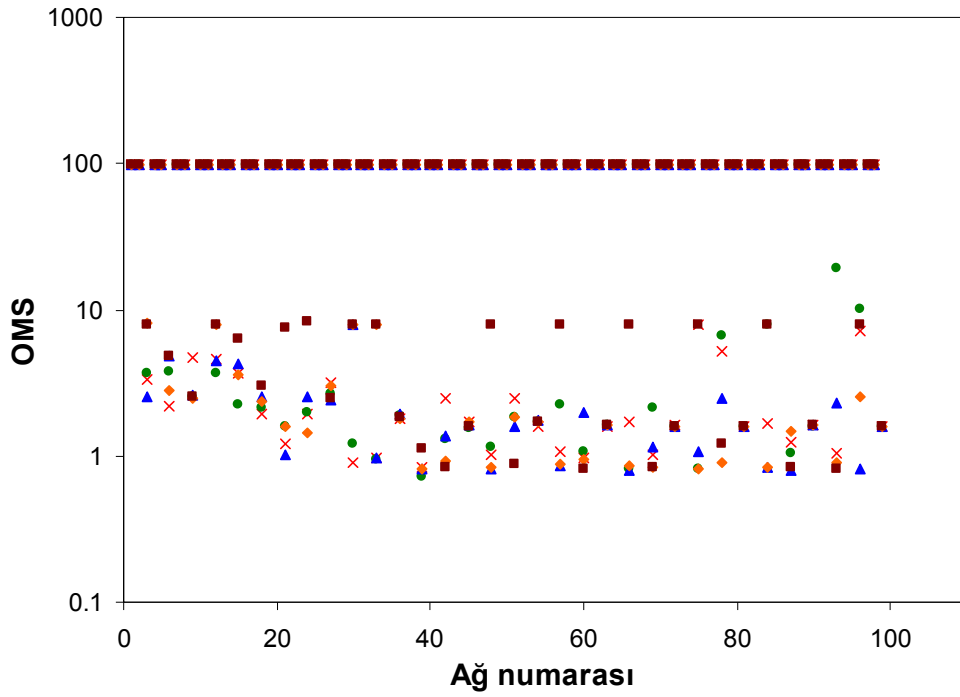
Şekil 4.13 İkinci ağın üretmiş olduğu değerlerin deneysel değerler ile karşılaştırılması

Aynı işlem farklı başlangıç substrat ve ürün derişimi için tekrarlanmıştır. Gerçek değerler ile tahmin edilen değerler arasında büyük bir uyum gözlenmiştir. Bu durum yapay sinir ağların mühendislik uygulamalarında kullanılan matematiksel ifadelerin yerine kullanılabileceğini göstermektedir. Reaksiyon kinetiğinin herhangi bir matematiksel ifadeyle sınırlandırılmadığı için çok daha doğru sonuçlar üretebileceği açıktır. Buradan yola çıkarak gelecekte yapay sinir ağlarının kinetik ifadelerin yerini alacağı ve yaygın bir şekilde kullanılacağı düşünülmektedir.

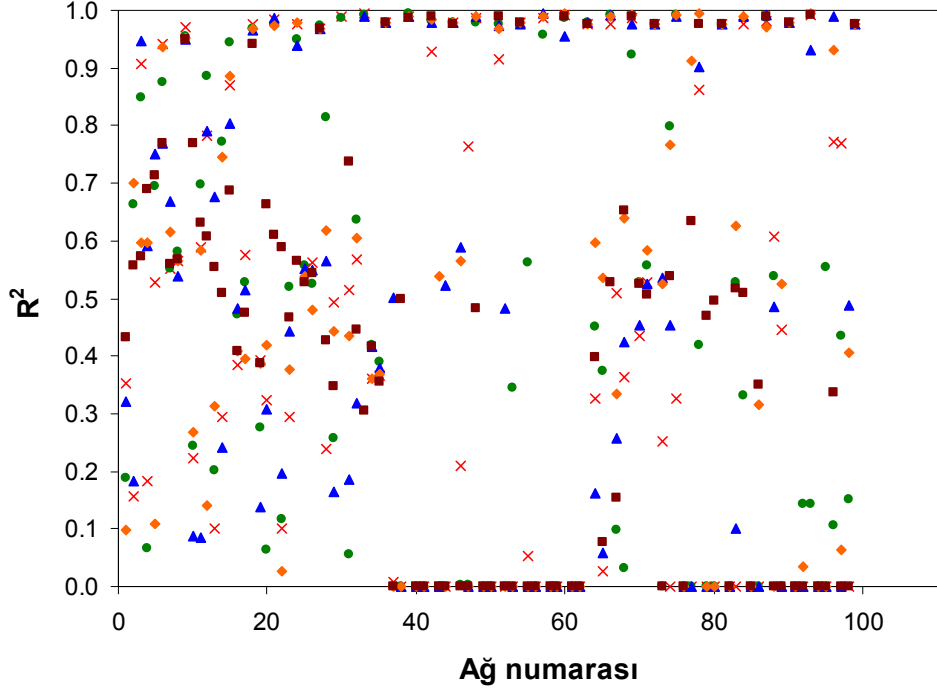
#### 4.4. Absorbans-renk veri grubu

Çalışma kapsamında rafine ayçiçeği, zeytin, fındık, kanola, susam, pamuk, mısır, soya yağları ve bu yağların karışımlarından oluşan toplam 100 farklı renk değerine sahip yağ karışımları hazırlanmış, yağların görünür bölge absorbans spektrumları ve  $L^*$ ,  $a^*$  ve  $b^*$  renk değerleri saptanmıştır. Üretilen veri grubu kullanılarak her


hangi matematiksel bir eşitliğe gerek kalmaksızın absorbands verilerini kullanarak  $L^*$ ,  $a^*$  ve  $b^*$  renk değerlerini yüksek doğrulukta tahmin edebilecek yapay sinir ağı üretilmeye çalışılmıştır. Veri grubu kullanılarak yapay sinir ağlarında eğitim süreci gerçekleştirilmiş, 930 farklı ağ ve üç farklı veri grubu için ( $L^*$ ,  $a^*$  ve  $b^*$ ) eğitilmiş ve yüksek skorlara sahip ağlar saptanmıştır. Elde edilen sonuçlar Şekil 4.14-4.22'da verilmiş ve yüksek istatistiksel skorlara sahip ağların parametreleri Çizelge 4.4-4.6'de verilmiştir. Önceki eğitim sürecinde olduğu gibi absorbands-renk veri grubunda da aynı veri grubu için eğitim parametrelerine bağlı olarak çok farklı sonuçlar elde edilmiştir.



Şekil 4.14 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.15 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Şekil 4.16 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Çizelge 4.4 Absorbans- $L^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri


Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
8	<i>traincgf</i>	<i>tansig</i>	<i>purelin</i>	0.730	0.994	0.124	1	5	1
7	<i>trainoss</i>	<i>logsig</i>	<i>purelin</i>	0.793	0.991	0.162	2		
6	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	0.806	0.993	0.142	3		3
7	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	0.809	0.993	0.138	4		
4	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	0.809	0.993	0.138			2
9	<i>traincgf</i>	<i>tansig</i>	<i>purelin</i>	0.818	0.990	0.171	5		
3	<i>trainscg</i>	<i>logsig</i>	<i>purelin</i>	0.842	0.992	0.153		1	4
6	<i>traincgb</i>	<i>tansig</i>	<i>purelin</i>	0.867	0.994	0.159			5
6	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	0.904	0.994	0.175		4	
3	<i>trainbfg</i>	<i>logsig</i>	<i>purelin</i>	0.904	0.994	0.175		3	
10	<i>trainrp</i>	<i>logsig</i>	<i>purelin</i>	0.965	0.994	0.227		2	



Şekil 4.17 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



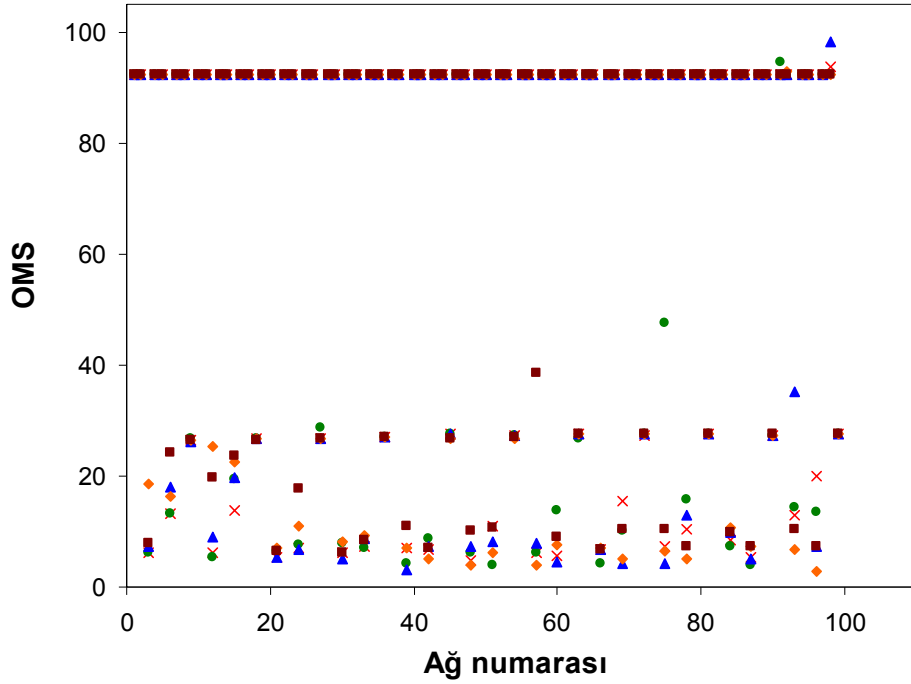
Şekil 4.18 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Şekil 4.19 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

Çizelge 4.5 Absorbans- $a^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri


Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
8	<i>trainrp</i>	<i>tansig</i>	<i>logsig</i>	8.64	0.848	6.509	1		
4	<i>traingda</i>	<i>logsig</i>	<i>logsig</i>	8.92	0.847	6.512	2		
6	<i>traingda</i>	<i>logsig</i>	<i>logsig</i>	8.92	0.847	6.512	3		
3	<i>traincgb</i>	<i>logsig</i>	<i>logsig</i>	10.10	0.844	6.513	4		
7	<i>trainoss</i>	<i>tansig</i>	<i>logsig</i>	11.06	0.845	6.513	5		
9	<i>traincgp</i>	<i>logsig</i>	<i>purelin</i>	15.96	0.996	0.056		4	2
8	<i>traincgp</i>	<i>tansig</i>	<i>purelin</i>	16.68	0.996	0.067			4
6	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	17.10	0.997	0.046		1	1
5	<i>traincgf</i>	<i>logsig</i>	<i>purelin</i>	18.25	0.996	0.057		3	3
9	<i>trainrp</i>	<i>logsig</i>	<i>purelin</i>	21.99	0.997	0.153		2	5
3	<i>traincgb</i>	<i>tansig</i>	<i>purelin</i>	22.99	0.994	0.095			5



Şekil 4.20 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.21 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.22 Absorbans- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

Çizelge 4.6 Absorbans- $b^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri


Gizli katman nöron sayısı	Eğitim Fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
8	<i>trainlm</i>	<i>logsig</i>	<i>purelin</i>	2.768	0.996	0.242	1	1	1
7	<i>traincgf</i>	<i>tansig</i>	<i>purelin</i>	3.174	0.994	0.305	2	3	2
6	<i>trainoss</i>	<i>logsig</i>	<i>purelin</i>	3.863	0.994	0.337	3	4	3
7	<i>traincgp</i>	<i>tansig</i>	<i>purelin</i>	3.872	0.992	0.429	4		
4	<i>traincgp</i>	<i>logsig</i>	<i>purelin</i>	3.955	0.992	0.418	5		
9	<i>traincgb</i>	<i>tansig</i>	<i>purelin</i>	4.003	0.995	0.338		2	4
3	<i>traincgb</i>	<i>logsig</i>	<i>purelin</i>	0.842	0.992	0.153		5	5

Toplam 2790 ağ eğitilmiş ve bunlar içerisinde yüksek performansa sahip ağlar  $L^*a^*b^*$  değerlerinin tahmin edilmesinde kullanılmıştır. Bu ağlar içerisinde en iyi istatistiksel skora sahip olanlara bakılırsa her üç renk değeri içinde % 8.64'in altında OMS, 0.992'nin üzerinde  $R^2$  ve 0.0242'nin altında HKO değerleri elde edilmiştir. Bu değerlere bakıldığında eğitilmiş ağların oldukça yüksek doğrulukta renk değerlerini tahmin edebildiği söylenilebilir. Bu aşamada her üç renk değerini tahmin edebilen tek bir ağ eğitmek yerine her üç renk değeri içinde ayrı ayrı ağlar eğitilmiştir. Bu yaklaşım sayesinde daha yüksek doğrulukta tahmin yeteneğine sahip ağların seçimi mümkün kılınmıştır. İstatistiksel değerler arasında OMS değeri tahmin edilen değerlerdeki hatayı ön plana çıkarmıştır.  $L^*$ değerinde % 0.730,  $a^*$  değerinde % 2.768 ve  $b^*$  değerinde % 8.640 hata değeri saptanmıştır.  $b^*$  değeri dışındaki istatistiksel değerler % 5 deneysel hata değerinin altında kalmıştır. Bu hatalar geliştirilen sistem kadar standart sistemden de


kaynaklanabilmektedir. Daha fazla örnek ve spektrofotometre kullanılarak bu hata değerlerinin düşürülebileceğine inanılmaktadır.

#### **4.5. RGB- $L^*a^*b^*$ veri grubu**


$L^*a^*b$  renk formatı sıvı örnekler kadar katı örnekler içinde bilimsel ve endüstriyel ölçümlerde önem taşıyan bir renk formatıdır.  $L^*a^*b$  renk formatında ölçüm yapabilmek için özel spektrofotometrelere gereksinim duyulmaktadır. Bu ekipmanlar oldukça pahalı olmasının yanı sıra renk ölçümü kullanıcı tarafından belirlenen belirli çap içerisindeki ortalama renk değerini saptayabilmektedir. Homojen olmayan ve/veya düzgün bir şekle sahip olmayan örneklerde problemler yaşanmakta olup ön işlemler yapılarak bu problemler minimize edilmeye çalışılmaktadır. Bu çalışma kapsamında katı örneklerde renk ölçümü yapabilecek düşük maliyetli, düzensiz şekil ve renk dağılımına sahip bir renk ölçüm sisteminin basit ofis ekipmanları ile kurulması ve YSA kullanılarak renk değerlerinin  $L^*a^*b$  renk formatında türetilmesi hedeflenmiştir. İlk aşamada renk kartelası kullanılarak RGB ve  $L^*a^*b$  formatlarında renk değerleri saptanmış ve yapay sinir ağının eğitiminde kullanılmıştır. Üç farklı renk değeri için farklı ağlar denenerek toplam 3 X 930 farklı yapay sinir ağı oluşturulmuş ve eğitilmiştir. Eğitim süreci sonrası eğitilmiş ağların performansları gerçek değerler ile tahmin edilen değerler karşılaştırılarak incelenmiştir. Farklı ağlar için elde edilen OMS,  $R^2$  ve HKO değerleri Şekil 4.23-4.31'da görülmektedir. Üç farklı renk değeri için en yüksek istatistiksel değerlere sahip beş ağın parametreleri Çizelge 4.7-4.9'de verilmiştir.



Şekil 4.23 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.24 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Şekil 4.25 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $L^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)


Çizelge 4.7 Absorbans- $L^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri

Gizli katman nöron sayısı	Eğitim fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
8	<i>trainrp</i>	<i>logsig</i>	<i>purelin</i>	27.27	0.996	3.42767	1	1	
7	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	27.27	0.996	3.31688	2		2
5	<i>traincgb</i>	<i>tansig</i>	<i>purelin</i>	27.27	0.996	3.63326	3		3
4	<i>traincgb</i>	<i>purelin</i>	<i>purelin</i>	27.27	0.996	3.27160	4	4	3
3	<i>traingda</i>	<i>purelin</i>	<i>purelin</i>	27.27	0.996	2.51736	5		1
4	<i>traingda</i>	<i>purelin</i>	<i>purelin</i>	27.27	0.996	3.27919		5	4
3	<i>trainlm</i>	<i>tansig</i>	<i>purelin</i>	29.21	0.995	3.31688			5






Şekil 4.26 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Şekil 4.27 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)




Şekil 4.28 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $a^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)

Çizelge 4.8 Absorbans- $a^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri


Gizli katman nöron sayısı	Eğitim fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
7	<i>trainscg</i>	<i>logsig</i>	<i>purelin</i>	0.045	0.990	2.739	1	1	1
6	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	0.126	0.990	2.739	2	3	2
4	<i>trainscg</i>	<i>tansig</i>	<i>purelin</i>	0.126	0.990	2.739	3	4	3
4	<i>trainrp</i>	<i>logsig</i>	<i>purelin</i>	0.458	0.990	2.741	5	2	4
3	<i>trainbfg</i>	<i>tansig</i>	<i>purelin</i>	1.964	0.989	2.921		5	5
5	<i>traincgp</i>	<i>logsig</i>	<i>purelin</i>	0.209	0.973	7.102	4		



Şekil 4.29 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için OMS değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



Şekil 4.30 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için  $R^2$  değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron)



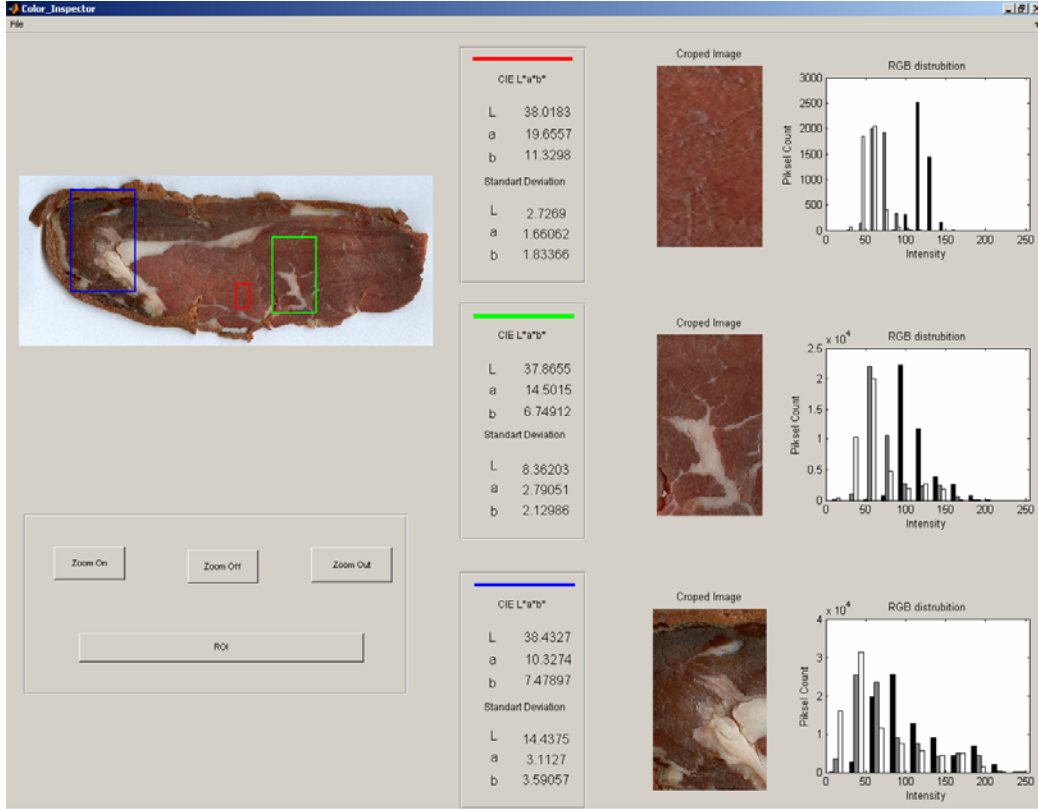
Şekil 4.31 RGB- $L^*a^*b^*$  veri grubu ile eğitilmiş ağlar için  $b^*$  renk değeri için HKO değer dağılımları (■: İki nöron, ◆: Dört nöron, ▲: Altı nöron, ●: Sekiz nöron, ×: On nöron).

Bu sonuçlar doğrultusunda geliştirilen algoritmanın ve yazılımın RGB verilenin  $L^*a^*b^*$ ye dönüştürülmesinde de kullanılabileceği ortaya konmuştur. Çalışmanın son aşamasında geliştirilen YSA'nın renk ölçümünde kolay kullanımı için ara yüzey geliştirilmiştir. Geliştirilen ara yüzey Şekil 4.32'de verilmiştir. Bu ara yüzey kullanılarak örneğin resmi yazılıma yüklenebilir, istenilen bölge seçilebilir ve renk ölçümü gerçekleştirilebilir. Geliştirilen ara yüzeyi test etmek amacıyla farklı gıda örneklerinin renk ölçümleri gerçekleştirilmiştir. Farklı gıda örnekleri için ölçülen ve tahmin edilen renk değerleri Çizelge 4.10'da verilmiştir. Çizelgede görüldüğü gibi ölçülen değerler ile tahmin edilen değerler arasında istatistiksel olarak bir fark yoktur.

Çizelge 4.9 Absorbans- $b^*$  veri grubu istatistiksel performans kriterlerine göre sıralanmış ağ parametreleri

Gizli katman nöron sayısı	Eğitim fonksiyonu	Transfer fonksiyonu		OMS (%)	$R^2$	HKO	Performans sırası		
		#1	#2				OMS	$R^2$	HKO
7	<i>traingdm</i>	<i>tansig</i>	<i>purelin</i>	19.02	0.798	105.746	1		
6	<i>traingd</i>	<i>tansig</i>	<i>purelin</i>	19.30	0.847	93.094	2		
4	<i>traingd</i>	<i>tansig</i>	<i>purelin</i>	19.38	0.851	92.723	3		
4	<i>traingdm</i>	<i>tansig</i>	<i>purelin</i>	19.39	0.821	95.819	4		
6	<i>traingd</i>	<i>tansig</i>	<i>purelin</i>	19.44	0.861	91.663	5		
5	<i>traingd</i>	<i>logsig</i>	<i>purelin</i>	20.48	0.987	51.539			3
4	<i>traingd</i>	<i>logsig</i>	<i>purelin</i>	21.03	0.989	27.907			2
4	<i>traincgp</i>	<i>purelin</i>	<i>purelin</i>	21.50	0.902	0.337			5
3	<i>traincgf</i>	<i>purelin</i>	<i>purelin</i>	21.51	0.902	0.327			4
2	<i>traingda</i>	<i>purelin</i>	<i>purelin</i>	21.54	0.902	0.182			3
8	<i>traingda</i>	<i>purelin</i>	<i>purelin</i>	21.55	0.902	0.172			2
7	<i>traingda</i>	<i>purelin</i>	<i>purelin</i>	21.56	0.902	0.158			1
6	<i>traincgf</i>	<i>tansig</i>	<i>purelin</i>	21.81	0.977	16.002			5
4	<i>trainbfg</i>	<i>logsig</i>	<i>purelin</i>	21.89	0.982	30.034			4
5	<i>traingda</i>	<i>tansig</i>	<i>purelin</i>	22.10	1.013	25.286			1

Bu sonuçlar geliştirilen yazılımın ve ara yüzeyin gıda örneklerinde kullanılabileceğini göstermektedir. Ayrıca çalışma kapsamında geliştirilen ara yüzeyi kullanarak kullanıcının gereksinmesi doğrultusunda çok büyük veya küçük bir alanda renk ölçümü gerçekleştirilebilmekte, homojen renk dağılımına sahip olmayan örneklerde renk ölçümü çok daha doğru bir şekilde yapılabilmektedir. Geliştirilen yazılımın en büyük avantajı ise gelişmiş spektrofotometrelerde şekil bozukluğu nedeniyle ölçüm alınamayan örneklerde ölçüm alınabilir olmasıdır.



Şekil 4.32 RGB renk değerlerinin  $L^*a^*b^*$  renk değerlerine dönüştürmek için geliştirilen yazılım ara yüzeyi

Yapay sınır ağları bilimin her alanında yoğun bir şekilde kullanılmakla birlikte kullanıcıların en büyük problemi uygun ağ tasarımının seçilememesidir. Yoğun bir şekilde ağ parametrelerinin optimizasyonuna gereksinim duyulmaktadır. Yaygın bir yaklaşım olarak sınırlı sayıda ağın kullanıcı tarafından oluşturulması ve test edilmesi sonrasında en doğru tahmin kapasitesine sahip ağın seçilmesidir. Bu kapsamda sınırlı sayıda ağ denenebilmekte ve bu nedenle en uygun ağın seçimi genellikle yapılamamaktadır. Çalışma kapsamında bu problemi ortadan kaldırabilecek bir yazılımın geliştirilmesi minimum kullanıcıya gereksinim duyulması ve bu sayede YSA yazılımları ile bilgisi olmayanların da çalışmalarında YSA'nı kullanabilmeleri, çalışmalarında verilerini maksimum düzeyde kullanabilmeleri ve eğitim sürecini daha iyi bir şekilde gerçekleştirebilmeleri

Çizelge 4.10 Gıda örnekleri için ölçülen ve tahmin edilen renk değerleri

Örnek	Deneysel ölçülen			Tahmin edilen		
	$L^*$	$a^*$	$b^*$	$L^*$	$a^*$	$b^*$
Kaşar peyniri	81.6	-0.5	19.1	81.3	-1.6	18.1
Kırmız et	43.0	17.1	6.9	42.0	10.0	12.5
Lazanya	84.4	1.3	25.8	84.1	1.5	27.4
Sosis -I	67.3	27.1	14.8	59.2	24.0	13.5
Sosis -II	56.7	31.1	12.2	46.8	29.0	11.4
Havuç -I	59.4	30.6	34.8	46.3	26.3	31.1
Havuç -II	64.2	32.4	39.2	61.0	37.5	44.6
Tacuk eti	60.9	5.5	6.2	57.7	-2.1	6.3
Proses peyniri	91.1	-1.5	7.4	94.4	-0.9	9.8
Beyaz çikolata	43.2	10.7	12.8	38.4	9.7	12.6
Çikolata	33.0	5.0	3.9	26.7	5.2	4.5
Goflet	86.9	2.2	24.2	79.8	0.9	23.3
<b>R<sup>2</sup></b>	<b>0.958</b>	<b>0.938</b>	<b>0.962</b>			

sağlanmıştır. Geliştirilen yazılım farklı mühendislik uygulamalarında test edilmiş ve tüm uygulamalarda yüksek başarılar sağlanmıştır. Geliştirilen yazılım kullanıcı ihtiyaçları doğrultusunda farklı uygulamalarla da birleştirilmiştir. Özellikle RGB- $L^*a^*b$  renk değerleri ile yapılan çalışmada kullanıcının yüzde yüz ihtiyacını karşılayabilecek bir uygulama hazırlanmıştır. Bu durum geliştirilen yazılımın ticarileştirilebilecek ürünlerde de başarı ile kullanılabileceğini göstermiştir.

## 5. TARTIŞMA VE YORUM

Yapay sinir ağıları farklı disiplinler arasında yaygın olarak kullanılmaktadır. Son yıllarda karşılaşılan çalışmalarda kullanımının daha da yaygınlaşacağını göstermektedir. Yapay sinir ağlarının en büyük avantajı bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkinin her hangi bir eşitliğe gereksinim duyulmaksızın algılanabilmesi ve sonrasında eğitilmiş ağ kullanılarak bağımsız değişkenler için bağımlı değişken tahmin edilebilmektedir. Bilim tarihi boyunca bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişki saptanmaya çalışılmış ve bu ilişkiyi tanımlamak için matematiksel eşitlikler ortaya konmuştur. Bu aşamada matematiksel işlem yükünü azaltmak ve eşitliğin kullanımını arttırmak için basit eşitliklerin kullanımı tercih edilmiş ve bazı kabullenmeler yapılmıştır. Bu durum eşitliklerin doğruluğunu sınırlandırmaktadır. Yapay sinir ağları bu aşamada devreye girmekte olup ilişkinin bir eşitlikle sınırlandırılmasını ortadan kaldırmakta doğal sinir sistemine benzer bir yaklaşım kullanılarak bağımlı değişkenle bağımsız değişken ilişkilendirilmektedir. Dolayısıyla YSA günümüze kadar yaygın olarak kullanılan matematiksel eşitliklerin yerine kullanılabilir yeni bir yaklaşımdır.

Yapay sinir ağlarının basit bir matematiksel altyapısı olmasına karşın çok fazla parametresinin olması, yoğun tekrarlanır matematiksel işlemlere gereksinim duyması ve en önemlisi bir programa gereksinim duyması kullanımını sınırlandırmaktadır. Bu durum programlara yakın olmayan ve programlama mantığını bilmeyen kullanıcıların işlerini zorlaştırmakta ve/veya YSA'nın başarısını sınırlandırmaktadır. Bu çalışma kapsamında genel bilgisayar kullanıcıların kullanabileceği bir yazılım geliştirerek YSA'nın kullanımı kolaylaştırmak, maksimum sayıda YSA eğitim parametresi test ederek daha iyi eğitilmiş ve dolayısıyla daha doğru tahmin kapasitesine sahip ağıın seçimine imkan sağlamak



amaçlanmıştır. Çalışma kapsamında yazılım hazırlanmış ve çok farklı veri grupları için test edilmiştir. Geliştirilen yazılım sayesinde tüm veri grupları için yüksek tahmin kapasitesine sahip eğitilmiş ağlar seçilebilmiştir. Bu sonuçlar geliştirilen başarılı olduğunu göstermiştir. Tez kapsamında sadece yazılım geliştirilmekle kalmamış aynı zamanda YSA'nın farklı uygulamalarda kullanılabilirliği gösterilmiştir. Bunlardan en önemlisi enzimatik reaksiyon hızının tahmininde kinetik eşitlik yerine YSA'nın kullanılabileceği gösterilmiş ve sonrasında eğitilmiş ağın mühendislik hesaplamalarında kullanılabilirliği gösterilmiştir. Bu yeni bir yaklaşım olmakla birlikte ileriki yıllarda yaygın olarak kullanılacağına inanılmaktadır. Bir diğer yenilik ise renk değerlerinin absorbans verilerinden tahmin edilmesi olmuştur. Bu yaklaşım sayesinde pahalı ve yaygın olmayan renk ölçüm sistemleri yerine genel laboratuvar ekipmanları arasında yer alan basit UV-VİS spektrofotometre kullanılarak gerçekleştirilebilmiştir. Son olarak katı, non-homojen ve düzgün bir şekle sahip olmayan örneklerde renk ölçümünü yapabilecek bir sistem tasarlanmış ve  $L^*a^*b^*$  formatında renk ölçümü mümkün kılınmıştır.

## KAYNAKLAR

- Baş, D., 2005, Enzimatik Reaksiyonlara Ait Kinetik Katsayıların Cevap Yüzeyi Metodu Ve Yapay Sinir Ağları Kullanılarak Saptanması, Yüksek Mühendislik Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 73s.
- Baş, D., Dudak, F.C., & Boyacı, İ.H., 2007, Modeling and optimization III: Reaction rate estimation using artificial neural network (ANN) without a kinetic model, J. Food Eng. 79, 622-628.
- Brodnjak-Vončina, D., Kodba, Z.C., & Novič, M., 2005, Multivariate data analysis in classification of vegetable oils characterized by the content of fatty acids, Chemom. Intell. Lab. Syst. 75, 31– 43.
- Buciński, A., Zieliński, H., & Kozłowska, H., 2004, Artificial neural networks for prediction of antioxidant capacity of cruciferous sprouts, Trends Food Sci. Technol. 15, 161–169.
- Dutta, R., Hines, E.L, Gardner, J.W., Udrea, D.D., & Boilot, P., 2003, Non-destructive egg freshness determination: an electronic nose based approach, Meas. Sci. Technol. 14, 190–198.
- Elmas, Ç. 2003, Yapay sinir ağları, Seçkin Yayıncılık, Ankara, 192s.
- Gonçalves, E.C., Minim, L.A., Coimbra, J.S.R., & Minim, V.P.R., 2005, Modeling sterilization process of canned foods using artificial neural networks. Chem. Eng. Process. 44, 1269–1276.

- Hajmeer, M.N., Basheer, I.A., & Najjar, Y.M., 1997, Computational neural networks for predictive microbiology II. Application to microbial growth, *Int. J. Food Microbiol.* 34, 51-66.
- Haykin, S., 1994, *Neural networks*, Prentice Hall, New Jersey, 696p.
- Jimenez-Marquez, S.A., Thibault, J., & Lacroix, C., 2005, Prediction of moisture in cheese of commercial production using neural networks, *Int. Dairy J.* 15, 1156–1174.
- Karaboğa D., *Yapay zeka optimizasyon algoritmaları*, Atlas Yayın Dağıtım, 2004, 199s.
- Lou, W., & Nakai, S., 2001, Application of artificial neural networks for predicting the thermal inactivation of bacteria: a combined effect of temperature, pH and water activity, *Food Res Int.* 34, 573–579.
- Mittal, G.S., & Zhang, J., 2003, Artificial neural network-based psychrometric predictor, *Biosystems Engineering*, 85, 283–289.
- Öztemel, E., 2003, *Yapay sinir ağları*, Papatya Yayıncılık, Ankara, 232s.
- Razavi, S.M.A., Mousavi, S.M., & Mortazavi, S.A., 2003, Dynamic prediction of milk ultrafiltration performance: A neural network approach, *Chem. Eng. Sci.* 58, 4185 - 4195.
- Torrecilla, J.S., Otero, L., & Sanz, P.D., 2004, A neural network approach for thermal/pressure food processing, *J. Food Eng.* 62, 89–95.
- Torrecilla, J.S., Otero, L., & Sanz, P.D., 2005, Artificial neural networks: a promising tool to design and optimize high-pressure food processes, *J. Food Eng.* 69, 299–306.



-----

Oluşturulan Ağlar Matfile olarak kaydedilir.

```
clear all
load ag
for i=0:10
    load(int2str(i))
    results=res(tnetwork,tro,to)
    xlswrite('veriler',results,int2str(i));
    clear results
    clear tnetwork
end
```

-----

```
function results=res(tnetwork,tro,testo)
%results=res(tnetwork)
results={'epochhs','training error','test
error','trainFcn','hlayer','transferFcn1','transferFcn2','trr2','trm','trn','tr2','tm','tn','agnumarası',
'traad','taad'};
for i=1:size(tnetwork,2);
    results{i+1,1}=size(tnetwork(i).tr.perf,2);
    results{i+1,2}=tnetwork(i).tr.perf(size(tnetwork(i).tr.perf,2));
    results{i+1,3}=tnetwork(i).error;
    results{i+1,4}=tnetwork(i).net.trainFcn;
    if tnetwork(i).net.numLayers-1==0;
        results{i+1,5}=tnetwork(i).net.numLayers-1;
        results{i+1,6}=tnetwork(i).net.layers{1,1}.transferFcn;
        results{i+1,7}=0;
    else
        results{i+1,5}=tnetwork(i).net.numLayers-1;
        results{i+1,6}=tnetwork(i).net.layers{1,1}.transferFcn;
        results{i+1,7}=tnetwork(i).net.layers{2,1}.transferFcn;
    end
    [mtr(i),ntr(i),rtr(i)] = postreg(tnetwork(i).trout,tro);
    [mt(i),nt(i),rt(i)] = postreg(tnetwork(i).tout,testo);
    results{i+1,8}=rtr(i);
    results{i+1,9}=mtr(i);
    results{i+1,10}=ntr(i);
    results{i+1,11}=rt(i);
    results{i+1,12}=mt(i);
    results{i+1,13}=nt(i);
    results{i+1,14}=i;
    results{i+1,15}=aad1(tro,tnetwork(i).trout);
    results{i+1,16}=aad1(testo,tnetwork(i).tout);
end
```

-----

```
function sonuc=aad1(gercek,hesap)
for i=1:size(gercek,2)
```

```
s(i)=(abs(gercek(i)-hesap(i))/gercek(i))*100;  
end  
sonuc=sum(s)/i;
```

-----

## ÖZGEÇMİŞ

**Adı Soyadı :** Kıvanç Kılıç

**Doğum Yeri :** Ankara

**Doğum Yılı :** 1982

**Medeni Hali :** Bekar

**Eğitim ve Akademik Durumu:**

**Lise :** 1992-2000 Çorum Anadolu Lisesi

**Lisans :** 2000-2004 Hacettepe Üniversitesi Gıda Mühendisliği Bölümü

**Yabancı Dil :** İngilizce