



T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü



# YAPAY SİNİR AĞLARININ GAMA SPEKTROMETRİK ÖLÇÜMLERE UYGULANMASI

Doktora Tezi

Selin ERZİN

Nükleer Bilimler Anabilim Dalı

İzmir  
2019



T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü

# **YAPAY SİNİR AĞLARININ GAMA SPEKTROMETRİK ÖLÇÜMLERE UYGULANMASI**

Selin ERZİN

Danışman : Prof. Dr. Günseli YAPRAK

Nükleer Bilimler Anabilim Dalı  
Nükleer Bilimler Doktora Programı

İzmir  
2019



Selin ERZİN tarafından Doktora tezi olarak sunulan “Yapay sinir ağlarının gama spektrometrik ölçümlere uygulanması” başlıklı bu çalışma EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliği ile EÜ Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesi’nin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve 18/07/2019 tarihinde yapılan tez savunma sınavında aday oybirliği/~~oyçokluğu~~ ile başarılı bulunmuştur.

**Jüri Üyeleri:**

**Jüri Başkanı** : Prof. Dr. Günseli YAPRAK  
**Raportör Üye** : Prof. Dr. Özlem KARADENİZ  
**Üye** : Prof. Dr. N. Füsun ÇAM  
**Üye** : Prof. Dr. Aysun UĞUR GÖRGÜN  
**Üye** : Doç. Dr. Arzu EGE

**İmza**

.....  
.....  
.....  
.....  
.....



**EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ****ETİK KURALLARA UYGUNLUK BEYANI**

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Doktora Tezi olarak sunduğum “Yapay Sinir Ağlarının Gama Spektrometrik Ölçümlere Uygulanması” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

18 / 07/ 2019



Selin ERZİN



**ÖZET****YAPAY SİNİR AĞLARININ GAMA SPEKTROMETRİK  
ÖLÇÜMLERE UYGULANMASI**

ERZİN, Selin

Doktora Tezi, Nükleer Bilimler Anabilim Dalı

Tez Danışmanı: Prof. Dr. Günseli YAPRAK

Temmuz 2019, 85 sayfa

Son yılların en yaygın konularından biri olan yapay sinir ağları (YSA), öğrenme kabiliyeti, hızlı çalışması, tanımlama kolaylığı, az bilgi ile çalışabilme, doğrusal olmayan sistemleri modelleyebilme, bilgiyi paralel olarak işleyebilme ve yeni durumlara uyum sağlayabilme gibi özelliklere sahiptir. Bu özelliklerinden dolayı, YSA, nükleer spektroskopi alanında örneğin, gama spektroskopisi, alfa spektroskopisi, pik-background oranı, puls tipi dedektörlerin enerji çözünürlük iyileştirmesi, proton kaynaklı X-ışını emisyonları, X-ışını flüoresan ve Rutherford geri saçılma vb. konularında kullanılmaktadır.

YSA'nın avantajlarını ve nükleer spektroskopide kullanımını göz önüne alarak, bu tezde, ilk olarak Nükleer Bilimler Enstitüsü sayım laboratuvarında bulunan HPGe dedektörü kullanılarak, gama spektral analizi için YSA uygulanmıştır. Geliştirilen YSA modelinin performansı, Çandarlı kıyı sedimenti örneklerinin gama spektral analizi ile test edilmiştir. YSA ile örnekler içerisindeki gama verici radionüklitlerin varlıkları başarıyla tespit edilmiştir.

Bu çalışmanın ikinci adımında, YSA, NaI(Tl) Sintilasyon Gama Spektrometre sisteminin değişik sayım sürelerinde ölçebileceği minimum dedekte edilebilir aktivite (MDA)'leri bulmak için kullanılmıştır. Bu amaçla, Enstitüde kullanılan sayım süreleri dikkate alınarak, 5000- 87000s arası,  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitleri için, minimum dedekte edilebilen aktivite (MDA) değerleri, Curie kriterlerine dayalı olarak hesaplanmıştır. YSA'dan elde edilen MDA değerleri ile hesaplanan MDA değerleri karşılaştırıldığında, birbirleriyle örtüştüğü görülmüştür.

Bu alıřmada, ilk kez, YSA, NaI(Tl) sintilasyon gama spektroskopisi ile doęal radyonklit analizleri iin uygulanmıřtır. Bu amala, 126 adet deęiřik orijinli evresel materyal; kaya, toprak, granit, mermer ve gbre rneklerinin ierisindeki uranyum, toryum ve potasyum konsantrasyonları hesaplanmıřtır. Hesaplanan aktivite deęerleri, YSA modelinden tahmin edilen deęerlerle karřılařtırıldıęında, YSA'nın rneklerdeki  $^{238}\text{U}$ ,  $^{232}\text{Th}$ , ve  $^{40}\text{K}$  aktivitelerini doęru bir řeklide tahmin edebildięi grlmřtr.

**Anahtar szckler:** Gama spektrometresi, kantitatif radyonklit analizi, minimum detekte edilebilen aktivite, yapay sinir aęları.



**ABSTRACT****APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO  
GAMMA SPECTROMETRIC MEASUREMENTS**

Erzin, Selin

PhD in Nuclear Sciences

Supervisor: Prof. Dr. Günseli YAPRAK

July 2019, 85 pages

Artificial neural networks (ANN), which is one of the most common subjects of recent years, has features such as learning ability, fast work, ease of identification, ability to work with less information, modeling nonlinear systems, processing information in parallel and adapting to new situations. In the field of nuclear spectroscopy, for example, gamma spectroscopy, alpha spectroscopy, peak-background ratio, energy resolution improvement of pulse type detectors, proton-induced X-ray emissions, X-ray fluorescence and Rutherford backscatter, and the like subjects.

Considering the advantages of ANN and its use in nuclear spectroscopy, in this thesis, ANN was firstly applied for gamma spectral analysis using the HPGe detector found in the census laboratory of the Institute of Nuclear Sciences. The performance of the ANN model was tested by gamma spectral analysis of Çandarlı coastal sediment samples. With ANN, the presence of gamma emitting radionuclides in the samples has been successfully determined.

In the second step of this study, ANN was used to find the minimum detectable activity (MDA) that the NaI (T1) Scintillation Gamma Spectrometer system could measure at different counting times. For this purpose, minimum detectable activity (MDA) values for  $^{238}\text{U}$ ,  $^{232}\text{Th}$  and  $^{40}\text{K}$  radionuclides between 5000- 87000s were calculated based on Curie criteria, taking into account the counting times used in the Institute. When the MDA values obtained from ANN were compared with the calculated MDA values, it was seen that they overlap with each other.

In this study, for the first time, ANN was applied for natural radionuclide analysis by NaI (T1) scintillation gamma spectroscopy. For this purpose, 126 different environmental materials; uranium, thorium and potassium concentrations in rock, soil, granite, marble and fertilizer samples were calculated. When the calculated activity values were compared with the values estimated from the ANN model, it was found that the ANN could accurately predict  $^{238}\text{U}$ ,  $^{232}\text{Th}$ , and  $^{40}\text{K}$  activities in the samples.

**Keywords:** Artificial neural networks, gamma spectrometry, quantitative radionuclide analysis, minimum detectable activity.



## ÖNSÖZ

Yapay sinir ağları (YSA), yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır. YSA'nın klasik modelleme tekniklerine (parametrik modeller) göre avantajları, parametrik olmaması (veri tabanlı), doğrusal olmayan sistemleri modelleyebilmesi, bilgiyi paralel olarak işleyebilmesi ve yeni durumlara uyum sağlayabilme yeteneğidir. Bu özelliklerinden dolayı, YSA pratik uygulamalarda kullanılmaya başlanmış ve halen kullanılmaya devam edilmektedir. Genellikle istatistiksel araç olarak veri işlemede kullanılan YSA, son zamanlarda nükleer spektroskopide alanında kullanılmaktadır. Nükleer spektroskopide YSA'nın çeşitli uygulamaları vardır, örn. gama spektroskopisi, alfa spektroskopisi, pik-background oranı, puls şekilli dedektörlerin çözünürlük iyileştirmesi, proton kaynaklı X-ışını emisyonları, X-ışını flüoresan ve Rutherford geri saçılma.

YSA'nın avantajlarını ve nükleer spektroskopide kullanımını göz önüne alarak, bu çalışmada, ilk olarak Nükleer Bilimler Enstitüsü sayım laboratuvarında bulunan HPGe dedektörü kullanılarak, gama spektral analizi için YSA uygulanmış ve YSA ile örnekler içerisindeki radionüklitlerin varlıkları başarıyla tespit edilmiştir. İkinci olarak, YSA, NaI(Tl) Sintilasyon Gama Spektrometre sisteminin değişik sayım sürelerinde ölçebileceği minimum dedekte edilebilir aktivite (MDA)'leri bulmak için kullanılmış ve YSA'dan elde edilen MDA değerleri ile hesaplanan MDA değerleri karşılaştırıldığında, birbirleriyle örtüştüğü görülmüştür. Son olarak, YSA, NaI(Tl) sintilasyon gama spektroskopisi ile 126 adet değişik orijinli örneklerin doğal radyonüklit analizleri için uygulanmıştır. Hesaplanan aktivite değerleri, YSA modelinden tahmin edilen değerlerle karşılaştırıldığında, YSA'nın örneklerdeki  $^{238}\text{U}$ ,  $^{232}\text{Th}$ , ve  $^{40}\text{K}$  aktivitelerini doğru bir şekilde tahmin edebildiği görülmüştür.

İZMİR

18/07/2019

Selin ERZİN



## İÇİNDEKİLER

### Sayfa

|                                                                          |      |
|--------------------------------------------------------------------------|------|
| İÇ KAPAK .....                                                           | ii   |
| KABUL ONAY SAYFASI .....                                                 | iii  |
| ETİK KURALLARA UYGUNLUK BEYANI .....                                     | v    |
| ÖZET .....                                                               | vii  |
| ABSTRACT , .....                                                         | ix   |
| ÖNSÖZ .....                                                              | xi   |
| İÇİNDEKİLER DİZİNİ .....                                                 | xiii |
| ŞEKİLLER DİZİNİ .....                                                    | xvii |
| TABLolar DİZİNİ .....                                                    | xx   |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                     | xxi  |
| 1.GİRİŞ .....                                                            | 1    |
| 2.GENEL BİLGİLER .....                                                   | 3    |
| 2.1 Yapay Sinir Ağları .....                                             | 3    |
| 2.2 Yapay Sinir Ağlarının Özellikleri .....                              | 3    |
| 2.3 Yapay Sinir Ağlarının Yapısı ve Bileşenleri.....                     | 4    |
| 2.4 Yapay Sinir Ağlarının Mimari Yapılarına Göre Sınıflandırılması ..... | 7    |

## İÇİNDEKİLER (devam)

### Sayfa

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| 2.4.1 İleri Beslemeli Yapay Sinir Ağları .....                                              | 7  |
| 2.4.2 Geri Beslemeli Yapay Sinir Ağları .....                                               | 8  |
| 2.5 Yapay Sinir Ağlarında Öğrenme Kuralları .....                                           | 9  |
| 2.6 Önceki Çalışmalar .....                                                                 | 11 |
| 2.6.1 Yapay Sinir Ağlarının Gama Spektral Analize Uygulanması ile İlgili Çalışmalar.....    | 11 |
| 2.6.2 Yapay Sinir Ağlarının İstatiksel Araç Olarak Kullanılması ile İlgili Çalışmalar ..... | 17 |
| 3. MATERYAL VE METOT .....                                                                  | 19 |
| 3.1 Çalışmada Kullanılan Gama Spektrometrik Sistemler .....                                 | 19 |
| 3.1.1 HPGe Gama Spektrometrik Sistem .....                                                  | 19 |
| 3.1.2 NaI(Tl) Gama Spektrometrik Sistem .....                                               | 20 |
| 3.2 Çalışılan Örneklerin Tanımlanması .....                                                 | 20 |
| 3.3 Gama Spektroskopisiyle Jeolojik Örneklerde Uranyum-Toryum-Potasyum Tayini .....         | 21 |
| 3.3.1 Duyarlılık Faktörleri ( $K_1$ , $K_2$ ve $K_3$ )' nin elde edilmesi .....             | 26 |

## İÇİNDEKİLER (devam)

### Sayfa

|                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------|----|
| 3.4 Çalışmada Kullanılan Yapay Sinir Ağları .....                                                      | 28 |
| 3.4.1 İleriye Beslemeli Geriye Yayımlı Yapay Sinir Ağları .....                                        | 28 |
| 3.4.2 Radyal Tabanlı Yapay Sinir Ağları (RTYSA).....                                                   | 30 |
| 4. DENEYSEL BULGULAR VE TARTIŞMA .....                                                                 | 32 |
| 4.1 Enerji Kalibrasyonu .....                                                                          | 32 |
| 4.2 Minimum Dedekte Edilebilir Aktivite (MDA) Değerlerinin Bulunması .....                             | 36 |
| 4.2.1 $^{232}\text{Th}$ için Minimum Dedekte Edilebilir Aktivite (MDA) Değerlerinin Bulunması.....     | 37 |
| 4.2.2 $^{238}\text{U}$ için Minimum Dedekte Edilebilir Aktivite (MDA) değerlerinin bulunması .....     | 39 |
| 4.2.3 $^{40}\text{K}$ için Minimum Dedekte Edilebilir Aktivite (MDA) değerlerinin bulunması .....      | 40 |
| 4.3 YSA'nın NaI(Tl) Sintilasyon Gama Spektroskopisinde Doğal Radyonüklit Analizlerine Uygulanması..... | 42 |
| 4.3.1 Toryumu elde etmek için geliştirilen 1. Model (RTANN-1).....                                     | 53 |
| 4.3.2 Uranyumu elde etmek için geliştirilen 2. Model (RTANN-2).....                                    | 54 |
| 4.3.3 Potasyumu elde etmek için geliştirilen 3. Model (RTANN-3).....                                   | 55 |
| 4.3.4 Toryum, Uranyum ve Potasyumu birlikte elde etmek için geliştirilen 4. Model (RTANN-4).....       | 57 |

**İÇİNDEKİLER (devam)**

|                            | <u>Sayfa</u> |
|----------------------------|--------------|
| 5. SONUÇ VE ÖNERİLER ..... | 71           |
| KAYNAKLAR DİZİNİ .....     | 75           |
| TEŞEKKÜR .....             | 84           |
| ÖZGEÇMİŞ .....             | 85           |



## ŞEKİLLER DİZİNİ

| <u>Şekil</u>                                                              | <u>Sayfa</u> |
|---------------------------------------------------------------------------|--------------|
| 2.1 YSA'nın beş bileşeni (Yurdakul 2014) .....                            | 5            |
| 2.2 Aktivasyon fonksiyonu örnekleri (Tüzen, 2012) .....                   | 7            |
| 2.3 Tipik ileri beslemeli YSA mimarisi (Kılıç, 2011) .....                | 8            |
| 2.4 Tipik geri beslemeli YSA mimarisi (Kılıç, 2011) .....                 | 9            |
| 3.1 Çalışmada kullanılan HPGe gama spektrometre sistemi .....             | 19           |
| 3.2 Çalışmada kullanılan NaI(Tl) gama spektrometre sistemi .....          | 20           |
| 3.3 Th, U ve K kanallarına gelen katkılar (Yaprak, 1995).....             | 22           |
| 3.4 Potasyum (a), Uranyum (b) ve Toryum (c) kanalları (Yaprak, 1995)..... | 24           |
| 3.5 Duyarlılık Faktörü $K_1$ .....                                        | 26           |
| 3.6 Duyarlılık Faktörü $K_2$ .....                                        | 27           |
| 3.7 Duyarlılık Faktörü $K_3$ .....                                        | 27           |
| 3.8 Tipik radyal tabanlı yapay sinir ağı (Okkan ve Dalkılıç, 2012) .....  | 30           |
| 4.1 Set1 için elde edilen YSA sonuçlarının grafiksel gösterimi .....      | 34           |
| 4.2 Set2 için elde edilen YSA sonuçlarının grafiksel gösterimi .....      | 35           |

## ŞEKİLLER DİZİNİ (devam)

| Şekil                                                                                                                                                                  | Sayfa |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------|
| 4.3 $^{232}\text{Th}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin eğitme verileri için karşılaştırılması .....                                               | 38    |
| 4.4 $^{232}\text{Th}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin test verileri için karşılaştırılması .....                                                 | 38    |
| 4.5 $^{238}\text{U}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin eğitme verileri için karşılaştırılması .....                                                | 39    |
| 4.6 $^{238}\text{U}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin test verileri için karşılaştırılması .....                                                  | 40    |
| 4.7 $^{40}\text{K}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin eğitme verileri için karşılaştırılması .....                                                 | 41    |
| 4.8 $^{40}\text{K}$ 'in için hesaplanan ve tahmin edilen MDA değerlerinin test verileri için karşılaştırılması .....                                                   | 41    |
| 4.9 Eğitimde kullanılan örnekler için hesaplanan $^{232}\text{Th}$ değerlerinin RTANN-1 modelinden tahmin edilen $^{232}\text{Th}$ değerleriyle karşılaştırılması..... | 54    |
| 4.10 Testte kullanılan örnekler için hesaplanan $^{232}\text{Th}$ değerlerinin RTANN-1 modelinden tahmin edilen $^{232}\text{Th}$ değerleriyle karşılaştırılması ..... | 54    |
| 4.11 Eğitimde kullanılan örnekler için hesaplanan $^{238}\text{U}$ değerlerinin RTANN-2 modelinden tahmin edilen $^{238}\text{U}$ değerleriyle karşılaştırılması.....  | 55    |
| 4.12 Testte kullanılan örnekler için hesaplanan $^{238}\text{U}$ değerlerinin RTANN-2 modelinden tahmin edilen $^{238}\text{U}$ değerleriyle karşılaştırılması .....   | 55    |

## ŞEKİLLER DİZİNİ (devam)

| <u>Şekil</u>                                                                                                                                                             | <u>Sayfa</u> |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------|
| 4.13 Eğitimde kullanılan örnekler için hesaplanan $^{40}\text{K}$ değerlerinin RTANN-3 modelinden tahmin edilen $^{40}\text{K}$ değerleriyle karşılaştırılması .....     | 56           |
| 4.14 Testte kullanılan örnekler için hesaplanan $^{40}\text{K}$ değerlerinin RTANN-3 modelinden tahmin edilen $^{40}\text{K}$ değerleriyle karşılaştırılması .....       | 56           |
| 4.15 Eğitimde kullanılan örnekler için hesaplanan $^{232}\text{Th}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{232}\text{Th}$ değerleriyle karşılaştırılması ..... | 58           |
| 4.16 Testte kullanılan örnekler için hesaplanan $^{232}\text{Th}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{232}\text{Th}$ değerleriyle karşılaştırılması .....   | 58           |
| 4.17 Eğitimde kullanılan örnekler için hesaplanan $^{238}\text{U}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{238}\text{U}$ değerleriyle karşılaştırılması .....   | 59           |
| 4.18 Testte kullanılan örnekler için hesaplanan $^{238}\text{U}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{238}\text{U}$ değerleriyle karşılaştırılması .....     | 59           |
| 4.19 Eğitimde kullanılan örnekler için hesaplanan $^{40}\text{K}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{40}\text{K}$ değerleriyle karşılaştırılması .....     | 60           |
| 4.20 Testte kullanılan örnekler için hesaplanan $^{40}\text{K}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{40}\text{K}$ değerleriyle karşılaştırılması .....       | 60           |

## TABLOLAR DİZİNİ

| <u>Tablo</u>                                                                                                                                                                                                                                       | <u>Sayfa</u> |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------|
| 2.1 Toplama fonksiyonu örnekleri (Öztemel, 2006; Tüzen, 2012) .....                                                                                                                                                                                | 6            |
| 3.1 Çalışmada kullanılan örnekler .....                                                                                                                                                                                                            | 21           |
| 3.2 Sıyırılma Oranları ( $\alpha$ , $\beta$ ve $\gamma$ ) (Yaprak, 1995) .....                                                                                                                                                                     | 24           |
| 3.3 Duyarlılık Faktörleri ( $K_1$ , $K_2$ ve $K_3$ ) (Yaprak, 1995) .....                                                                                                                                                                          | 25           |
| 4.1 Kullanılan radyonüklitlerin enerjileri.....                                                                                                                                                                                                    | 33           |
| 4.2 Set1 için elde edilen YSA çıktıları .....                                                                                                                                                                                                      | 34           |
| 4.3 Set2 için elde edilen YSA çıktıları .....                                                                                                                                                                                                      | 35           |
| 4.4 $^{238}\text{U}$ , $^{232}\text{Th}$ ve $^{40}\text{K}$ radyonüklitleri için MDA Değerleri.....                                                                                                                                                | 37           |
| 4.5 YSA'dan elde edilen MDA değerleri ile hesaplanan MDA değerlerinin karşılaştırılmasından elde edilen $R^2$ ve RMSE değerleri.....                                                                                                               | 42           |
| 4.6 İncelenen örnekler içindeki hesaplanan $^{232}\text{Th}$ , $^{238}\text{U}$ ve $^{40}\text{K}$ konsantrasyonları..                                                                                                                             | 43           |
| 4.7 Geliştirilen RTANN-1, RTANN-2 ve RTANN-3 modellerinin performans indisleri.....                                                                                                                                                                | 57           |
| 4.8 Eğitimde kullanılan örnekler için hesaplanan $^{232}\text{Th}$ , $^{238}\text{U}$ ve $^{40}\text{K}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{232}\text{Th}$ , $^{238}\text{U}$ ve $^{40}\text{K}$ değerleriyle karşılaştırılması..... | 61           |
| 4.9 Testte kullanılan örnekler için hesaplanan $^{232}\text{Th}$ , $^{238}\text{U}$ ve $^{40}\text{K}$ değerlerinin RTANN-4 modelinden tahmin edilen $^{232}\text{Th}$ , $^{238}\text{U}$ ve $^{40}\text{K}$ değerleriyle karşılaştırılması.....   | 67           |
| 4.10 Geliştirilen RTANN-4 modelinin performans indisleri.....                                                                                                                                                                                      | 69           |

## SİMGELER VE KISALTMALAR DİZİNİ

| <u>Simgeler</u>    | <u>Açıklama</u>                         |
|--------------------|-----------------------------------------|
| $f(x)$             | Aktivasyon fonksiyonu                   |
| $\Sigma$           | Toplama fonksiyonu                      |
| $Q$                | Eşik değeri                             |
| $X$                | Girdi                                   |
| $W$                | Ağırlık                                 |
| $\Delta W$         | Ağırlıktaki değişim miktarı             |
| <u>Kısaltmalar</u> |                                         |
| EDXRF              | Enerji dağılımlı X-ışını spektroskopisi |
| HPGe               | Yüksek saflıkta germanyum               |
| MAE                | Ortalama mutlak hata                    |
| MDA                | Minimum detekte edilebilen aktivite     |
| NaI(Tl)            | Sodyum iyodür                           |
| PBR                | Pikin backgrounda oranı                 |
| PIXE               | Proton kaynaklı X-ışını emisyonları     |
| RMSE               | Ortalama karesel hata kökü              |
| XRF                | X-ışını floresans                       |
| YSA                | Yapay sinir ağları                      |



## 1.GİRİŞ

İnsan beyninin işleyişinden esinlenerek geliştirilen yapay sinir ağları (YSA), öğrenme, genelleştirme vb. üstün özelliklerinden dolayı, kompleks sorunların çözümünde ampirik yöntemlere kıyasla daha sıklıkla kullanılmaktadır. Ayrıca, istatistiksel araç olarak veri işlemede de kullanılan YSA, son zamanlarda nükleer spektroskopide kullanılmaktadır (Kucuk and Kucuk, 2006). Nükleer spektroskopide YSA'nın çeşitli uygulamaları vardır, örn. gama spektroskopisi, alfa spektroskopisi, pik-background oranı, puls şekilli dedektörlerin çözünürlük iyileştirmesi, proton kaynaklı X-ışını emisyonları, X-ışını flüoresan ve Rutherford geri saçılma. Yoshida et al. (2002), HPGe dedektöründen elde edilen gama spektrumunun analizine, YSA'yı başarıyla uygulamıştır. Son zamanlarda, HPGe spektrum analizinde hesaplama yöntemi olarak kullanılsa da, NaI(Tl) sintilasyon gama spektroskopisi ile uygulamaları çok sınırlıdır.

YSA'nın avantajlarını ve nükleer spektroskopide kullanımını göz önüne alarak, bu çalışmada ilk olarak Nükleer Bilimler Enstitüsü sayım laboratuvarında bulunan HPGe dedektörü kullanılarak, gama spektral analizi için YSA uygulanmıştır. Geliştirilen YSA modelinin performansı, Çandarlı kıyı sedimenti örneklerinin gama spektral analizi ile test edilmiştir. YSA ile örnekler içerisindeki radyonüklitlerin varlıkları başarıyla tespit edilmiştir.

İkinci olarak, YSA, NaI(Tl) Sintilasyon Gama Spektrometre sisteminin değişik sayım sürelerinde ölçebileceği minimum dedekte edilebilir aktivite (MDA)'leri bulmak için kullanılmıştır. Bu amaçla, Enstitüde kullanılan sayım süreleri dikkate alınarak, 5000- 87000s arası,  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitleri için, MDA değerleri, Curie kriterlerine dayalı olarak hesaplanmıştır. YSA'dan elde edilen MDA değerleri ile hesaplanan MDA değerleri karşılaştırıldığında, birbirleriyle örtüştüğü görülmüştür.

Son olarak, YSA, NaI(Tl) sintilasyon gama spektroskopisi ile doğal radyonüklit analizleri için uygulanmıştır. Bu amaçla, 126 adet değişik orijinli çevresel materyal; kayaç, toprak, granit, mermer ve gübre örneklerinin ölçümü yapılmıştır. 10000s sayım süresi için radyometrik (IAEA orijinli) ,  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  standartları kullanılarak duyarlılık ve sıyırma katsayıları hesaplandıktan sonra, aynı sayım süresi için bütün örnekler sayılarak konvansiyonel analiz tekniği ile bütün örnekler içerisindeki uranyum, toryum ve potasyum konsantrasyonları hesaplanmıştır. Hesaplanan aktivite değerleri, YSA modelinden tahmin edilen

değerlerle karşılaştırıldığında, YSA'nın örneklerdeki  $^{238}\text{U}$ ,  $^{232}\text{Th}$ , ve  $^{40}\text{K}$  aktivitelerini doğru bir şekilde tahmin edebildiği görülmüştür.



## 2. GENEL BİLGİLER

### 2.1 Yapay Sinir Ağları

1950'li yıllarda bilim insanları, alışagelmış çözüm yöntemlerini kullanmak yerine, doğada ki olayların bir kısmını bilgisayarda modelleyerek çözümlemeye yönelmişler ve böylelikle literatürde "Yapay Zeka" kavramının ortaya çıkmasına neden olmuşlardır (Ardıç, 2014). Yapay zekanın alt dallarından biri olan yapay sinir ağları (YSA), beyinin öğrenme özelliğini göz önünde bulundurarak, ağa sunulan girdi bilgilerini öğrenmekte ve daha sonra öğrenilen bilgilerden hedeflenen çıktılara ulaşabilmektedir. Bu nedenle, öğrenme ve öğrenme sonrası genelleştirme yapabilme özellikleri, YSA'nın en önemli özellikleridir.. Bu özelliklerle, YSA, herhangi bir problemi yada karşılaşılan durumu, ağa sunulan verilerden öğrenmekte ve böylelikle daha önce rastlaşmadığı problemler için yeni sonuçlar elde etmektedir.(Garip, 2005). Bu özelliklerinden dolayı, YSA pratik uygulamalarda kullanılmaya başlanmış ve halen kullanılmaya devam edilmektedir.

### 2.2 Yapay Sinir Ağları (YSA)'nın Özellikleri

YSA'nın literatürde yaygın olarak kullanılmasına sebep olan özellikleri aşağıda verilmiştir.

**Doğrusal olmama:** Yapısı gereği doğrusal olan YSA'nın doğrusal olup olmaması durumu, ağda kullanılacak olan transfer fonksiyonu ile belirlenir. Böylelikle, YSA her iki durum içinden analiz edilecek probleme çözüm üretebilmektedir.

**Öğrenme:** YSA'nda öğrenme, bir probleme ait olan girdi ve çıktı değerleri arasındaki ilişkiye en uygun olan ağırlık değerlerinin bulunması olarak tarif edilir. Modellenecek problem için YSA, bu probleme ait girdi-çıktı veri çiftlerinden oluşan bir eğitim kümesi ile eğitilir. YSA'nın ürettiği çıktı değerleri ile hedef değerleri kullanılarak hesaplanan fark minimum oluncaya kadar ağ yapısında bulunan bağlantı ağırlıkları değiştirilerek ağın eğitimine devam edilir. Öğrenme süreci sonunda, optimum ağırlık değerleri bulunmuş olur (Gulhan, 2005)

**Genelleştirme:** YSA'nın eğitme işlemi bittikten sonra, daha önce hiç karşılaşmadığı girdi verileri içinde uygun çıktı değerleri üretebilmesine genelleştirme yeteneği olarak adlandırılmaktadır (Bahadır, 2013). YSA'nın eğitmede karşılaşmamış olduğu girdi değerlerine karşılık bulduğu çıktı değerlerinin uygun olup olmadığının kontrolü için, YSA'dan üretilen çıktı değerleriyle hedef

değerleri karşılaştırılır. Bu karşılaştırmadan elde edilen hata miktarının daha önceden belirlenen bir hata oranı içerisinde olması beklenilmektedir. YSA, bu özelliği sayesinde, tahmin, örüntü tanıma, sınıflandırma vb. birçok alanda başarıyla uygulanmaktadır (Hamzaçebi, 2011; Bahadır, 2013).

**Uyarlanabilirlik:** Belirli bir probleme ait girdi verilerin ağı sunulmasıyla oluşturulan YSA, farklı bir problemle karşılaşıldığında, bu probleme adapte edilebilir ve tekrar eğitime işlemi yapılabilir. (Wei, 2000; Bahadır, 2013)

**Hata toleransı:** YSA'nın eğitime aşamasına, bağlantı ağırlıklarının değerleri belirlenir. Bazen ağı sunulan girdiler, gürültü etkisi olarak isimlendirilen beklenmeyen hatalar içerebilir ve bu hatalar, ağıdaki bütün ağırlıklara dağıtılması nedeniyle, çıktı üzerindeki etkileri azaltılmış olur (Bahadır, 2013). Bu nedenle, YSA'nın hata toleransı, alışagelmış metotlara kıyasla daha fazla olmaktadır (Wei, 2000; Bahadır, 2013).

**Eksik bilgi ile çalışabilme:** YSA, eğitime sonrası, ağı sunulan yeni verilerde eksik bilgi olmasını göz ardı ederek çalışabilirler ve bu çalışma sonucu elde edilen performans, eksik olan bilginin mahiyetine göre farklılık gösterir. Oluşturulan ağı performansında bir değişiklik olmaması durumunda, eksik olan bilginin önemli olmadığı ortaya çıkar (Öztemel, 2006). Ağı performansında bir azalma olması durumunda ise eksik bilginin önemli olduğunu gösterir (Bahadır, 2013).


**Analiz ve tasarım kolaylığı:** YSA'nın nöronlardan meydana gelen tipik yapısı, oluşturulacak olan tüm YSA modellerinin yapıları ile benzerdir ve böylelikle bu modellerde tipik yapıda olduğu gibi nöronlardan oluşacaktır. Bu sebeple, değişik uygulamalarda, benzer öğrenme algoritmalarını kullanılarak yeni YSA'ları kolayca tasarlanabilir. Bu tasarım kolaylığı, karşılaşılan problemlerin YSA ile analizinde, büyük ölçüde basitlik sağlayacaktır (Baykan, 2007; Bahadır, 2013).

### 2.3 Yapay Sinir Ağlarının Yapısı ve Bileşenleri

YSA, yapay sinir hücresi (nöron) olarak adlandırılan işlem elamanlarının tabakalar halinde yerleştirilmesiyle oluşturulur. YSA, bir girdi tabakası, bir veya birden çok gizli (saklı) tabaka ve çıkış tabakasından oluşmaktadır. İlk katman olan girdi tabakasında ve son katman olan çıkış katmanında, modelleme de kullanılacak probleme ait veriler yer almaktadır ve bu sebeple, bu katmanlardaki nöronların sayıları bu verilere bağlıdır. Girdi tabakasında, ağı sunulan veri, ağı içerisinde bağlantılarla saklı katmana iletilir. İletilen bu veri, saklı ve çıkış katmanlarında

işlenerek, dış ortama çıktı olarak çıkar. Her katmandaki sinir hücrelerine, sadece, kendisinden önce yer alan katmandaki hücrelerden veri aktarımına müsaade edilir. Saklı katmanları bulunmayan YSA, karmaşık problemleri modellemede yetersiz kalmaktadır ve bu yüzden, bu problemleri modellemek için oluşturulan ağlarda, minimum bir saklı tabaka kullanılmasına ihtiyaç duyulmaktadır. Oluşturulacak modeldeki saklı tabaka sayısı ve bu saklı tabalardaki saklı nöronların sayısı modellenecek problemin karmaşıklık derecesine bağlı olmakla birlikte yapılan denemelerle bulunmaktadır. (Kumanlıoğlu, 2010).

Şekil 2.1 'de, beş bileşenden oluşan bir YSA gösterilmiştir. YSA'nın bu beş bileşeni aşağıda kısaca verilecektir.



Şekil 2.1. YSA'nın beş bileşeni (Yurdakul, 2014).

**Girdiler:** Girdiler ( $X$ ), bir YSA modelinde çözümünü yapılacak olaya ait ağa sunulan verileri içerir. Girdilerin işlevleri, sunulan bu verilerin üzerinde hiç bir matematiksel işlem yapmadan bir sonraki katmana aktarmaktır.

**Ağırlıklar:** Ağırlıklar ( $W_{ij}$ ), ağa sunulan girdilerin nöronlar üzerindeki etkisini belirten katsayılarıdır (Tüzen, 2012).

**Toplama Fonksiyonu:** Toplama fonksiyonu (birleştirme fonksiyonu) kullanılarak, bir nörona iletilen net girdileri hesaplanır. Toplama fonksiyonunun örnekleri Tablo 2.1'de verilmiştir. Toplama fonksiyonu, genellikle bir nörondaki

her bir giriş ile bu girişe ait ağırlıkların çarpılarak, bu çarpımların toplanması ile elde edilir ve matematiksel ifadesi aşağıdaki gibidir (Haykin, 2005).

$$Net\ Toplam = \sum_{i=1}^n X_i W_{ij} \quad (2.1)$$

Ancak bir çok uygulamada,  $Q$  olarak ifade edilen eşik değeri de denkleme dahil edilmiştir. Bu durumda,


$$Net\ Toplam = \sum_{i=1}^n X_i W_{ij} + Q_j \quad \text{veya} \quad Net\ Toplam = \sum_{i=1}^n X_i W_{ij} + Q_j$$

şeklinde ifade edilir.

Tablo 2.1. Toplama fonksiyonu örnekleri (Öztemel, 2006; Tüzen, 2012).

| Net Giriş                                                              | Açıklama                                                                                                                                                      |
|------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Toplam</b><br>$Net\ Girdi = \sum_i^n G_i A_i$                       | Her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır ve böylece net girdi bulunur.                                                                   |
| <b>Çarpım</b><br>$Net\ Girdi = \prod_i G_i A_i$                        | Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.                                        |
| <b>Maksimum</b><br>$Net\ Girdi = Max(G_i A_i), i=1, \dots, N$          | N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.                                      |
| <b>Minimum</b><br>$Net\ Girdi = Min(G_i A_i), i=1, \dots, N$           | N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.                                      |
| <b>Çoğunluk</b><br>$Net\ Girdi = \sum_i^n sgn(G_i A_i)$                | N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir. |
| <b>Kümülatif Toplam</b><br>$Net\ Girdi = Net(eski) + \sum_i^n G_i A_i$ | Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.                                         |

**Transfer Fonksiyonu:** Transfer fonksiyonu, nörona aktarılan net toplamı işleyerek nöronun bu toplam için üreteceği çıktıyı verir. Aktivasyon fonksiyonu, doğrusal ya da doğrusal olmayan fonksiyon olabilir. Modellenecek problem için en uygun fonksiyonun hangisi olup olmadığı denemelerle bulunur (Kasaplı, 2014). Transfer fonksiyonunun gayesi, çıktıların üretilmesinde öğrenme aşamasının hızlanmasını önleyerek, çıktıların büyük değerlerde elde edilmesini engellemektir. Literatürde sıklıkla tercih edilen transfer fonksiyonların bazıları, Şekil 2.2’de gösterilmiştir (Öztemel, 2006).



Şekil 2.2. Aktivasyon fonksiyonu örnekleri (Tüzen, 2012).

**Çıktı:** Transfer fonksiyonu kullanılmasıyla bulunan değerlerdir. YSA'dan elde edilen çıktı değerleri, hedef değerler ile mukayese edilerek hata hesaplanır ve bu hata kabul edilebilecek değere varana kadar, ağı eğitme işlemi sürdürülür.


## 2.4 Yapay Sinir Ağlarının Mimari Yapılarına Göre Sınıflandırılması

YSA'da, nöronlar ve nöronların arasındaki bağlantıları çok farklı biçimlerde oluşturulabilir ve bu nedenle, oluşturulan ağ yapıları, nöronlar ve bağlantılar arasındaki mimari yapıya göre farklı adlandırılmaktadır. (Gulhan, 2005). Bu nedenle, YSA, akış yönleri ya da beslenme şekilleri göz önünde bulundurularak ikiye ayrılmakta ve ilgili ağlar aşağıda anlatılacaktır.

### 2.4.1 İleri Beslemeli Yapay Sinir Ağları

Literatürde sıklıkla kullanılan ağlardan biri olan ileri beslemeli yapay sinir ağları, nöronların (işlem elamanlarının), katmanlar halinde bir araya gelmelerinden oluşturulmaktadır. Bu sinir ağları, genellikle, bir girdi katmanı, bir ve/veya birden fazla gizli katmanları ve bir çıktı katmanı olmak üzere üç katmandan oluşturulur. İleri beslemeli YSA'nın girdi katmanındaki nöronlardan sunulan veriler, çıktı katmanına doğru tek yönlü olan bağlantılar ile aktarılmaktadır. Bir girdi, iki gizli

ve bir çıktı katmanından oluşturulan ileri beslemeli sinir ağının mimarisi Şekil 2.3'de verilmiştir. (Kılıç, 2011).




Şekil 2.3. Tipik ileri beslemeli YSA mimarisi.

İleri beslemeli bir YSA'nın eğitime aşamasında, dış ortamdan gelen veriler YSA'nın birinci katmanı olan girdi katmanından ağına sunulur. YSA, girdi katmanındaki nöronların çıktı değerlerini hesaplayarak, bir sonraki gizli katmana girdi değeri olarak iletirler (Kılıç, 2011). Daha sonra, gizli katmana iletilen bu değerlere göre, YSA, çıktı değerleri üretmekte ve üretilen çıktı değerlerini çıktı katmanından dış dünyaya sunmaktadır. İleri beslemeli YSA, girdi verilerine karşılık hızlı bir şekilde çıktıları üretebilmektedir. Bu ağlara, Rumelhart ve McClelland (1986) ağları emsal olarak verilebilir (Afsar, 2008).

#### 2.4.2 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli YSA'da, çıkışı ve gizli katmanlardaki çıkışlar, giriş katmanına veya önceki gizli katmana aktarılır. Bir girdi, iki gizli ve bir çıktı katmanından oluşturulan ileri beslemeli sinir ağının mimarisi Şekil 2.4'de verilmiştir. İleri beslemeli YSA'nın dinamik bir hafızaya sahiptir. Bu özelliğiyle, ileri beslemeli ağdaki nöronların çıkışı, yalnızca o andaki giriş değerlerine bağlı olmamakla birlikte önceki giriş değerlerine de bağlı olmaktadır. İleri beslemeli ağlara emsal olarak, Hopfield (1982) ve Elman (1990) ağları verilebilir (Afsar, 2008; Kılıç, 2011). Dinamik hafızasından dolayı, ileri beslemeli YSA, özellikle ön tahmin işlemlerinde başarıyla uygulanmaktadır.



Şekil 2.4. Tipik geri beslemeli YSA mimarisi (Kılıç, 2011).

## 2.5 Yapay Sinir Ağlarında Öğrenme Kuralları

YSA'nın eğitiminde, farklı stratejilere sahip çeşitli öğrenme metotları kullanılmakta ve bu metotlar ağ performansını önemli ölçüde etkilemektedir (Bahadır, 2013). Öğrenme aşamasındaki hedef, ağa sunulan verilere göre bulunması gereken doğru sonuçlara en yakın çıktıları elde edebilmektir. Bu sebeple, YSA, ağa sunulan girdilere, model oluşturulurken seçilen YSA mimarisine de uygun olarak işlemler yaptıktan sonra, çıktıları üretir. Eğitim aşamasında, bütün verilerin ağ içinde bir kez işleminden geçmesi, bir devir (epoch) olarak isimlendirilir. Devir sayısının az ya da çok seçilmesi, ağın öğrenme sürecinde, YSA'nın performansını önemli ölçüde etkilemektedir. Örneğin, bir YSA modelini oluştururken devir sayısının oldukça yüksek seçilmesi YSA'nın performansını önemli ölçüde düşürmektedir. Bir YSA' da hata, YSA'dan elde edilen çıktı değerleri ile daha önceden belirlenen hedef değerleri arasındaki farktır. Bir YSA'nın eğitime aşamasında işlemler, ağın ürettiği çıktılarına göre hesaplanan hata değerini kabul edilebilir sınırlar içerisinde kalana kadar tekrarlanır.

YSA'nın veri ve hedef değerleri arasındaki ilişkiyi öğrenmesi, ilgili probleme ait örnekler kullanılarak deneme yanılma ile ağ ağırlıklarının en uygun değerlerinin tespit edilmesi olarak tanımlanabilir. Aşağıda verilen denklemde, herhangi bir ağırlık ( $W$ ) için, YSA'nın öğrenmesi matematiksel olarak gösterilmektedir. (Bahadır, 2013).

$$W_{yeni} = W_{eski} + \Delta W \quad (2.2)$$

Denklem 2.2'deki  $\Delta W$  değeri, belirli bir kurala göre hesaplanan mevcut ağırlık değerlerindeki değişim miktarıdır.  $\Delta W$ 'yi hesaplamak için tanımlanmış kurallara, öğrenme kuralları olarak adlandırılır. Literatürde eğitime aşamasında kullanılacak birçok öğrenme algoritması geliştirilmiştir. Geliştirilen bu algoritmaların çoğu, matematiksel tabanlı olup YSA'daki ağırlıkların yenilenmesi amacıyla kullanılırlar. Literatürde sıklıkla kullanılan öğrenme kuralları şunlardır:

**Hebb Kuralı:** Donald Hebb (1949) tarafından geliştirilen en eski ve en basit öğrenme algoritması olan Hebb Kuralı, diğer öğrenme kurallarının da temelini oluşturur. Bu öğrenme kuralına göre, bir nöron diğer bir nörondan girdi alırsa ve eğer her iki nöronda matematiksel olarak aynı işareti taşıyorsa, bu iki nöron arasındaki ağırlık artırılır (güçlendirilir) ve tam tersi durumda ise azaltılır (zayıflatılır).

**Hopfield Kuralı:** Hebb (1949) kuralına benzeyen Hopfield (1998) kuralı, YSA nöronların arasındaki ağırlıkların hangi oranda artırılmasının veya azaltılmasının gerekliliğini gösterir. YSA'nın ürettiği çıktılar ve programa sunulan girdilerin aktif yada pasif olması halinde, ağırlıkların artırılması ya da azaltılması öğrenme katsayısı kullanılarak yapılır. Öğrenme katsayısı, model oluşturulmadan önce, kullanıcı tarafından belirlenen ve sıklıkla 0 ile 1 arasında olan sabit olan bir değerdir.

**Delta Kuralı:** Günümüzde en çok bilinen ve çok yaygın kullanılan öğrenme kuralıdır. Bu kuralda, hedef değeri ile YSA'dan elde edilen çıktı değerleri arasındaki farkı azaltmak için, YSA'daki nöronların bağlantılarının ağırlık değerleri sürekli olarak yeniden hesaplanır. Bu hesaplamalar, gerçek çıktı ile elde edilen çıktı arasındaki hata karelerinin ortalamasını en aza indirebilmek amacıyla yapılır. Hesaplanan hatalar, YSA'nın son katmanı olan çıktı katmandan geriye doğru ardışık iki katman arasındaki bağlantı ağırlıklarına dağıtılır ve bu işleme hatanın geriye dağıtılması anlamına gelen geri besleme işlemi denir. Bu çalışmada kullanılan geriye yayılım (back propogation) algoritması da, Delta Kuralına göre hataları azaltmaktadır.

**Kohonen Kuralı:** Biyolojik sinir hücrelerinin öğrenme kurallarından esinlenerek geliştirilen bu kuralda, nöronlar ağırlıkları değiştirmek için birbirleri ile yarışır ve en büyük çıktıyı üreterek nöron yarışı kazanan nöron bağlantı ağırlıklarını değiştirir. Böylelikle, yarışı kazanan nöron yakınındaki nöronlara kıyasla daha kuvvetli bir duruma gelmektedir (Öcal, 2007). Bu kuralda, bir hedef

değerler dizisi olmadığından, eğitim süreci kendi kendine (danışmansız) olarak tamamlanır.

**Levenberg Marquardt Öğrenme Kuralı:** Hızlı ve yüksek performansından dolayı, kullanıcılar tarafından sıklıkla tercih edilen popüler öğrenme algoritmasıdır. Bu algoritmada, hata değeri hesaplandıktan sonra, nöronlar kendi hatalarını azaltmak amacıyla ağırlıklarını ayarlamak durumundadır. Hızlı öğrenme ve iyi yakınsayabilme özelliğine sahip olan bu öğrenme kuralı, maksimum komşuluk fikri üzerine kurulmuş en az kareler hesaplama algoritmasıdır. Bu algoritmada, hedef ve çıktı değerleri kullanılarak hesaplanan hata değeri, yapılan iterasyon sonunda hata yüzeyine parabolik olarak yakınsar ve parabolün minimumu o iterasyon için çözümü oluşturur.

## 2.6 Önceki Çalışmalar

### 2.6.1 Yapay sinir ağlarının gama spektral analize uygulanması ile ilgili çalışmalar

Yapay Sinir Ağları (YSA) yöntemi, gama ışını spektrumlarının analizi için geleneksel yöntemlere kıyasla birçok avantaj sağlamıştır. Yaygın otomatik spekturum analiz yöntemleriyle karşılaştırıldığında, YSA, tam paralel hesaplama kullanır, uygulamak kolaydır ve doğrusal olmayanları içerir. Bu yaklaşım, makul bir doğrulukla hızlı bir cevap gerekli olduğunda yararlı görünmektedir. Tehlikeli ortamlarda, otomatik model tanıma sistemleri (sinir ağları gibi), geleneksel örnekleme ve laboratuvar analiz yöntemlerine göre belirgin bir avantaja sahiptir; çünkü çevre, insan operatörleri için risk olmadan izlenebilir.

YSA'nın nükleer fiziğe uygulanması, esas olarak hızlandırıcılar ve nükleer reaktörler ile ilgili problemlerde artmıştır (Castin et al., 2011; Eendebak et al., 2011; Mól et al., 2011; Santhosh et al., 2011; Freeman et al., 2012)

Nükleer spektroskopide YSA'nın çeşitli uygulamaları vardır, örn. alfa spektroskopisi (Baeza et al., 2011; Jimenez et al., 2012). Alfa spektrumlarının analizi, spektrumda alfa piklerini ayırt edebilmek için iyi radyokimyasal prosedürler gerektirir ve bunları analiz etmenin en kolay yolu doğrudan ilgili bölgede elde edilen sayımların toplanmasıdır. Bununla birlikte, alfa zirvelerinin düşük enerjili kuyrukları sıklıkla bu basit yaklaşımı işe yaramaz hale getirir çünkü bazı pik zirveleri kısmen üst üste gelir. Bu sorunu çözmek için birçok fit uydurma prosedür önerilmiştir ki, bir çoğu teorik alfa zirvesinin şeklini taklit eden yarı deneysel matematiksel fonksiyonlara dayanır. Bu yöntemlerin temel dezavantajı,

kullanılan çok sayıda fit uydurma parametrenin, fiziksel anlamlarının belirsiz ya da tamamen eksik olduğu anlamına gelmesidir. Baeza et al., (2011) çalışmalarında yeni bir yaklaşım olan YSA'yı önermişlerdir. Deneysel verileri matematiksel bir fonksiyona oturtmak yerine, alfa piki zirvesinin şeklini modellemek için daha önce laboratuvarlarında analiz edilen gerçek numunelerden elde edilen bir çok polonyum spektrumunu bir model olarak kullanan, eğitilmiş bir yapay sinir ağı (YSA) kullanmışlardır. Bu anlamda YSA, gerçek alfa piki zirvesinin şeklini öğrenebilir. Çalışmada geri beslemeli algoritmaya dayanan eğitimi ile ileri beslemeli çok katmanlı YSA modeli tasarlanmıştır. Pik uydurma prosedürü, alfa piki zirvelerinin karakteristiği olan deneysel gözlemlere dayanır. Polonyum izotop spektrumları seçilmiştir, çünkü  $Po^{208}$ ,  $Po^{209}$  ve  $Po^{210}$  na karşılık gelen alfa zirveleri tek enerjilidir ve birbirlerinden iyi ayrılmıştır. Bu fit uydurma prosedürünün getirdiği belirsizlikler sayım belirsizliklerinden daha azdır. Bu yeni yaklaşım, üst üste binen pik zirvelerini çözme problemine uygulanmıştır. İlk olarak, YSA'nın her bir pik zirveyisini çözme kabiliyetini test etmek için gerçek numunelerin yapay olarak üst üste binen alfa pik zirvelerini çözümlemede teorik bir çalışma gerçekleştirilmiştir. Sonra, radyoaktif içeriği önceden bilinen sertifikalı örneklerden elde edilen farklı spektrumların aktivite düzeylerinin belirlenmesi ile YSA prosedürü kontrol edilmiş ve sonuçları diğer yöntemlerle karşılaştırılmıştır.

YSA'nın nükleer spektroskopideki bir diğer uygulaması pik-background oranının (Dragovic and Onjia, 2005) belirlenmesidir. Pik-to-background oranı (PBR), gama spektrometrik ölçümlerde dedeksiyon limitlerinin optimizasyonu için oldukça önemlidir. Ölçüm süresinin optimizasyonu ile dedeksiyon limitleri iyileştirilebilir. Bir spektrumda birçok radyonüklitin PBR'lerinin optimize edilmesi gerektiğinden bu görev genellikle karmaşık ve zaman harcayıcı olmaktadır. Çalışmada gama-ışını spektrometresinde ölçüm zamanının bir fonksiyonu olarak PBR tahmininde YSA modeli kullanılmıştır. YSA'nın en iyi tahmin gücü ile yapılabilmesi için, parametreler optimize edilmiştir. Toprak örneklerinde yaygın olarak bulunan sekiz radyonüklit ( $Ra^{226}$ ,  $U^{238}$ ,  $U^{235}$ ,  $K^{40}$ ,  $Th^{232}$ ,  $Cs^{134}$ ,  $Cs^{137}$  ve  $Be^7$ ) için tahmin edilen ve deneysel PBR değerlerinin çoğu başarıyla elde edilmiştir.

Elementlerin spektral çizgilerinin tanımlanması (Saritha and Nampoori, 2009) YSA uygulamalarına diğer bir örnektir. Spektroskopik çalışmalar çeşitli bileşiklerin ve elementlerin spektrumunu ele alır. Spektroskopik çalışmalarda, bir spektrometre kullanılarak alınan numunenin spektrumu bir grafik üzerinde çizilir ve çeşitli enerji tepe noktaları tanımlanır. Bir örneğin spektrumu, örnekte mevcut olan tüm elementlerin karakteristik spektral çizgisini içerir. Bu spektral çizgilerin

lineer bir süperpozisyonudur. Belirli bir elementin zayıf spektral çizgisi bile, eğer örnekte bu elementin konsantrasyonu yüksekse elde edilir. Ayrıca, bir elementin en güçlü çizgisi, konsantrasyonunun düşük olduğu bir örnek için gözlemlenemez.

YSA'nın diğer bir uygulaması PIXE (proton kaynaklı X-ışını emisyonları) (Correa et al., 2006) dir. Correa et al. (2006) yaptığı çalışmada balıklarda metal biokirliliği birikimine ilişkin olarak balık dokularının örnekleri, element konsantrasyonlarını belirlemek için, protonlarla ışınlanmıştır. Birkaç PIXE spektrumu, balık kas, karaciğer ve solungaç örneklerinden elde edilerek örneklerin bir kısmı standart yöntemle analiz edilmiş ve daha sonraki hesaplamalar için YSA'yı eğitmede kullanılmıştır. Verilerin dağılımı ile ilgili varsayımlar olmaksızın, Şili'deki Rapel Gölünden alınan balıklardan elde edilen bu organik numunelerde P, S, K, Ca, Fe, Zn elementlerini tespit etmek ve konsantrasyonlarını belirlemek mümkün olmuştur. Analiz iki aşamada gerçekleştirilmiştir. İlk olarak, YSA'yı eğitmek için PIXE spektrumları kullanılmış ikinci olarak da YSA uygulanmasının bağımsız olarak standart metodoloji ile elde edilen sonuçları ile karşılaştırıldığı bir yöntem kullanılmıştır. Bu çalışmanın temel amacı, metallerin biyolojik olarak birikimine ilişkin bir çalışma da PIXE spektrumlarının hızlı analizi için YSA'nın uygulanmasını keşfetmektir. YSA uygulaması ile analistin her bir analize doğrudan katılımını engelleyerek çok sayıda numune analizinin birkaç dakika gibi yeterince hızlı bir şekilde yapılabileceği kanıtlanmıştır. YSA'nın eğitimi tamamlandıktan sonra PIXE spektrum analizinin otomasyonu ile maliyetler ve zamanın azaltılması sağlanmaktadır.

XRF (X-ışını flüoresan) (Bos and Weber; 1991; Boger and Karpas, 1994; Hernandez-Caraballo and Marco-Parra, 2003; Tuo et al., 2008) ve RBS (Rutherford geri saçılma) (Vieira and Barradas, 2000; Barradas et al., 2002; Matias et al., 2003; Barradas et al., 2004; Nene et al., 2006; Demeulemeester et al., 2010) çalışmaları da YSA uygulamalarının diğer örneklerindendir.

Tuo ve arkadaşlarının yaptığı çalışmada enerji dağılımlı X-ışını floresans (EDXRF) analizinde örnekleri sınıflandırmada matris etki düzeltmesi için YSA'nın ayrıntılı algoritması kullanılmıştır. Enerji dağılımlı X-ışını floresans (EDXRF) analizinde matris etkisi farklı faktörlere sebep olabilir. Bir çok elementten oluşan kalın bir örnek de ki mineral numunelerinde olduğu gibi, yüksek atom numarası olan bir elementin karakteristik X-ışınlarının foton numaraları, komşu düşük atom numaralı elementin kenar absarpsiyonu ile azaltılabilir ve etki elementten elemente farklıdır. Ayrıca, farklı türlerden toplanan aynı karakteristlik örnekler genellikle

farklı miktarlarda majör ve minör elementer içeriğe sahiptir. Karmaşık matris etkisi EDXRF tekniğini geçersiz yapabilir. Bu nedenle, EDXRF analizlerinde bu tür örnekler için bir matris etkisi düzeltme modeli oluşturmak önemlidir ve elementel analiz için standart bir eğrinin türetilmesi, düzeltilmiş matris etkili örnek sınıflandırmasına bağlıdır. Çalışmada kullanılan yöntem, örnekleri otomatik olarak sınıflandırarak matris etkisini etkili bir şekilde düzeltebilmektedir. Geleneksel sınıflandırma ve tahmin yöntemleri ile karşılaştırıldığında kullanılan YSA modeli numuneleri daha yüksek tanıma, kendini organize etme gibi karakterlere sahiptir. Yöntem, örnekleri otomatik olarak sınıflandırarak matris etkisini etkili bir şekilde düzeltebilmiş ve X ışını absorpsiyonu ve iyileştirmesinin etkisi örneklerin majör elemanları ile azaltılmıştır.

YSA, gama ışını spektrometresinde tek tek pikleri analiz etmek yerine, tüm spektrumun model tanıma özelliğini kullanarak, spektrumlardan otomatik olarak radyoaktif izotopları tanımlamak için kullanılmıştır (Olmos et al., 1991). YSA kullanılarak, ayrıca, deneysel koşulların optimizasyonu (Dragovich et al., 2005) ve kantitatif spektrometri analizi (Pilato et al., 1999, Yoshida et al., 2002) yapılmıştır.

Literatürde ilk defa Olmos et al. (1991) tarafından Ge (Li) ve NaI(Tl) dedektörlerinde, gama spektral analize YSA uygulanarak, radyonüklitlerin tanımlanması (kalitatif analiz) gerçekleştirilmiştir. Bu çalışmanın amacı, radyasyon spektrum analizi probleminde, YSA'nın uygulanabilirliğini tanıtmaktır. Bu çalışmadan sonra, nükleer spektroskopide YSA araştırılacak yeni bir konsept olarak kullanılmıştır. Özellikle düşük çözünürlüklü dedektörlerde, spektral analizde algoritmanın kullanılabilirliği gösterilmiştir.

Keller and Kouzes (1995), NaI(Tl) dedektöründe gama spektrumlarından radyonüklitlerin tanımlanmasında YSA'yı kullanmışlardır. Bu çalışma, YSA'nın geleneksel analitik tekniklere göre basitlik, gerçek zamanlı analiz ve otomasyon içeren avantajlarını göstermiştir.

Karmaşık spektrumların doğru olarak nicel analizi, uzmanların bilgisine dayanması ve uzun süreli yorucu hesaplamalar gerektirmesinden dolayı, Plato et al. (1999), HPGe dedektöründe, YSA kullanarak, örnek içerisindeki bilinmeyen radyonüklitlerin aktivitelerini kısa sürede kolaylıkla bulmuşlardır. Hesaplanan ve YSA dan elde edilen aktivite değerlerini karşılaştırmış ve aralarında mükemmel bir uyum sağlandığını görmüşlerdir.

Daha öncede bahsedildiği üzere, YSA algoritması tahminler, doğrusal olmayan problemler ve gerçek zamanlı veri analizi gibi çok çeşitli veri işleme uygulamalarında kullanılmaktadır. Bu tekniğin bir avantajı, peş peşe uygun bir eğitimle hızlı tanımlama yöntemidir. Bu teknik aynı zamanda nükleer spektroskopinin alanı, örn. X, gama ve alfa-ışını spektrometresinde (Yoshida et al., 2002) kullanılmıştır. Bununla birlikte, HPGe dedektörleri ile elde edilen gama ışını spektrometrisinde nadiren kullanılmıştır (Yoshida et al., 2002). Bunun nedeni, tipik olarak 4096 kanal veya daha fazla olan spektral büyüklük, YSA'nın girdi veri boyutu için büyük olmasıdır. Spektral analizin bir amacı, numunede bulunan radyonüklitin tanımlanması ve radyoaktivite miktarının belirlenmesidir. Bir HPGe dedektöründe spektrumdaki piklerin tanımlanması için gama spektral analizini yapmak genellikle kompleks fit uydurma fonksiyonları ile zaman harcayıcı hesaplamalar ve uzman bilgisi gerektirir. YSA'nın mükemmel örnek tanımlama karakteristiğine sahip olması nedeniyle bu spektral analizi için rahatlıkla uygulanabilir. Ancak 4096 ve daha fazla kanal sayısına sahip bir gama spektrumu YSA'nın girdi veri büyüklüğü için çok büyük kalmaktadır.

Yoshida et al. (2002), YSA'yı gama ışını spektrumlarının nitel analizine uygulamışlardır. Daha önce bahsedilen büyük olan girdi veri boyutunu, gama spektrumundaki piklerin yerlerini belirleyerek elde ettikleri verileri piklerin enerjilerine dönüştürerek, azaltmışlardır. Böylelikle enerjilerden oluşan veri seti YSA'nın girdi verisi olarak işletmişlerdir (Yoshida et al., 2002). YSA'nın eğitimi için sıklıkla kullanılan geri yayımlı (BP) algoritma içeren bir YSA modeli kullanmışlardır. Sonuç olarak YSA, karışık radyoizotoplardan oluşan gama ışını spektrumlarının analizine ve uranyum cevherleri spektrumlarına uygulanmıştır. Radyoizotop tanımlama başarıyla gerçekleştirilmiştir.

Peak-to-background oranı (PBR), gama spectrometrik ölçümlerde dedeksiyon limitlerinin optimizasyonu için önem teşkil etmektedir. En iyi dedeksiyon limitlerinin ölçüm zamanının optimizasyonu ile geliştirilebildiği bilinmektedir. Birçok radyonüklitin PBR si tek bir spektrumda optimize edilmesi gerekmektedir. Fakat bu karmaşık ve zaman harcayıcı bir işlemdir. Dragovic and Onjia (2005), çevresel toprak örneklerinin gama spektral analizinde ölçme zamanının fonksiyonu olan PBR yi tahmin etmek için YSA'yı kullanmışlardır. Çalışmada bu modeli geliştirmek için, YSA'nın öğrenme oranı, döngü sayısı ve gizli tabakadaki nöron sayısı gibi parametreleri optimize edilmiştir. Bu model kullanılarak, toprak örneklerinde sıklıkla dedekte edilen 8 radyonüklitin ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{232}\text{Th}$ ,

$^{134}\text{Cs}$ ,  $^{137}\text{Cs}$  ve  $^7\text{Be}$ ) elde edilen PBR değerleri deneysel değerleriyle karşılaştırılmış ve uyumlu olduğu bulunmuştur.

Literatürde yapılan birçok çalışmada YSA modeli geliştirilirken, yapay radyonüklitlerin bulunduğu örnekler kullanılmasına rağmen çevresel örneklerin kullanıldığı çalışmaların çok az olduğu görülmektedir. Dragovich et al. (2005) doğal toprak örneklerinde radyonüklitlerin aktivite seviyelerinin ölçülmesindeki belirsizliklerini tahmin etmek için YSA'yı kullanmışlardır. Bu çalışmada, ölçme zamanının bir fonksiyonu olarak, toprak örneklerinde 8 radyonüklitin ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{232}\text{Th}$ ,  $^{134}\text{Cs}$ ,  $^{137}\text{Cs}$  ve  $^7\text{Be}$ ) aktivite seviyelerinin ölçümündeki belirsizlikleri tahmin etmek için geri yayımlı üç tabakadan oluşan bir YSA modeli geliştirilmiştir. Az deneysel veriler kullanarak bile YSA'nın iyi sonuçlar verdiği gösterilmiştir. Deneysel ve YSA dan tahmin edilen belirsizlikler karşılaştırılarak performans analizi yapılmıştır. Bu analiz, geliştirilen YSA modelin doğru tahmin yaptığını göstermiştir.

Dragovich et al. (2006) doğal toprak örneklerinde radyonüklitlerin minimum dedekte edilebilir aktivitelerini tahmin etmek için YSA'yı kullanmışlardır. Bu çalışmada, ölçme zamanının bir fonksiyonu olarak, toprak örneklerinde 8 radyonüklitin ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{232}\text{Th}$ ,  $^{134}\text{Cs}$ ,  $^{137}\text{Cs}$  ve  $^7\text{Be}$ ) minimum dedekte edilebilir aktivitelerini tahmin etmek için geri yayımlı üç tabakadan oluşan bir YSA modeli geliştirilmiştir. Çalışmada bu modeli geliştirmek için, YSA'nın öğrenme oranı, döngü sayısı ve gizli tabakadaki nöron sayısı gibi parametreleri optimize edilmiştir. Deneysel ve YSA dan tahmin edilen minimum dedekte edilebilir aktiviteleri karşılaştırılarak yapılan performans analizi sonucunda, geliştirilen YSA modelinin doğru tahminler yaptığı bulunmuştur.

Bir ortama geçen gama ışınlarının spektrum bilgisinden birçok durumda faydalanılır. Özellikle geçen radyasyonlardan dolayı sağlıkta oluşabilecek tehlikelerin tahmin edilebilmesini sağlar. Aynı zamanda birincil fotonun enerjisinin bozulması ve geçişin daha iyi anlaşılmasına yardımcı olur. Bu alanda yapılan çalışmalar sıklıkla yığılma (build-up) ve doz hesaplarını içerir. Bir gama fotonunun madde ile etkileşimi fotoelektrik etki, compton etkisi ve çift oluşumu olmak üzere üç ayrı olay ile gerçekleşir. Fakat çift oluşum düşük foton enerjilerinde ( $<1.02\text{ MeV}$ ) gerçekleşmez. Diğer iki olay başlangıç fotonunun termal enerjili birçok fotona bölününceye kadar ortamda devam eder.

Ortamın fotoelektrik saçılma kesiti enerji artışıyla azalırken, Compton saçılma kesiti enerji arttıkça yavaşça azalır. Ortamda çoklu saçılmadan dolayı yığılmanın görüldüğü ve iki saçılma kesitinin birbirini dengelediği enerjide spektrumun düşük enerjili kısmında bir pik görülür. Bu pik ortamın çoklu saçılma piki olarak adlandırılır (Küçük and Küçük, 2006). Yığılma, ortamın bir karakteristik özelliğidir. Küçük and Küçük (2006),  $^{137}\text{Cs}$  noktasal kaynak kullanarak, sekiz farklı silindirik ortam (su, parafin, polietilen, gliserin, alüminyum, tuz, kükürt ve bakır) için 2x2 silindirik NaI (Tl) dedektörü ile geçiş gama ışınları spektrumunu ölçmüşlerdir. Çalışmalarında YSA'yı bu sekiz farklı ortamın geçiş gama ışınları spektrumunun tahmininde kullanmışlardır. YSA'nın tahmininin deneysel ölçümlerle karşılaştırıldığında iyi sonuçlar verdiği tespit edilmiştir.

Yüksek verimli ve enerji çözünürlüklü gama ışını spektroskopik sistemleri, radioaktivite miktarlarının ve örnek içerisindeki radyonüklitin tanımlanmasında en değerli gama spektral analiz tekniğini sağlarlar. Radyonüklitin aktivitesi tam enerji pik veriminin düzeltilmesiyle pik sayma oranından bulunabilir. Bilgisayarların ve elektronik cihazların hızla gelişmesi ile birlikte ticari programlar çok çeşitli koşullarda ve farklı şekillerde hesaplama yapabilme yeteneğine sahip olmalıdır. Kaliteli sayılabilecek bu evrensellik, yazılıma kullanıcıların müdahalesini gerektirirdiğinden dolayı dezavantaja sahiptir (Gilmore, 2008).

Medhat (2012), hem radyonüklitleri tanımlamak hem de bazı doğal radyoaktif kaynakların aktivitelerindeki belirsizliklerini tahmin etmek için YSA'yı uygulamıştır. Bu metot yüksek çözünürlüklü gama ışını spektrometresi HPGe ile toprak örneklerinde bulunan doğal radyonüklitlerden yayılan gama ışını spektrum analizini elde etmek için kullanılmıştır. Modelin performansı değerlendirildiğinde ölçülen ve tahmin edilen değerlerin yüksek oranda örtüştüğü bulunmuştur.

## **2.6.2 Yapay sinir ağlarının istatistiksel araç olarak kullanılması ile ilgili çalışmalar**

. YSA sınıflandırıcılarının diğer istatistiksel yöntemlere göre bazı önemli avantajları vardır. İstatistiksel sınıflandırma teknikleri tipik olarak model dağılımı hakkında önceden bilgi gerektirirken, sinir ağı sınıflandırıcıları dağıtım hakkında herhangi bir bilgiye sahip olmadan iyi çalışmaktadır. YSA'lar, temel veri dağıtımıyla ilgili esnek varsayımları kullanarak yeni verilere otomatik olarak adapte olma ve gerçek modelleme fonksiyonunu bilmeden modeller oluşturma becerisine sahiptir. YSA toprak bilimlerinde, toprak özelliklerinin tahmininde ve toprak sınıflarının çevre verilerinden kaynaklanma olasılığının yanı sıra farklı coğrafi bölgelere göre toprak sınıflandırması için yaygın şekilde kullanılmaktadır.

Dragovich and Onjia (2007a), YSA kullanarak deęişik coęrafik orijinli toprak örneklerini radyonüklit içeriklerine göre sınıflandırmış ve elde ettikleri sonuçları çok deęişkenli analiz teknikleri ile karşılaştırmışlardır. Coęrafik kökeni bilinmeyen toprakları tanımak ve sınıflandırmak için çok deęişkenli veri analizi yöntemleri kullanılmıştır. Sırbistan ve Karadaę'daki toplanan 103 toprak örneęi bölgelere göre sınıflarına ayrılmıştır. Örnekler içerisindeki radyonüklitler ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{134}\text{Cs}$ ,  $^{137}\text{Cs}$ ,  $^{232}\text{Th}$  ve  $^7\text{Be}$ ) in aktiviteleri gama ışını spektrometresi tespit edilerek farklı tanıma metodlarının girdi verisi olarak kullanılmıştır. Toprak örneklerinin içerdikleri bu sekiz radyonüklite göre sınıflandırılması için doğrusal diskriminant analizi (LDA), k-en yakın komşular (kNN), sınıf benzetimi (SIMCA) ve yapay sinir aęları kullanılmıştır. Tahmin etme kabiliyetleri sırasıyla % 82,8, % 88,6, % 60,0 ve % 92,1'dir. Böylelikle sınıflandırmada YSA'nın tahmininin dięer yöntemlere göre daha başarılı olduğunu göstermişlerdir.

Yosunlar ve likenler, biyolojik izlemede önemli bir role sahiptir. Dragovich et al. (2007), bu bitkileri coęrafik orjinlerine göre sınıflandırmak için üç katmanlı bir ileri beslemeli yapay sinir aęı modeli geliştirmişlerdir. Örnekler içerisindeki radyonüklitler ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{134}\text{Cs}$ ,  $^{137}\text{Cs}$ ,  $^{232}\text{Th}$  ve  $^7\text{Be}$ ) in aktiviteleri gama ışını spektrometresi ile tespit edilerek bu deęerler aęın girdi parametreleri olarak kullanmışlar ve ortalama sınıflandırma oranı % 90,7 civarında elde etmişlerdir.

Toprak örneęindeki radyoaktivitenin baskın kısmını, ilk radyonüklitler ( $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$ )'in bozunumları oluşturur. Nükleer silah testleri ve nükleer kazalar sonucu toprakta önemli miktarda  $^{137}\text{Cs}$  de bulunmaktadır. Lokasyonlar ile kirlilik arasındaki korelasyonu tanımlamak için sinir aęı yaklaşımının kullanımı ile ilgili birkaç çalışma bulunmaktadır (Kanevski et al., 1996). Dragovich and Onjia (2007b), gama ışını spektrometresi ile belirlenen radyonüklit içerięine dayalı olarak toprak numunelerini sınıflandırmak için YSA'yı kullanmışlardır. Toplam 103 toprak örneęi, toplandıkları Sırbistan ve Karadaę'daki bölgelere göre sınıflarına ayrılmıştır. Gama ışını spektrometresi ile ölçülen radyonüklitler ( $^{226}\text{Ra}$ ,  $^{238}\text{U}$ ,  $^{235}\text{U}$ ,  $^{40}\text{K}$ ,  $^{134}\text{Cs}$ ,  $^{137}\text{Cs}$ ,  $^{232}\text{Th}$  ve  $^7\text{Be}$ )' in aktiviteleri, YSA'nın girdi verisi olarak kullanılmıştır. Eęitim setlerinde farklı sayıdaki örneęe sahip beş farklı eęitim algoritması test edilmiş ve minimum ortalama karekök hata (RMSE) deęerini bulmak için karşılaştırılmıştır. YSA'nın optimizasyonu için geri yayılımlı algoritma kullanarak toprak örneklerini % 92 oranında sınıflandırmayı başarmışlardır.

### 3. MATERYAL VE METOT

#### 3.1 Çalışmada Kullanılan Gama Spektrometrik Sistemler

##### 3.1.1 HPGe Gama Spektrometrik Sistem

İncelenen örneklerdeki  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  içeriklerinin saptanmasında kullanılan gama spektrometre sistemi (Şekil 3.1), 184cc HpGe coaksial dedektör (dedektör verimi: %25,  $^{60}\text{Co}$ 'ın 1,33 MeV gama enerjisi için FWHM: 1.83 keV ve pik/compton oranı:57:1), Ortec Model-671 spektroskopi amplifikatörü ve Canberra PC bazlı MCA (8K) Wilkinson ADC'den oluşmuş ve 100 mm kurşun ile zırhlanmıştır. Curie (1968) kriterlerine dayalı olarak, gama spektrometre sisteminin 86400s'de ölçebileceği minimum dedekte edilebilen aktiviteler (MDA)  $^{238}\text{U}$  için 5 Bq kg<sup>-1</sup>,  $^{232}\text{Th}$  için 5 Bq kg<sup>-1</sup> ve  $^{40}\text{K}$  için 16 Bq kg<sup>-1</sup> dir. Radyometrik sayım hatasının, toprak ve kayaç örneklerinde genelde %10'nun altında kaldığı gözlenmiştir.

**Analitik Kalite Kontrolü:** Gama spektrometre sisteminin analitik kalite kontrolü, IAEA kaynaklı RGU-1, RGTh-1 ve Amersham kaynaklı Standard referans materyallerden, örneklerle benzer matris ve geometride hazırlanan standartlar kullanılarak yapılmıştır.



Şekil 3.1. Çalışmada kullanılan HPGe gama spektrometre sistemi.

### 3.1.2 NaI(Tl) Gama Spektrometrik Sistem

İncelenen örneklerde  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  içeriklerinin saptanmasında kullanılan gama spektrometre sistemi (Şekil 3.2), 3''x 3'' NaI(Tl) sintilasyon detektörü, Ortec Model-575 spektroskopi amplifikatörü, Ortec Model-456 yüksek voltaj kaynağı ve PC bazlı MCA (8 K, Wilkinson ADC)'den oluşmuş ve 75 mm kurşun ile zırhlanmıştır.

Bu çalışmada, Yapay Sinir Ağları (YSA); ilk olarak HPGe gama spektral analizde, ikinci adımda  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitlerinin MDA değerlerinin bulunmasında, üçüncü adımda ise NaI(Tl) sintilasyon gama spektroskopisi ile doğal radyonüklit analizlerini elde etmede kullanılmıştır.



Şekil 3.2. Çalışmada kullanılan NaI(Tl) gama spektrometre sistemi.

### 3.2 Çalışılan Örneklerin Tanımlanması

Çalışmada granit, kayaç, toprak, sediment, komposit gübreler, ham fosfat ve ticari doğal yapı taşları çalışılmış ve kullanılan örnekler Tablo 3.1 de verilmiştir.

Tablo 3.1. Çalışmada kullanılan örnekler.

| Örnek No. | Örnek türü         | Örneğin içeriği           |
|-----------|--------------------|---------------------------|
| 1-52      | Granit-Toprak      | Çataldağ                  |
| 53-67     | Gübre              | Kompozit gübre, hamfosfat |
| 68-114    | Doğal yapı taşları | Mermer, granit, kayaç     |
| 115-126   | Mineraller         | Sediment                  |

### 3.3. Gama Spektroskopisiyle Jeolojik Örneklerde Uranyum-Toryum-Potasyum Tayini:

Herhangi bir jeolojik örnek matrisi içinde genelde U, Th, K radyoelementleri değişik konsantrasyonlarda ve bir arada bulunurlar. NaI(Tl) sintilasyon dedektörlerinin sınırlı ayırma gücü nedeniyle, bu primordial radyonüklitler için seçilen gama enerjileri (2,6 MeV, 1,76 MeV, 1,46 MeV), sintilasyon gama spektroskopisiyle yapılan ölçümlerde konsantrasyon hesabında doğrudan kullanılamazlar. Böyle bir örneğin sintilasyon gama spektrumunda, bu radyonüklitlerin birbirlerine olan katkılarının uygun faktörlerle çıkartılması gerekmektedir. Bu katkı oranlarını geometriye ve spektrometrenin çeşitli ayarlarına bağlı olarak veren *Sıyırma (Stripping) Oranlarının* ve net sayımlardan K (%), U (ppm), Th (ppm) olarak konsantrasyona geçmeyi sağlayan *Duyarlılık (Sensitivite) Faktörleri'nin* nasıl saptanacağına ilişkin yöntem, Yener ve Yaprak (1988), Yaprak (1995) ve Yaprak and Aslani, 2009)'da detayları ile geniş şekilde verilmiştir. Klasik olarak nitelendirilen bu yöntemde, U, Th ve K primordial radyonüklitlerinin katkılarının nasıl çıkarılacağı ve hesaplanacağı aşağıda detaylandırılmıştır.


**Potasyum spektrumu**, tek enerjili bir gama kaynağına karşı NaI(Tl) detektörünün tipik bir cevabıdır.  $^{40}\text{K}$  pikinin enerjisi 1,461 MeV' dir ve alçak enerji süreklilik bölgesi 1,461 MeV gama ışınının Compton uzantısıdır.

**Uranyum spektrumu**, çok sayıda ürün çekirdekten gelen birçok gama ışını içerir. Uranyum tayinlerinde intensitesi yüksek ve girişim etkilerinden uzak olması nedeni ile çoğunlukla Bi-214'den gelen 1,76 MeV enerjili gama piki kullanılır.

**Toryum spektrumu** da ürün nüklitlerinin bozunmasıyla oluşan birçok gama

ışını pikine sahiptir. Bunlardan en önemlisi Tl-208' dir ve bu pik örnek içindeki Th konsantrasyonunun kantitatif tayininde kullanılır. Jeolojik örneklerde K, U, Th tayini yapmak için spektrumlarda yukarıda sözü edilen gama enerjilerine karşılık gelen enerji aralıkları (kanallar) belirlenir.

Seçilen enerji aralığına (kanallara) düşen net sayımı, dolayısı ile örnek konsantrasyonunu hesaplamak için o enerji aralığına diğer radyoelementlerden gelen gama ışınlarının etkisinin çıkarılması gerekir (Şekil 3.3).



Şekil 3.3. Th, U ve K kanallarına gelen katkılar (Yaprak, 1995).


**Potasyum Kanalı:** Potasyum kanallarındaki sayımların çoğu art-ortamdan kaynaklanmaktadır. Sistemin bulunduğu odadaki ortamdan potasyum kanalına gelen katkılar % 65 dolayındadır. Toryum ve uranyumdan gelen katkılar da % 15 -

20 arasındadır. Aynı şekilde potasyum kanallarındaki sayımlar da doğrudan konsantrasyon hesabında kullanılmazlar (Şekil 3.4a).

**Uranyum Kanalı:** Spektrumda uranyum için seçilen kanallara toryum'dan ihmal edilemeyecek katkılar gelir. Uranyumu saptamakta kullanılan Bi-214'ün 1,76 MeV gama piki toryum serisinden Tl-208'in 2,61 MeV enerjili gamasının 2.10 MeV tek kaçak piki ve 1,59 MeV çift kaçak piki arasına düşer. Bunlardan başka toryum serisinde Ac-228'in 1.588 MeV enerjili gaması da uranyum kanalındaki sayımlara katkıda, bulunur. Bu yüzden uranyum kanallarındaki sayımlar uranyum konsantrasyonu hesabında doğrudan kullanılamazlar (Şekil 3.4b).

**Toryum Kanalı:** Toryum için seçilen kanallardaki sayımların %86'sı toryumdan %2'si uranyumdan ( Bi- 214  $\rightarrow$  2,42 MeV ) geri kalanı da art-ortamdan gelmektedir (Şekil 3.4c).

Potasyum, uranyum toryum konsantrasyonlarını saptamak için, seçilen kanallardaki katkıları uygun faktörlerle çıkarmak gerekir. Bu katkı oranlarını geometriye ve spektrometrenin çeşitli ayarlarına bağlı olarak veren faktörlere *sıyırma (stripping) oranları* denir. Net sayımlardan % K, ppmU, ppmTh olarak konsantrasyona geçmeyi sağlayan faktörlere de *duyarlılık (sensitivite) faktörleri* denir. Sıyırma oranları ve duyarlılık faktörleri, sırasıyla, Tablo 3.2 ve Tablo 3.3'de verilmiştir.



Şekil 3.4. Potasyum (a), Uranyum (b) ve Toryum (c) kanalları (Yaprak, 1995).

Tablo 3.2. Sıyrılma Oranları ( $\alpha$ ,  $\beta$  ve  $\gamma$ ) (Yaprak, 1995).

$$\alpha = \frac{\text{Toryum'dan Uranyum'a gelen katkı}}{\text{Toryum net sayımı } (Th_{net})}$$

$$\beta = \frac{\text{Toryum'dan Potasyum'a gelen katkı}}{\text{Toryum net sayımı } (Th_{net})}$$

$$\gamma = \frac{\text{Uranyum'dan Potasyum'a gelen katkı}}{\text{Uranyum net sayımı } (U_{net})}$$

Tablo 3.3. Duyarlılık Faktörleri ( $K_1$ ,  $K_2$  ve  $K_3$ ) (Yaprak, 1995).

|                                                         |  |
|---------------------------------------------------------|--|
| $K_1 = \frac{C(T_h)}{Th(ppm)}$                          |  |
| $C(T_h) = \text{Toryum kanallarındaki net sayım}$       |  |
| $Th(ppm) = \text{Standardın ppm olarak toryum içeriği}$ |  |
| $K_2 = \frac{C(U)}{U(ppm)}$                             |  |
| $C(U) = \text{Uranyum kanallarındaki net sayım}$        |  |
| $U(ppm) = \text{Standardın ppm olarak uranyum içeriği}$ |  |
| $K_3 = \frac{C(K)}{\%K}$                                |  |
| $C(K) = \text{Potasyum kanallarındaki net sayım}$       |  |
| $\%K = \text{Standardın \% olarak potasyum içeriği}$    |  |

Uygun standartlar ile duyarlılık (sensitivite) faktörleri ve sıyrma (stripping) oranları saptandıktan sonra, örnek içindeki eU eTh, %K konsantrasyonlarına aşağıdaki eşitliklerle geçilir. Ürün aktivitesi kullanılarak kantitatif analiz yapılan bu yöntemde bulunan U ve Th konsantrasyonları eşdeğer uranyum (eU) ve eşdeğer toryum (eTh) olarak ifade edilir. Ölçümlerde  $^{40}\text{K}$ 'ın kendi karakteristik gaması (1460,75 keV ) kullanıldığından bulunan %K konsantrasyonu doğrudan potasyum içeriğini verir (Yener ve Yaprak, 1988; Yaprak, 1995).


$$eTh (ppm) = \frac{C(Th)}{K_1} \quad (3.1)$$

$$eU \text{ (ppm)} = \frac{1}{K_2} [C(U) - \alpha C(\text{Th})] \quad (3.2)$$


$$\% K = \frac{1}{K_3} [C(K) - \gamma [C(U)] - \alpha C(\text{Th}) - \beta C(\text{Th})] \quad (3.3)$$

### 3.3.1 Duyarlılık Faktörleri ( $K_1$ , $K_2$ ve $K_3$ ) nin elde edilmesi.


İncelenen örneklerde U, Th ve K tayininde NaI(Tl) gama spektrometre sistemi kullanılmıştır. 4096 kanal için  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  standartları kullanılarak duyarlılık ve sıyırma katsayıları 7200s, 20000s, 30000s ve 86400s' lik sayım süreleri için hesaplanmıştır (Şekil 3.5 -3.7).



Şekil 3.5. Duyarlılık Faktörü  $K_1$ .



Şekil 3.6. Duyarlılık Faktörü  $K_2$ .



Şekil 3.7. Duyarlılık Faktörü  $K_3$ .

### 3.4 Çalışmada Kullanılan Yapay Sinir Ağları

#### 3.4.1 İleriye Beslemeli Geriye Yayınimli Yapay Sinir Ağları

Daha öncede belirtildiği üzere, bir girdi katmanı, bir veya birden fazla gizli katman ve bir çıktı tabakasından oluşturulan bir yapay sinir ağı (YSA), girdi tabakasında dışarıdan ağa sunulan girdi, ağ içerisinde ileriye doğru iletilir. Öğrenme aşamasında, optimum gizli tabakaların sayısı ve bu tabakalardaki nöronların sayısı, her modellenen problem için denemeler yapılarak belirlenmektedir. (Kumanlioğlu, 2010). İleriye doğru beslemeli geriye yayılım yapay sinir ağlarında, önce çıktı katmanındaki çıktı değerini hesaplamak amacıyla, dışarıdan girdi katmanının nöronlarına sunulan verileri ileriye doğru besleme yapılır. Daha sonra, çıktı değerleri ile hedef değerleri kullanarak hesapladığı farklara göre, bağlantı ağırlıklarının revize edilerek geriye doğru ilerleme yapılır (Sahin, 2007).

İleriye doğru beslemeli geriye yayılım yapay sinir ağlarını eğitirken, ilk olarak, bağlantı ağırlıklarının değerleri rastgele seçilir ve seçilen öğrenme algoritmasıyla, ağa sunulan girdi için, öğrenme başarı ile sonuçlanana kadar seçilen bu değerler değiştirilmektedir. Eğitim aşamasındaki amaç, hedef değer ile YSA modelinin ürettiği çıktı değeri kullanılarak bulunan farkın, kabul edilebilir değerde olması istenilmektedir. Eğitim sonunda, oluşturulan YSA, bağlantı ağırlıklarını saklar ve böylelikle, bu ağa daha önce rastlanmamış bir girdi için sakladığı bağlantı ağırlıklarını kullanarak ileriye doğru besleme yapar ve bir çıktı elde eder.

YSA'da dışarıdan ağa sunulan girdi değerleri ( $G_i$ ) ilk olarak, saklı nöronlardaki bağlantı ağırlıkları ( $W_{ij}$ ) ile çarpılıp toplanarak saklı nöronların girdileri ( $S_j$ ) oluşturulur (Denklem 3.4).

$$S_j = \sum_{i=1}^k W_{ij} G_i \quad j = 1, 2, \dots, h \quad (3.4)$$

Oluşturulan her  $S_j$  değeri için, bir transfer fonksiyonu kullanarak bir gizli nöron çıktısı ( $SO_j$ ) oluşturulur. Bu amaçla, literatürde çok yaygın olarak kullanılan fonksiyon sigmoid fonksiyonudur. Sigmoid fonksiyonu kullanılarak  $HO_j$  değeri aşağıdaki gibi hesaplanmaktadır. Bu denklemde,  $\theta_j$  başlangıç (eşik) değerini göstermektedir. Bu değerde, öğrenme sürecinde, ağırlıklara benzer bir şekilde öğrenilir.

$$SO_j = \frac{1}{1 + \exp[-(S_j + \theta_j)]} \quad (3.5)$$

Daha sonra, hesaplanan  $SO_j$  çıktısı, bir sonraki katmanın girdisi olur ve bu işlem çıktı katmanına iletilinceye kadar sürer.  $m$  adet çıktı nöronlarına ulaşan girdi aşağıdaki gibi hesaplanır:

$$IO_n = \sum_{j=1}^h W_{jn} SO_{jn} \quad n=1, \dots, m \quad (3.6)$$

Bu girdi değerleri ağı tanımlanan aktivasyon fonksiyonu tarafından işlenerek sinir ağı çıktı değerleri,  $O_n$  elde edilir.

Daha sonraki ağırlık düzenlenmesi ya da öğrenme süreci geriye doğru ilerleme algoritması ile yapılmaktadır. Çıktı katmanındaki  $O_n$  değeri, hedef değeri  $\zeta_n$  ile aynı olmayacaktır. Her girdi grubu için hata karelerinin toplamı,  $e_p$ ,  $p$ 'inci girdi grubu için aşağıdaki şekilde bulunmaktadır:

$$e_p = \sum_{n=1}^m (\zeta_n - O_n)^2 \quad (3.7)$$

Aşağıda verilen formül kullanılarak, ortalama kare hatası (OKH), bütün girdi grupları için hesaplanır. Bu formülde,  $\zeta_{pm}$ ,  $p$ 'inci grup için hedef değeri,  $O_{pn}$  ise  $p$ 'inci grup için çıktı değeridir.

$$OKH = \frac{1}{2N} \sum_{p=1}^N \sum_{n=1}^m (\zeta_{pm} - O_{pn})^2 \quad (3.8)$$

Geriye doğru ilerleme algoritmasının amacı, OKH değerinin iterasyonla en aza indirilmesidir. Bunun için, önce çıktı birimindeki her bir nöron için  $\delta_n$  gradyanının hesaplanması aşağıda verilen formül kullanılarak hesaplanır:

$$\delta_n = O_n(1 - O_n)(\zeta_n - O_n) \quad (3.9)$$

Hata gradyanı  $\delta_j$  daha sonra gizli birimler için bir önceki birimdeki hataların ağırlıklı toplamının hesaplanması ile bulunmaktadır:

$$\delta_j = HO_j(1 - HO_j) \sum_{i=1}^m \delta_n W_{jn} \quad (3.10)$$

Hata gradyanları daha sonra ağı ağırlıklarını güncellemek için kullanılmaktadır:

$$\Delta W_{ij}(r) = \mu \delta_j X_i \quad (3.11)$$

$$W_{ij}(r+1) = W_{ji}(r) + \Delta W_{ji}(r) \quad (3.12)$$


n'inci veri sunumundan sonraki ağırlık değişimi şu şekildedir:

$$\Delta W_{ji}(r) = \mu \delta_j X_i + \alpha \Delta W_{ji}(r-1) \quad (3.13)$$

burada  $\alpha$  ve  $\mu$ , sırasıyla momentum ve öğrenme oranları;  $r$  ise iterasyon sayısıdır.

### 3.4.2 Radyal Tabanlı Yapay Sinir Ağları (RTYSA)

Broomhead ve Lowe (1988) tarafından insan sinir hücrelerinde görülen etki tepki davranışlarından esinlenilerek geliştirilen radyal tabanlı yapay sinir ağları (RTYSA)'nın eğitimi, çok boyutlu uzayda eğri uydurma yaklaşımı olarak düşünülebilir. RTYSA modelleri de tipik YSA mimarisi gibi bir girdi katmanı, bir gizli katmanı ve bir çıktı katmanı olmak üzere toplam 3 katmandan oluşur (Şekil 3.8). RTYSA'larda, verilerin girdi katmanından gizli katmanına iletilmesinde radyal tabanlı transfer fonksiyonları kullanılmaktadır.



Şekil 3.8. Tipik radyal tabanlı yapay sinir ağı.

Radyal tabanlı yapay sinir ağının ürettiği çıktı değeri ( $y_i$ ), Denklem 3.14 de verilen formülle hesaplanmaktadır. Bu denklemde,  $x \in R^{n \times 1}$  = RTYSA'nın girdi vektörünü,  $\phi_j(.) \in R^+ =$  radyal tabanlı aktivasyon fonksiyonunu;  $D_k \in R^{n \times 1} =$  girdi vektör uzayının bir alt setinden seçilen radyal tabanlı merkezleri;  $\|.\| =$  girdi vektörünün merkezden ne kadar uzak olduğunun bir ölçütü olan Öklidyen

normunu;  $W_{ij}$ = çıktı katmanındaki ağırlıkları,  $N$ = gizli katmanda bulunan hücre sayısı.

$$y_i = \sum_{j=1}^N W_{ij} \phi_j(x, D_j) = \sum_{j=1}^N W_{ij} \phi_j(\|x - D_j\|), \quad i = 1, 2, \dots, n \quad (3.14)$$

Bu çalışmada, oluşturulan RTYSA modellerinde aktivasyon fonksiyonu olarak Gauss fonksiyonu (Denklem 3.15) kullanılmıştır. Bu formülde,  $x$  girdi vektörünü,  $D_j$  merkezleri ve  $\sigma$  ise standart sapma değerini göstermektedir.  $\sigma$  değeri, RTYSA'nın modelinin performansını etkileyen en önemli dağılma (spread) parametresi olarak da anılmaktadır.

$$\phi_j(x) = \exp\left(-\|x - D_j\|_2^2 / 2\sigma^2\right) \quad (3.15)$$

## 4. DENEYSEL BULGULAR VE TARTIŞMA

### 4.1 Enerji Kalibrasyonu

Bir HPGe dedektöründe, spektrumundaki piklerin tanımlanması için gama spektral analizini yapmak genellikle kompleks fit uydurma fonksiyonları ile zaman harcayıcı hesaplamalar ve uzman bilgisi gerektirir. Yapay Sinir Ağları (YSA)'nın mükemmel örnek tanımlama karakteristiğine sahip olması nedeniyle, YSA bu spektral analizi için rahatlıkla uygulanabilir. Ancak 4096 ve daha fazla kanal sayısına sahip bir gama spektrumu, YSA'nın girdi data büyüklüğü için çok büyük kalmaktadır. Bu durum, gama spektrumundaki piklerin yerlerinin belirlenerek elde edilen verinin pikin enerjisine dönüştürülmesiyle aşılabilmektedir. Böylelikle enerjilerden oluşan data seti, YSA'nın girdi datası olarak işletilebilmektedir (Eiji Yoshida et al. , 2002). Buradan yola çıkarak, Nükleer Bilimler Enstitüsü Sayım Laboratuvarında bulunan HPGe dedektörü kullanılarak, Çandarlı deniz kumu örneklerinin (Set1 ve Set2) gama spektral analizi için YSA uygulanmıştır. Böylece, örnekler içerisindeki radyonüklitlerin varlıkları YSA ile tespit edilmiştir. Burada, YSA gama spektrumunun nitel analizi için uygulanmıştır. YSA'nın girdi data büyüklüğünü azaltmak için yalnızca spektrumdaki piklere karşılık gelen enerjiler girdi datası olarak işleme konulmuş olup, başlangıçtaki eğitme işlemi için radyonüklitlerin baskın gama enerjileri kullanılmıştır.

İlk olarak bir supervised data seti, 11 radyonüklitin gama enerjilerinden seçilerek oluşturulmuştur. Bu enerjiler, YSA'nın girdi tabakasının her bir nöronunu oluşturmaktadır. Kullanılan radyonüklitlerin enerjileri, Tablo 4.1de verilmiştir.

İkinci olarak, girdi data setinin hazırlanması için, Çandarlı'dan alınan deniz kumu örneklerinin gama spektrumları kullanılmıştır. Kalibrasyon denklemi kullanılarak piklerin kanal numaralarına karşılık gelen enerjileri elde edilmiştir. Elde edilen bu enerjiler, daha önce oluşturulan supervised datadaki enerjilerle karşılaştırılmıştır. Şöyle ki, spektrumdan elde edilen enerjiler daha önce oluşturulan supervised datadaki enerjiyle karşılaştırıldığında  $\pm 1,5keV$  aralığında kalıyorsa, girdi tabakadaki bu nöronun değeri 1'e, kalmıyorsa 0 olarak set edilmiştir. Böylelikle pikin konumu, bu pike karşılık gelen gama enerjisine dönüştürülerek YSA'nın girdi datasının oluşturularak işletilmesi sağlanmıştır. Böylelikle, oluşturulan YSA'nın yapısı 1 girdi tabaka (tabakadaki nöron sayısı 21 olmak üzere), 1 gizli tabaka (tabakadaki nöron sayısı 40 olmak üzere) ve 1 çıktı tabaka (tabakadaki nöron sayısı 11 olmak üzere)'dan oluşmaktadır. Çıktı tabakasındaki her bir nöron, bir radyoizotopa karşılık gelmekte ve çıktı değeri ise radyoizotopun

bulunma olasılığını göstermektedir. YSA algoritması olarak, uygulamada sıklıkla kullanılan Geri Yayılma (Back-Propagation (BP)) algoritması kullanılmıştır. YSA'nın eğitmesi için, supervised datada bulunan radyonüklitlerin keyfi sayısını içeren girdi data setlerinin bir sayısı kullanılarak yapılmıştır. Böyle bir girdi data setinde, belli radyonüklitlerin nöronları 1 ve diğerleri 0 dır. YSA'nın eğitme aşaması için 188 data seti, test aşaması için ise 47 data seti olmak üzere toplam kullanılan data sayısı 235 tir. Gizli tabakadaki nöron sayısı, 5 ile başlanmış, ağın ürettiği çıktı değerleri ile beklenen değerler arasındaki fark minimum oluncaya kadar, 5'er 5'er artırılarak 40 olarak elde edilmiştir.


Tablo 4.1 Kullanılan radyonüklitlerin enerjileri.

| <b>Radyonüklit</b> | <b>Enerji (keV)</b>                      |
|--------------------|------------------------------------------|
| <sup>234</sup> Pa  | 1001,03                                  |
| <sup>214</sup> Pb  | 295,21; 351,92                           |
| <sup>214</sup> Bi  | 609,3; 1120,29; 1238,1; 1407,98; 1764,49 |
| <sup>228</sup> Ac  | 338,4; 911,1; 968,9                      |
| <sup>212</sup> Bi  | 727,17                                   |
| <sup>208</sup> Tl  | 583,14; 860,37; 2614,5                   |
| <sup>235</sup> U   | 143,76; 185,72                           |
| <sup>223</sup> Ra  | 269,4                                    |
| <sup>212</sup> Pb  | 238                                      |
| <sup>137</sup> Cs  | 661,65                                   |
| <sup>40</sup> K    | 1460,8                                   |

Elde edilen sonuçlar kullanılan Set1 için Tablo 4.2 ve Şekil 4.1 de, Set2 için ise Tablo 4.3 ve Şekil 4.2 de verilmiştir. Sonuçlardan görüleceği üzere, YSA ile Çandarlı'dan alınan kum örnekler içerisindeki radyonüklitlerin varlıkları başarıyla tespit edilmiştir.

Tablo 4.2. Set1 için elde edilen YSA çıktıları.


| Radyonüklit       | YSA Çıktısı |
|-------------------|-------------|
| $^{234}\text{Pa}$ | 1,00        |
| $^{214}\text{Pb}$ | 1,00        |
| $^{214}\text{Bi}$ | 1,00        |
| $^{228}\text{Ac}$ | 1,00        |
| $^{212}\text{Bi}$ | 0,96        |
| $^{208}\text{Tl}$ | 1,00        |
| $^{235}\text{U}$  | 1,00        |
| $^{223}\text{Ra}$ | 0,00        |
| $^{212}\text{Pb}$ | 0,00        |
| $^{137}\text{Cs}$ | 0,00        |
| $^{40}\text{K}$   | 0,99        |



Şekil 4.1. Set1 için elde edilen YSA sonuçlarının grafiksel gösterimi.

Tablo 4.3. Set2 için elde edilen YSA çıktıları.

| Radyonüklit       | YSA Çıktısı |
|-------------------|-------------|
| $^{234}\text{Pa}$ | 1,00        |
| $^{214}\text{Pb}$ | 1,00        |
| $^{214}\text{Bi}$ | 1,00        |
| $^{228}\text{Ac}$ | 1,00        |
| $^{212}\text{Bi}$ | 1,00        |
| $^{208}\text{Tl}$ | 1,00        |
| $^{235}\text{U}$  | 0,71        |
| $^{223}\text{Ra}$ | 0,00        |
| $^{212}\text{Pb}$ | 1,00        |
| $^{137}\text{Cs}$ | 0,00        |
| $^{40}\text{K}$   | 0,00        |



Şekil 4.2. Set2 için elde edilen YSA sonuçlarının grafiksel gösterimi.

#### 4.2 Minimum Dedekte Edilebilir Aktivite (MDA) değerlerinin bulunması.

Enstitüde kullanılan sayım süreleri dikkate alınarak, 5000 - 87000s arası  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitleri için MDA değerleri, Curie kriterlerine (Lloyd A. Currie, 1968) dayalı olarak aşağıdaki formülle hesaplanmıştır. Bu formülde,  $K_1$ ,  $K_2$  ve  $K_3$  3. Bölümde hesaplanan duyarlılık faktörleridir.

##### Duyarlılık Faktörleri

$$MDA (Th, U, K) = \frac{2,71+3,29\sqrt{Background (Th,U,K)}}{K_1, K_2, K_3} \quad (4.1)$$

Bu amaçla 5000 - 87000s sayım sürelerinde radyometrik standartlar ölçülmüş (Tablo 4.4) ve benzer sayım sürelerinde U, Th ve K kanallarındaki background (BG) sayımları elde edilmiştir. 1000 s aralıkla girilen bu verilere ek olarak tekli, ikili ve üçlü kombinasyonlar oluşturulmuş ve toplamda 581 veri seti elde edilmiştir. Daha sonra bu oluşturulan veri setinin %80 ni (465 veri seti) YSA'nın eğitime aşaması için geri kalan %20 si (116 veri seti) test aşaması için kullanılmıştır. Eğitime algoritması olarak Geri-Beslemeli Algoritma (BP) kullanılmıştır. Aktivasyon fonksiyonu olarak hiperbolik fonksiyon kullanılmıştır. Eğitime aşamasının başlangıcında tek gizli tabaka seçilmiş fakat model performansının (hata değerlerinin) iyi olmadığı gözlenerek gizli tabaka sayısı ikiye çıkarılmıştır. Ortalama karesel hata kökü (RMSE) eğitime ve test işlemlerini sonlandırmak için kullanılan bir hata fonksiyonudur ve aşağıdaki formülle hesaplanmıştır.

$$RMSE = \frac{\sqrt{\sum_{i=1}^n (D_i - O_i)^2 / n}}{d} \quad (4.2)$$

Denklemdaki,  $D_i$  eğitime veya test işleminde istenilen çıktı (deneysel değerler),  $O_i$  yapay sinir ağı algoritmasının çıktısı (YSA'nın tahmin ettiği değerler),  $n$  eğitime veya teste kullanılan verilerin sayısı ve  $d$  eğitime veya test işleminde istenilen çıktının ortalama değeri ifade edilmektedir.


En iyi (optimal) YSA modeli, her bir gizli tabakada 15 gizli nöron kullanılarak elde edilmiştir. Bu optimal YSA modelden elde edilen MDA değerlerinin hesaplanan MDA değerleri ile karşılaştırılması her bir radyonüklit için aşağıda verilmiştir.

Tablo 4.4.  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitleri için MDA Değerleri.


| Sayım süresi<br>(s) | MDA (Bq/kg)       |                  |                 |
|---------------------|-------------------|------------------|-----------------|
|                     | $^{232}\text{Th}$ | $^{238}\text{U}$ | $^{40}\text{K}$ |
| 5000                | 22,612            | 27,014           | 131,292         |
| 10000               | 15,839            | 19,246           | 92,147          |
| 15000               | 12,722            | 15,594           | 75,017          |
| 20000               | 10,854            | 13,677           | 64,849          |
| 25000               | 9,706             | 12,425           | 57,872          |
| 30000               | 8,837             | 12,242           | 52,830          |
| 60000               | 6,432             | 8,004            | 37,051          |
| 87000               | 5,326             | 6,679            | 30,741          |

#### 4.2.1. $^{232}\text{Th}$ için Minimum Dedekte Edilebilir Aktivite (MDA) Değerlerinin Bulunması.

$^{232}\text{Th}$  için hesaplanan ve YSA'dan tahmin edilen MDA değerlerinin eğitime ve test verileri için karşılaştırılması, Şekil 4.3 ve Şekil 4.4'de verilmiştir. Bu şekillerden görüleceği üzere,  $^{232}\text{Th}$  için YSA'dan tahmin edilen MDA değerleri ile hesaplanan MDA değerlerinin arasındaki determinasyon katsayısı ( $R^2$ ) 1'e yakın bulunmuştur. Bulunan bu yüksek  $R^2$  değerleri, hesaplanan MDA değerleri ile ve YSA'dan tahmin edilen MDA değerlerinin uyum içinde olduğunu yani örtüştüğünü göstermektedir.




Şekil 4.3.  $^{232}\text{Th}$  için hesaplanan ve tahmin edilen MDA değerlerinin eğitime verileri için karşılaştırılması




Şekil 4.4.  $^{232}\text{Th}$  için hesaplanan ve tahmin edilen MDA değerlerinin, test verileri için karşılaştırılması.

#### 4.2.2 $^{238}\text{U}$ için Minimum Dedekte Edilebilir Aktivite (MDA) değerlerinin bulunması

$^{238}\text{U}$  için hesaplanan ve YSA'dan tahmin edilen MDA değerlerinin eğitime ve test verileri için karşılaştırılması, Şekil 4.5 ve Şekil 4.6'da verilmiştir. Bu şekillerden görüleceği üzere,  $^{238}\text{U}$  için YSA'dan tahmin edilen MDA değerleri ile hesaplanan MDA değerlerinin arasındaki korelasyon katsayısı ( $R^2$ ) 1'e yakın bulunmuştur. Bulunan bu yüksek  $R^2$  değerleri, hesaplanan MDA değerleri ile ve YSA'dan tahmin edilen MDA değerlerinin örtüştüğünü göstermektedir.




Şekil 4.5.  $^{238}\text{U}$  için hesaplanan ve tahmin edilen MDA değerlerinin eğitime verileri için karşılaştırılması.




Şekil 4.6.  $^{238}\text{U}$  için hesaplanan ve tahmin edilen MDA değerlerinin, test verileri için karşılaştırılması.

#### 4.2.3 $^{40}\text{K}$ için Minimum Dedekte Edilebilir Aktivite (MDA) değerlerinin bulunması

$^{40}\text{K}$  için hesaplanan ve YSA'dan tahmin edilen MDA değerlerinin eğitme ve test verileri için karşılaştırılması, Şekil 4.7 ve Şekil 4.8'de verilmiştir. Bu şekilden görüleceği üzere,  $^{40}\text{K}$  için YSA'dan tahmin edilen MDA değerleri ile hesaplanan MDA değerlerinin arasındaki korelasyon katsayısı ( $R^2$ ) 1'e yakın bulunmuştur. Bulunan bu yüksek  $R^2$  değerleri, hesaplanan MDA değerleri ile ve YSA'dan tahmin edilen MDA değerlerinin birbirine çok yakın olduğunu göstermiştir.



Şekil 4.7.  $^{40}\text{K}$  için hesaplanan ve tahmin edilen MDA değerlerinin eğitime verileri için karşılaştırılması.



Şekil 4.8.  $^{40}\text{K}$  için hesaplanan ve tahmin edilen MDA değerlerinin, test verileri için karşılaştırılması.

Son olarak,  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  için hesaplanan ve tahmin edilen MDA değerlerinin, test verileri için karşılaştırılmasıyla hesaplanan performans indisleri (ortalama karesel hata kökü (RMSE) ve determinasyon katsayısı ( $R^2$ )) aşağıdaki Tablo 4.5’de verilmiştir. Tablo 4.5’den görüleceği üzere, hesaplanan performans indisleri, YSA’dan elde edilen MDA değerlerinin, hesaplanan MDA değerlerine çok yakın bulunduğunu göstermiştir.

Tablo 4.5. YSA’dan elde edilen MDA değerleri ile hesaplanan MDA değerlerinin karşılaştırılmasından elde edilen  $R^2$  ve RMSE değerleri.

| Radyonüklit       | $R^2$  |        | RMSE (Bq/kg) |      |
|-------------------|--------|--------|--------------|------|
|                   | Eğitme | Test   | Eğitme       | Test |
| $^{232}\text{Th}$ | 0,9985 | 0,9999 | 0,16         | 0,12 |
| $^{238}\text{U}$  | 0,9974 | 0,9999 | 0,33         | 0,22 |
| $^{40}\text{K}$   | 0,9992 | 0,9999 | 0,99         | 0,66 |

#### 4.3 YSA’nın NaI(Tl) Sintilasyon Gama Spektroskopisinde Doğal Radyonüklit Analizlerine Uygulanması

Bu çalışmada  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  tayininde, enstitüde bulunan Ortec Model-575 spektroskopi amplifikatörü, Ortec Model-456 yüksek voltaj kaynağı ve PC bazlı MCA (8 K, Wilkinson ADC)’den oluşmuş ve 75 mm kurşun ile zırhlanmış 3’’x3’’ NaI(Tl) sintilasyon detektörü kullanılmıştır. Çalışma kapsamında 126 adet değişik orijinli jeolojik materyal; kayaç, toprak, granit, mermer, gübre örnekleri kullanılmıştır. 10000s sayım süresi için  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  standartları kullanılarak duyarlılık ve sıyırma katsayıları hesaplandıktan sonra, aynı sayım süresi için bütün örnekler sayılarak konvansiyonel analiz tekniği ile bütün örnekler içerisindeki uranyum, toryum ve potasyum konsantrasyonları hesaplanmıştır. Hesaplanan konsantrasyonlar Tablo 4.6’ da verilmiştir. Daha sonra buradan elde edilen veri seti YSA ile işletilerek örnekler içerisindeki uranyum, toryum ve potasyum konsantrasyonları elde edilmiştir.

Tablo 4.6. İncelenen örnekler içindeki hesaplanan  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  konsantrasyonları.

| Örnek No. | Örnekler               | Net sayımlar |      |       | $^{40}\text{K}$ | $^{238}\text{U}$ | $^{232}\text{Th}$ |
|-----------|------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                        | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 1         | Çataldağ - Granit-CG14 | 7198         | 1172 | 753   | 1022,06         | 34,10            | 49,35             |
| 2         | Çataldağ-Granit-CG26   | 5632         | 1836 | 573   | 574,20          | 76,63            | 36,59             |
| 3         | Çataldağ-Granit-CG20   | 6961         | 2706 | 1315  | 623,73          | 93,88            | 83,98             |
| 4         | Çataldağ-Granit-CG15   | 6276         | 1628 | 850   | 736,89          | 54,10            | 54,28             |
| 5         | Çataldağ-Granit-CG31   | 3014         | 572  | 202   | 455,13          | 26,29            | 14,80             |
| 6         | Çataldağ-Granit-CG18   | 7376         | 1911 | 1075  | 890,83          | 61,96            | 70,46             |
| 7         | Çataldağ-Granit-CG12   | 5663         | 1726 | 1562  | 674,38          | 33,13            | 108,07            |
| 8         | Çataldağ-Granit-CG7    | 7153         | 2440 | 1207  | 732,91          | 86,00            | 79,11             |
| 9         | Çataldağ-Granit-CG16   | 6059         | 1213 | 788   | 963,67          | 41,49            | 61,33             |
| 10        | Çataldağ-Toprak-C17    | 4304         | 1671 | 1011  | 633,46          | 81,11            | 104,92            |
| 11        | Çataldağ-Toprak-C26    | 3602         | 1047 | 499   | 646,83          | 59,67            | 51,78             |
| 12        | Çataldağ-Toprak-C12    | 4778         | 1628 | 1253  | 653,26          | 50,79            | 107,61            |
| 13        | Çataldağ-Toprak-C14    | 3626         | 794  | 441   | 660,78          | 36,56            | 40,68             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler               | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                        | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 14        | Çataldağ-Toprak-C20    | 5574         | 2264 | 1227  | 586,28          | 89,47            | 95,50             |
| 15        | Çataldağ-Toprak-C18    | 4929         | 1437 | 730   | 816,92          | 72,86            | 69,93             |
| 16        | Çataldağ-Toprak-C16    | 5194         | 1779 | 1368  | 683,93          | 53,72            | 113,57            |
| 17        | Çataldağ-Toprak-C15    | 4848         | 1080 | 701   | 792,49          | 39,43            | 58,20             |
| 18        | Çataldağ - Granit-CG19 | 6582         | 1652 | 711   | 896,76          | 70,01            | 52,08             |
| 19        | Çataldağ - Granit-CG28 | 5580         | 2177 | 837   | 535,37          | 91,52            | 57,91             |
| 20        | Çataldağ - Granit-CG30 | 4165         | 542  | 224   | 758,12          | 25,66            | 18,00             |
| 21        | Çataldağ-Toprak-C22    | 4789         | 1096 | 763   | 776,12          | 37,30            | 63,35             |
| 22        | Çataldağ-Toprak-C25    | 3170         | 1734 | 750   | 296,93          | 108,37           | 81,22             |
| 23        | Çataldağ-Toprak-C11(1) | 6031         | 2422 | 1067  | 635,92          | 107,84           | 83,05             |
| 24        | Çataldağ-Toprak-C11(2) | 3415         | 1185 | 371   | 405,39          | 60,22            | 28,88             |
| 25        | Çataldağ-Toprak-C23    | 4769         | 1722 | 805   | 572,30          | 76,78            | 64,68             |
| 26        | Çataldağ-Toprak-C28    | 4355         | 1245 | 298   | 720,32          | 83,45            | 28,55             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler                 | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|--------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                          | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 27        | Çataldağ - Granit-CG9    | 5108         | 1476 | 949   | 556,65          | 40,77            | 59,09             |
| 28        | Çataldağ-Toprak-C3       | 5811         | 2000 | 1141  | 806,71          | 87,10            | 101,49            |
| 29        | Çataldağ - Granit-CG13G1 | 5624         | 622  | 312   | 1089,86         | 27,54            | 25,90             |
| 30        | Çataldağ - Granit-CG10   | 6059         | 1860 | 1120  | 669,97          | 57,24            | 73,41             |
| 31        | Çataldağ - Granit-CG11   | 6045         | 1346 | 656   | 756,20          | 46,62            | 41,89             |
| 32        | Çataldağ - Granit-CG13   | 5844         | 1257 | 637   | 825,65          | 47,41            | 45,33             |
| 33        | Çataldağ - Granit-CG1    | 7219         | 3019 | 1299  | 598,26          | 111,55           | 82,96             |
| 34        | Çataldağ - Granit-CG21   | 5309         | 1082 | 719   | 866,93          | 37,38            | 57,77             |
| 35        | Çataldağ - Granit-CG23   | 6337         | 1676 | 740   | 754,02          | 62,77            | 48,50             |
| 36        | Çataldağ - Granit-CG24   | 5917         | 1373 | 492   | 785,45          | 59,29            | 34,04             |
| 37        | Çataldağ - Granit-CG25   | 4956         | 2349 | 1162  | 354,20          | 80,67            | 74,21             |
| 38        | Çataldağ - Granit-CG2    | 6280         | 2069 | 978   | 782,13          | 88,84            | 76,12             |
| 39        | Çataldağ - Granit-CG32   | 5563         | 1388 | 450   | 695,44          | 60,35            | 30,29             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler              | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|-----------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                       | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 40        | Çataldağ - Granit-CG4 | 6900         | 2602 | 1213  | 634,46          | 92,36            | 77,47             |
| 41        | Çataldağ - Granit-CG5 | 6585         | 1742 | 1006  | 767,77          | 53,98            | 64,25             |
| 42        | Çataldağ - Granit-CG6 | 6960         | 1472 | 550   | 884,15          | 57,77            | 35,12             |
| 43        | Çataldağ - Granit-CG8 | 4964         | 820  | 462   | 761,16          | 28,83            | 32,88             |
| 44        | Çataldağ-Toprak-C10   | 5351         | 2131 | 1012  | 676,23          | 108,17           | 93,35             |
| 45        | Çataldağ-Toprak-C13   | 5637         | 1839 | 774   | 777,50          | 92,32            | 66,47             |
| 46        | Çataldağ-Toprak-C19   | 6129         | 3272 | 1443  | 448,36          | 150,31           | 115,94            |
| 47        | Çataldağ-Toprak-C21   | 3636         | 1132 | 581   | 628,09          | 61,78            | 60,29             |
| 48        | Çataldağ-Toprak-C24   | 4382         | 1837 | 559   | 498,48          | 107,60           | 49,72             |
| 49        | Çataldağ-Toprak-C27   | 4616         | 1366 | 353   | 695,53          | 83,55            | 31,40             |
| 50        | Çataldağ-Toprak-C30   | 4309         | 981  | 443   | 671,53          | 44,54            | 35,59             |
| 51        | Çataldağ-Toprak-C31   | 2738         | 532  | 299   | 539,76          | 25,23            | 28,64             |
| 52        | Çataldağ-Toprak-C5    | 4985         | 1825 | 1068  | 637,68          | 75,28            | 91,72             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler       | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|----------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 53        | Ham-Fosfat     | 8474         | 7760 | 203   | 0,00            | 456,63           | 14,31             |
| 54        | 15-30-15       | 3731         | 71   | 2     | 1056,43         | 6,35             | 0,21              |
| 55        | 15-15-15(1)    | 10987        | 281  | 143   | 3618,67         | 18,69            | 17,99             |
| 56        | DAP 1          | 437          | 271  | 0     | 27,08           | 26,44            | 0,00              |
| 57        | DAP 2          | 595          | 556  | 0     | 0,00            | 47,26            | 0,00              |
| 58        | MAP            | 0            | 398  | 0     | 0,00            | 32,53            | 0,00              |
| 59        | MKP            | 37123        | 0    | 0     | 7701,37         | 0,00             | 0,00              |
| 60        | Güneyson NSP-2 | 6304         | 5948 | 182   | 0,00            | 352,05           | 12,95             |
| 61        | 10-27-10       | 5626         | 268  | 116   | 1656,68         | 17,90            | 13,43             |
| 62        | K2SO4-1        | 58576        | 54   | 12    | 10770,07        | 2,61             | 0,82              |
| 63        | K2SO4-2        | 52801        | 0    | 0     | 11699,21        | 0,00             | 0,00              |
| 64        | NSP-1          | 7966         | 7294 | 72    | 0,00            | 479,37           | 5,60              |
| 65        | Biocomp        | 13119        | 110  | 113   | 3292,56         | 2,06             | 10,59             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler            | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|---------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                     | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 66        | 15-15-15 (2)        | 12581        | 159  | 59    | 3553,93         | 10,40            | 6,26              |
| 67        | 15-25-15            | 11310        | 0    | 84    | 3509,33         | 0,00             | 9,63              |
| 68        | African-Lila        | 8023         | 1647 | 981   | 1263,55         | 60,72            | 76,35             |
| 69        | Azulplatino         | 6456         | 1295 | 172   | 951,48          | 72,79            | 12,60             |
| 70        | Bafa-Kayrak         | 2766         | 1085 | 723   | 286,09          | 34,08            | 52,96             |
| 71        | Belev-Siyah         | 590          | 469  | 10    | 0,00            | 28,79            | 0,73              |
| 72        | Green-Tween         | 7004         | 1218 | 524   | 1087,22         | 51,63            | 38,39             |
| 73        | Konya-Yesil         | 666          | 96   | 21    | 94,00           | 4,37             | 1,34              |
| 74        | Rosa-Beta           | 4655         | 761  | 522   | 738,70          | 23,21            | 38,24             |
| 75        | Sophire-Blue        | 7376         | 1405 | 1129  | 1196,45         | 37,37            | 87,87             |
| 76        | Toros-Siyah         | 403          | 95   | 51    | 53,49           | 3,36             | 3,53              |
| 77        | White Palmas Silkar | 4046         | 46   | 0     | 789,59          | 2,87             | 0,00              |
| 78        | Denizli-Kayrak-Taş  | 279          | 28   | 63    | 49,45           | 0,00             | 4,62              |

Tablo 4.6. (devam)

| Örnek No. | Örnekler                      | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|-------------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                               | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 79        | Star-Galaxy                   | 508          | 8    | 82    | 89,76           | 0,00             | 5,37              |
| 80        | Lime-Stene-Klasik-Onur Mermer | 42           | 195  | 40    | 0,00            | 11,20            | 3,19              |
| 81        | Multicolor                    | 5359         | 700  | 924   | 929,67          | 0,75             | 69,74             |
| 82        | Cafe-Imperial                 | 9273         | 485  | 473   | 1673,58         | 8,04             | 33,66             |
| 83        | Verdelouras                   | 6764         | 1169 | 1264  | 1134,80         | 15,07            | 98,38             |
| 84        | Yaykin-Dolomit (Mermertaş)    | 0            | 0    | 0     | 0,00            | 0,00             | 0,00              |
| 85        | Volga-Blue                    | 1607         | 0    | 13    | 300,86          | 0,00             | 0,90              |
| 86        | Rosamarina                    | 9491         | 2741 | 2100  | 1300,93         | 77,98            | 163,45            |
| 87        | Verde-Karzai                  | 1436         | 0    | 46    | 285,40          | 0,00             | 3,37              |
| 88        | Aswan-Red                     | 6569         | 535  | 442   | 1247,18         | 13,63            | 34,40             |
| 89        | Knowo                         | 3917         | 503  | 564   | 659,35          | 5,17             | 41,32             |
| 90        | Coralmist-Silkar              | 7370         | 1193 | 667   | 1242,23         | 46,14            | 51,91             |
| 91        | Newgdendia (Doğa)             | 7798         | 507  | 872   | 1523,19         | 0,00             | 67,87             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler                | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|-------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                         | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 92        | Rosagondola             | 6796         | 1150 | 697   | 1067,10         | 39,34            | 51,06             |
| 93        | Coralmist (Doğa Mermer) | 7587         | 990  | 733   | 1265,42         | 27,69            | 53,70             |
| 94        | Gallo-Tapozia           | 6216         | 272  | 329   | 1103,75         | 1,58             | 22,76             |
| 95        | Çin-Rosa-Beta           | 5168         | 951  | 615   | 793,75          | 30,74            | 45,05             |
| 96        | Tiger-Skin              | 7755         | 369  | 882   | 1379,40         | 0,00             | 61,02             |
| 97        | New-Coleclenya-Silkar   | 7176         | 467  | 1037  | 1324,15         | 0,00             | 75,97             |
| 98        | TanBrown                | 6086         | 671  | 676   | 1113,94         | 11,09            | 52,62             |
| 99        | Rosaroyal-Mısır         | 8049         | 989  | 528   | 1393,78         | 38,28            | 39,85             |
| 100       | Rosaminho               | 7792         | 2016 | 868   | 1186,34         | 96,81            | 72,06             |
| 101       | Cirenbutterfly          | 6862         | 86   | 14    | 1748,92         | 6,16             | 1,34              |
| 102       | Wadisorsan-Mısır        | 6512         | 960  | 501   | 1055,21         | 36,60            | 36,70             |
| 103       | Rosavel                 | 9413         | 1236 | 610   | 1659,19         | 51,80            | 47,48             |
| 104       | hblbgold.spm            | 8006         | 407  | 630   | 1495,16         | 0,00             | 46,15             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler                           | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|------------------------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                                    | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 105       | Çin-Brown-Porino                   | 5752         | 937  | 731   | 915,48          | 24,48            | 53,55             |
| 106       | Giello-Sopheril-Light              | 6342         | 584  | 282   | 1182,47         | 24,78            | 21,95             |
| 107       | Milas-Limon                        | 0            | 0    | 0     | 0,00            | 0,00             | 0,00              |
| 108       | Bionca-Ratelya                     | 5527         | 830  | 640   | 923,47          | 22,70            | 48,30             |
| 109       | Aswaygrey                          | 5125         | 752  | 365   | 882,65          | 31,82            | 28,41             |
| 110       | Rosa-Toledo                        | 6844         | 1114 | 653   | 1117,74         | 40,33            | 49,28             |
| 111       | Kopobonito (Brezilya)              | 9076         | 2526 | 1694  | 1188,45         | 78,85            | 124,09            |
| 112       | Blue-Orissa                        | 8568         | 449  | 825   | 1599,91         | 0,00             | 60,44             |
| 113       | Verde More                         | 6643         | 247  | 401   | 1261,18         | 0,00             | 29,38             |
| 114       | Wali-Gliazal (waliglzr.spm) -Mısır | 5545         | 513  | 405   | 975,83          | 13,18            | 29,67             |
| 115       | Alumina                            | 2            | 104  | 0     | 0,00            | 8,43             | 0,00              |
| 116       | Çin-Kili                           | 452          | 293  | 165   | 55,65           | 32,45            | 36,97             |

Tablo 4.6. (devam)

| Örnek No. | Örnekler           | Net sayımlar |      |       | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th |
|-----------|--------------------|--------------|------|-------|-----------------|------------------|-------------------|
|           |                    | C(K)         | C(U) | C(Th) | (Bq)            | (Bq)             | (Bq)              |
| 117       | Dolomit            | 0            | 237  | 0     | 0,00            | 12,44            | 0,00              |
| 118       | Florid             | 1230         | 1190 | 69    | 0,00            | 51,05            | 3,63              |
| 119       | Kalsine-Boxit      | 3932         | 3616 | 3301  | 0,00            | 54,33            | 182,06            |
| 120       | Kalsit             | 0            | 0    | 53    | 0,00            | 0,00             | 4,83              |
| 121       | Kaolen             | 915          | 521  | 345   | 115,80          | 34,36            | 52,74             |
| 122       | Mangan-Karbonat    | 0            | 103  | 43    | 0,00            | 5,37             | 3,82              |
| 123       | Mika-Tozu          | 5699         | 698  | 430   | 1823,53         | 44,77            | 59,86             |
| 124       | Olivin             | 14           | 0    | 28    | 2,62            | 0,00             | 1,59              |
| 125       | Potasyum-Feldispat | 7291         | 201  | 93    | 1841,38         | 10,85            | 8,99              |
| 126       | Wollastonit        | 134          | 218  | 0     | 0,00            | 17,09            | 0,00              |

Örnekler içerisindeki Toryum, Uranyum, ve Potasyum konsantrasyonları YSA ile dört farklı model (RTANN-1, RTANN-2, RTANN-3, RTANN-4) geliştirilerek elde edilmiştir. Bu modeller geliştirilirken, verilerin ağı girilmeden önce normalize edilmesi gereklidir. Bunun için, her bir parametre, aşağıdaki denklem kullanılarak normalize edilmiştir.


$$X_{ni} = a \frac{X_i - X_{min}}{X_{mak} - X_{min}} + b \quad (4.3)$$

Denklemdaki  $X_{min}$  ve  $X_{mak}$  sırası ile veri setinin minimum ve maksimum değerini,  $X_i$  ölçülmüş değeri ve  $X_{ni}$  ise normalize edilmiş değerleri ifade edilmektedir. Denklemdaki a ve b değerleri sırasıyla 1,8 ve -0,9 alınmıştır.


Normalizasyon işleminden sonra, 126 deneysel veri setinin, 101'i (yaklaşık % 80) eğitim sürecinde, geri kalan 25'i (yaklaşık %20) test aşamasında kullanılmıştır. Test aşamasında kullanılan veriler eğitim sürecine dahil edilmemiştir. Tüm modellerde, YSA algoritması olarak, **radyal tabanlı algoritma (RTANN)** kullanılmıştır. Aktivasyon fonksiyonu olarak, bu tür algoritmalarda en sık kullanılan **Gauss fonksiyonu** seçilmiştir. RTANN modellerin performansını önemli ölçüde etkileyen dağılma (spread) parametresi sırasıyla **1, 2 ve 3** olarak alınmıştır. Geliştirilen modellerin performanslarının kontrolü için, sık kullanılan performans indisi olan ve Denklem 4.5'deki formülle hesaplanan Ortalama karesel hata kökü (RMSE) kullanılmıştır. Geliştirilen tüm modellerde, en iyi (optimal) RTANN modeli, dağılma parametresi **3** olarak alındığında elde edilmiştir.

#### 4.3.1 Toryumu elde etmek için geliştirilen 1. Model (RTANN-1)

Toryumu elde etmek için geliştirilen 1. Model (RTANN-1) de girdi parametresi olarak toryumun net sayımı, çıktı parametresi olarak ta toryum konsantrasyonu (Bq) kullanılmıştır. Hesaplanan toryum konsantrasyon değerlerinin, RTANN-1 modelinden tahmin edilen toryum konsantrasyonu değerleri ile karşılaştırılması Şekil 4.9 ve 4.10'da verilmiştir.




Şekil 4.9. Eğitimde kullanılan örnekler için hesaplanan  $^{232}\text{Th}$  değerlerinin RTANN-1 modelinden tahmin edilen  $^{232}\text{Th}$  değerleriyle karşılaştırılması.




Şekil 4.10. Testte kullanılan örnekler için hesaplanan  $^{232}\text{Th}$  değerlerinin RTANN-1 modelinden tahmin edilen  $^{232}\text{Th}$  değerleriyle karşılaştırılması.

#### 4.3.2. Uranyumu elde etmek için geliştirilen 2. Model (RTANN-2)

Uranyumu elde etmek için geliştirilen 2. Model (RTANN-2) de, girdi parametresi olarak uranyum yum net sayımları, çıktı parametresi olarak ta uranyum konsantrasyonu (Bq) kullanılmıştır. Hesaplanan uranyum konsantrasyon değerlerinin, RTANN-2 modelinden tahmin edilen uranyum konsantrasyonu değerleri ile karşılaştırılması Şekil 4.11 ve 4.12’de verilmiştir.




Şekil 4.11. Eğitimde kullanılan örnekler için hesaplanan  $^{238}\text{U}$  değerlerinin RTANN-2 modelinden tahmin edilen  $^{238}\text{U}$  değerleriyle karşılaştırılması.




Şekil 4.12. Testte kullanılan örnekler için hesaplanan  $^{238}\text{U}$  değerlerinin RTANN-2 modelinden tahmin edilen  $^{238}\text{U}$  değerleriyle karşılaştırılması.

#### 4.3.3 Potasyumu elde etmek için geliştirilen 3. Model (RTANN-3)

Potasyumu elde etmek için geliştirilen 3. Model (RTANN-3) de girdi parametreleri olarak potasyumun net sayımları, çıktı parametresi olarak ta potasyum konsantrasyonu (Bq) kullanılmıştır. Hesaplanan potasyum konsantrasyon değerlerinin, RTANN-3 modelinden tahmin edilen potasyum konsantrasyonu değerleri ile karşılaştırılması Şekil 4.13 ve 4.14’de verilmiştir.



Şekil 4.13. Eğitimde kullanılan örnekler için hesaplanan  $^{40}\text{K}$  değerlerinin RTANN-3 modelinden tahmin edilen  $^{40}\text{K}$  değerleriyle karşılaştırılması.



Şekil 4.14. Testde kullanılan örnekler için hesaplanan  $^{40}\text{K}$  değerlerinin, RTANN-3 modelinden tahmin edilen  $^{40}\text{K}$  değerleriyle karşılaştırılması.


Geliştirilen RTANN-1, RTANN-2 ve RTANN-3 modellerinin performans indisleri (RMSE ve  $R^2$ ) eğitme ve test verileri için hesaplanmış ve Tablo 4.7’de verilmiştir.

Tablo 4.7. Geliştirilen RTANN-1, RTANN-2 ve RTANN-3 modellerinin performans indisleri


| Model         | Eğitme |        | Test |        |
|---------------|--------|--------|------|--------|
|               | RMSE   | $R^2$  | RMSE | $R^2$  |
| RTANN-1 model | 0,26   | 0,9984 | 0,30 | 0,9962 |
| RTANN-2 model | 0,15   | 0,9999 | 0,08 | 0,9998 |
| RTANN-3 model | 1,07   | 1,00   | 3,12 | 0,9987 |

#### 4.3.4 Toryum, Uranyum ve Potasyumu birlikte elde etmek için geliştirilen 4. Model (RTANN-4)


Toryum, Uranyum ve Potasyumun birlikte elde edildiği son model olan RTANN-4 de ise, girdi parametreleri olarak toryum, uranyum ve potasyumun net sayımları, çıktı parametreleri olarak ta toryum, uranyum ve potasyumun konsantrasyonları (Bq) kullanılmıştır. Eğitme ve test verileri için hesaplanan toryum, uranyum ve potasyum konsantrasyon değerlerinin, RTANN-4 modelinden tahmin edilen toryum, uranyum ve potasyum konsantrasyonu değerleri ile karşılaştırılması Şekil 4.15 - 4.20 ’de verilmiştir.




Şekil 4.15. Eğitimde kullanılan örnekler için hesaplanan  $^{232}\text{Th}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{232}\text{Th}$  değerleriyle karşılaştırılması.




Şekil 4.16. Testte kullanılan örnekler için hesaplanan  $^{232}\text{Th}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{232}\text{Th}$  değerleriyle karşılaştırılması.




Şekil 4.17. Eğitimde kullanılan örnekler için hesaplanan  $^{238}\text{U}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{238}\text{U}$  değerleriyle karşılaştırılması.



Şekil 4.18. Testte kullanılan örnekler için hesaplanan  $^{238}\text{U}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{238}\text{U}$  değerleriyle karşılaştırılması.



Şekil 4.19. Eğitimde kullanılan örnekler için hesaplanan  $^{40}\text{K}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{40}\text{K}$  değerleriyle karşılaştırılması.



Şekil 4.20. Testte kullanılan örnekler için hesaplanan  $^{40}\text{K}$  değerlerinin, RTANN-4 modelinden tahmin edilen  $^{40}\text{K}$  değerleriyle karşılaştırılması.

Ayrıca, eğitim ve test aşamasında kullanılan örnekler için hesaplanan  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  değerlerinin, RTANN-4 modelinden tahmin edilen  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  değerleriyle karşılaştırılması sırasıyla Tablo 4.8 ve 4.9’da verilmiştir.

Tablo 4.8. Eğitimde kullanılan örnekler için hesaplanan  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  değerlerinin RTANN-4 modelinden tahmin edilen  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  değerleriyle karşılaştırılması.

| YSA’da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | $^{40}\text{K}$ | $^{238}\text{U}$ | $^{232}\text{Th}$ | $^{40}\text{K}$    | $^{238}\text{U}$ | $^{232}\text{Th}$ |
| 1                                | 194             | 6                | 9                 | 194                | 6                | 9                 |
| 2                                | 122             | 18               | 16                | 122                | 18               | 16                |
| 3                                | 144             | 11               | 11                | 144                | 11               | 11                |
| 4                                | 77              | 4                | 3                 | 76                 | 4                | 3                 |
| 5                                | 121             | 6                | 19                | 121                | 6                | 19                |
| 6                                | 139             | 16               | 15                | 139                | 16               | 15                |
| 7                                | 154             | 7                | 10                | 154                | 7                | 10                |
| 8                                | 78              | 7                | 6                 | 79                 | 7                | 6                 |
| 9                                | 95              | 7                | 16                | 95                 | 7                | 16                |
| 10                               | 89              | 5                | 5                 | 90                 | 5                | 6                 |
| 11                               | 94              | 14               | 15                | 94                 | 14               | 15                |
| 12                               | 103             | 8                | 17                | 103                | 8                | 17                |
| 13                               | 119             | 6                | 9                 | 119                | 6                | 9                 |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 14                               | 96              | 16               | 10                | 96                 | 16               | 10                |
| 15                               | 1970            | 0                | 0                 | 1970               | 0                | 0                 |
| 16                               | 116             | 6                | 10                | 116                | 6                | 10                |
| 17                               | 34              | 12               | 9                 | 34                 | 12               | 9                 |
| 18                               | 102             | 17               | 13                | 102                | 17               | 13                |
| 19                               | 89              | 12               | 10                | 89                 | 12               | 10                |
| 20                               | 94              | 11               | 4                 | 92                 | 11               | 4                 |
| 21                               | 111             | 8                | 12                | 111                | 8                | 12                |
| 22                               | 113             | 12               | 14                | 113                | 12               | 14                |
| 23                               | 163             | 4                | 4                 | 163                | 4                | 4                 |
| 24                               | 127             | 11               | 14                | 127                | 11               | 14                |
| 25                               | 147             | 9                | 8                 | 147                | 9                | 8                 |
| 26                               | 117             | 22               | 16                | 117                | 22               | 16                |
| 27                               | 134             | 6                | 9                 | 134                | 6                | 9                 |
| 28                               | 143             | 12               | 9                 | 144                | 12               | 9                 |
| 29                               | 141             | 11               | 6                 | 142                | 11               | 6                 |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 30                               | 125             | 14               | 12                | 125                | 14               | 12                |
| 31                               | 129             | 11               | 6                 | 129                | 11               | 6                 |
| 32                               | 150             | 11               | 13                | 149                | 11               | 13                |
| 33                               | 172             | 11               | 7                 | 174                | 11               | 7                 |
| 34                               | 133             | 5                | 6                 | 133                | 5                | 6                 |
| 35                               | 91              | 15               | 13                | 91                 | 15               | 13                |
| 36                               | 113             | 13               | 10                | 113                | 13               | 10                |
| 37                               | 69              | 23               | 18                | 69                 | 23               | 18                |
| 38                               | 70              | 15               | 7                 | 70                 | 15               | 7                 |
| 39                               | 97              | 12               | 4                 | 97                 | 12               | 4                 |
| 40                               | 104             | 7                | 6                 | 104                | 7                | 6                 |
| 41                               | 70              | 3                | 4                 | 72                 | 3                | 4                 |
| 42                               | 0               | 81               | 3                 | 0                  | 81               | 3                 |
| 43                               | 123             | 1                | 0                 | 120                | 1                | 0                 |
| 44                               | 358             | 2                | 2                 | 358                | 2                | 2                 |
| 45                               | 3               | 3                | 0                 | 6                  | 3                | 0                 |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 46                               | 0               | 6                | 0                 | 0                  | 6                | 0                 |
| 47                               | 1250            | 0                | 0                 | 1250               | 0                | 0                 |
| 48                               | 0               | 62               | 2                 | 0                  | 62               | 2                 |
| 49                               | 178             | 2                | 1                 | 178                | 2                | 1                 |
| 50                               | 1778            | 0                | 0                 | 1778               | 0                | 0                 |
| 51                               | 0               | 77               | 1                 | 0                  | 77               | 1                 |
| 52                               | 437             | 0                | 1                 | 437                | 0                | 1                 |
| 53                               | 417             | 1                | 1                 | 417                | 1                | 1                 |
| 54                               | 202             | 10               | 12                | 203                | 10               | 12                |
| 55                               | 49              | 6                | 9                 | 48                 | 6                | 9                 |
| 56                               | 0               | 5                | 0                 | 4                  | 5                | 0                 |
| 57                               | 185             | 9                | 7                 | 185                | 9                | 7                 |
| 58                               | 18              | 1                | 0                 | 19                 | 1                | 0                 |
| 59                               | 126             | 4                | 7                 | 126                | 4                | 7                 |
| 60                               | 10              | 1                | 1                 | 11                 | 1                | 1                 |
| 61                               | 134             | 0                | 0                 | 133                | 1                | 0                 |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 62                               | 8               | 0                | 1                 | 8                  | 0                | 1                 |
| 63                               | 17              | 0                | 1                 | 16                 | 0                | 1                 |
| 64                               | 0               | 2                | 0                 | 0                  | 2                | 0                 |
| 65                               | 153             | 0                | 12                | 154                | 0                | 12                |
| 66                               | 293             | 1                | 6                 | 294                | 1                | 6                 |
| 67                               | 54              | 0                | 0                 | 54                 | 0                | 0                 |
| 68                               | 208             | 12               | 26                | 208                | 12               | 26                |
| 69                               | 49              | 0                | 1                 | 50                 | 0                | 1                 |
| 70                               | 112             | 1                | 7                 | 112                | 1                | 7                 |
| 71                               | 199             | 7                | 8                 | 198                | 7                | 8                 |
| 72                               | 244             | 0                | 11                | 245                | 0                | 11                |
| 73                               | 181             | 7                | 9                 | 181                | 7                | 9                 |
| 74                               | 215             | 5                | 9                 | 215                | 5                | 9                 |
| 75                               | 199             | 0                | 4                 | 200                | 0                | 4                 |
| 76                               | 135             | 5                | 8                 | 135                | 5                | 8                 |
| 77                               | 248             | 0                | 11                | 248                | 0                | 11                |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 78                               | 225             | 0                | 13                | 224                | 0                | 13                |
| 79                               | 230             | 6                | 7                 | 230                | 6                | 7                 |
| 80                               | 178             | 15               | 11                | 177                | 15               | 11                |
| 81                               | 227             | 1                | 0                 | 229                | 1                | 0                 |
| 82                               | 179             | 6                | 6                 | 178                | 6                | 6                 |
| 83                               | 254             | 0                | 8                 | 253                | 0                | 8                 |
| 84                               | 156             | 4                | 9                 | 155                | 4                | 9                 |
| 85                               | 189             | 4                | 4                 | 188                | 4                | 4                 |
| 86                               | 152             | 4                | 8                 | 152                | 4                | 8                 |
| 87                               | 141             | 5                | 5                 | 141                | 5                | 5                 |
| 88                               | 0               | 4                | 0                 | 0                  | 4                | 0                 |
| 89                               | 202             | 13               | 21                | 202                | 13               | 21                |
| 90                               | 214             | 0                | 5                 | 214                | 0                | 5                 |
| 91                               | 166             | 2                | 5                 | 166                | 2                | 5                 |
| 92                               | 0               | 1                | 0                 | 0                  | 1                | 0                 |
| 93                               | 0               | 3                | 0                 | 0                  | 3                | 0                 |

Tablo 4.8. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 94                               | 0               | 12               | 1                 | 0                  | 12               | 1                 |
| 95                               | 0               | 0                | 1                 | 0                  | 0                | 1                 |
| 96                               | 9               | 3                | 4                 | 9                  | 3                | 4                 |
| 97                               | 0               | 12               | 41                | 0                  | 12               | 41                |
| 98                               | 1               | 0                | 0                 | 1                  | 0                | 0                 |
| 99                               | 0               | 2                | 0                 | 1                  | 2                | 0                 |
| 100                              | 0               | 0                | 0                 | 1                  | 0                | 0                 |
| 101                              | 0               | 0                | 0                 | 1                  | 0                | 0                 |

Tablo 4.9. Testte kullanılan örnekler için hesaplanan <sup>232</sup>Th, <sup>238</sup>U ve <sup>40</sup>K değerlerinin RTANN-4 modelinden tahmin edilen <sup>232</sup>Th, <sup>238</sup>U ve <sup>40</sup>K değerleriyle karşılaştırılması.

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 1                                | 112             | 15               | 7                 | 114                | 15               | 7                 |
| 2                                | 76              | 10               | 13                | 76                 | 10               | 13                |
| 3                                | 106             | 9                | 9                 | 106                | 10               | 9                 |

Tablo 4.9. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 4                                | 152             | 12               | 9                 | 153                | 12               | 9                 |
| 5                                | 65              | 10               | 5                 | 65                 | 10               | 5                 |
| 6                                | 144             | 8                | 8                 | 144                | 8                | 8                 |
| 7                                | 69              | 16               | 14                | 68                 | 16               | 14                |
| 8                                | 124             | 18               | 15                | 124                | 18               | 15                |
| 9                                | 75              | 7                | 7                 | 76                 | 7                | 7                 |
| 10                               | 92              | 11               | 13                | 92                 | 11               | 14                |
| 11                               | 381             | 0                | 1                 | 381                | -1               | 0                 |
| 12                               | 162             | 12               | 2                 | 173                | 11               | 3                 |
| 13                               | 191             | 6                | 14                | 190                | 7                | 14                |
| 14                               | 182             | 2                | 16                | 175                | 4                | 16                |
| 15                               | 200             | 2                | 6                 | 199                | 2                | 6                 |
| 16                               | 178             | 2                | 8                 | 177                | 2                | 8                 |
| 17                               | 265             | 8                | 8                 | 268                | 9                | 8                 |
| 18                               | 272             | 0                | 10                | 277                | 0                | 11                |
| 19                               | 3               | 2                | 2                 | 6                  | 2                | 2                 |

Tablo 4.9. (devam)

| YSA'da<br>kullanılan<br>Örnek No | Hesaplanan (Bq) |                  |                   | Tahmin edilen (Bq) |                  |                   |
|----------------------------------|-----------------|------------------|-------------------|--------------------|------------------|-------------------|
|                                  | <sup>40</sup> K | <sup>238</sup> U | <sup>232</sup> Th | <sup>40</sup> K    | <sup>238</sup> U | <sup>232</sup> Th |
| 20                               | 237             | 1                | 1                 | 239                | 1                | 1                 |
| 21                               | 163             | 4                | 5                 | 163                | 4                | 6                 |
| 22                               | 169             | 12               | 13                | 169                | 12               | 13                |
| 23                               | 118             | 4                | 3                 | 116                | 4                | 3                 |
| 24                               | 184             | 7                | 8                 | 184                | 7                | 8                 |
| 25                               | 0               | 1                | 1                 | -1                 | 1                | 1                 |

Tablo 4.8 ve 4.9 ve Şekil 4.21-4.26'dan görüleceği üzere, modelden elde edilen konsantrasyon değerleri, hesaplanan konsantrasyon değerleriyle örtüşmektedir. Geliştirilen RTANN-4 modelinin performans indisleri (RMSE ve R<sup>2</sup>) hesaplanmış ve Tablo 4.10 te verilmiştir.

Tablo 4.10. Geliştirilen RTANN-4 modelinin performans indisleri.

| Radyonüklit       | Eğitme |                | Test |                |
|-------------------|--------|----------------|------|----------------|
|                   | RMSE   | R <sup>2</sup> | RMSE | R <sup>2</sup> |
| <sup>232</sup> Th | 0,20   | 0,9990         | 0,39 | 0,9938         |
| <sup>238</sup> U  | 0,20   | 0,9997         | 0,51 | 0,9910         |
| <sup>40</sup> K   | 1,07   | 1,0000         | 3,12 | 0,9987         |

Hesaplanan performans indislerine göre (Tablo 4.7 ve 4.10), tüm modeller, örneklerdeki  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  konsantrasyonlarını doğru bir şekilde tahmin edebilmektedir. Konsantrasyonların tek tek (Tablo 4.7) ve üçünün bir arada modellendiği modeller (Tablo 4.10) karşılaştırıldığında, hesaplanan performans indisleri arasında ihmal edilecek kadar küçük farklar bulunmuştur. Bu nedenle, kolaylık açısından, RTANN-4 modelinin örneklerdeki  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  konsantrasyonlarını belirlemek için kullanılması daha uygun olacağı gözükmemektedir.



## 5. SONUÇ VE ÖNERİLER

Yapay Sinir Ağları (YSA), biyolojik sinir sisteminin çalışma prensibinden esinlenerek sinir sistemindeki sinir hücrelerinin (nöronlar) basitleştirilerek yapay olarak taklit edilmesi ve bilgisayar ortamına aktarılması ile ortaya çıkmıştır. YSA'lar biyolojik sinir sisteminin bir modellenmesi olduğundan dolayı, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirebilme üstünlüklerine sahiptirler. Nükleer spektroskopide YSA'nın çeşitli uygulamaları vardır, örn. gama spektroskopisi, alfa spektroskopisi, pik-background oranı, puls şekilli dedektörlerin çözünürlük iyileştirmesi, proton kaynaklı X-ışını emisyonları, X-ışını flüoresan ve Rutherford geri saçılma, vb.

Nükleer spektroskopide, HPGe ve NaI(Tl) dedektörlerinin, gama spektral analizine YSA uygulanarak, radyoizotopların tanımlanması (kalitatif analiz) gerçekleştirilmiştir. Bu çalışmalardan sonra, bu alanda YSA araştırılacak yeni bir araştırma alanı olarak kullanılmıştır. Özellikle düşük çözünürlüklü dedektörlerde, spektral analizde algoritmanın kullanılabilirliği gösterilmiştir. Bununla birlikte, HPGe dedektörleri ile elde edilen gama ışını spektrometrisinde nadiren kullanılmıştır. Bunun nedeni, tipik olarak 4096 kanal veya daha fazla olan spektral büyüklük, YSA'nın girdi veri boyutu için büyük olmasıdır. Spektral analizin bir amacı, bir örnek içerisinde bulunan radyonüklitin tanımlanması ve radyoaktivite miktarının belirlenmesidir. HPGe dedektöründe spektrumdaki piklerin tanımlanması için, gama spektral analizini yapmak genellikle kompleks fit uydurma fonksiyonları ile zaman harcayıcı hesaplamalar ve uzman bilgisi gerektirir. YSA'nın mükemmel örnek tanımlama karakteristiğine sahip olması nedeniyle, bu spektral analiz için rahatlıkla uygulanabilir. Ancak 4096 ve daha fazla kanal sayısına sahip bir gama spektrumu YSA'nın girdi veri büyüklüğü için çok büyük kalmaktadır.

Literatürde, HPGe dedektöründen elde edilen gama spektrumunun nitel analizine, YSA uygulanmıştır. Bu uygulamalarda büyük olan girdi veri boyutu, gama spektrumundaki piklerin yerleri belirlenerek, böylelikle elde edilen verilerin piklerin enerjilerine dönüştürülmesiyle azaltılmış ve YSA'nın girdi verisi olarak kullanılmıştır.

YSA'nın avantajlarını ve nükleer spektroskopide kullanımını göz önüne alarak, bu çalışmada, YSA, Ege Üniversitesi Nükleer Bilimler Enstitüsündeki

sayım labaratuvarları kullanılarak, HPGe detektörünün enerji kalibrasyonuna, NaI(Tl) detektöründe MDA'ların hesaplanmasına ve literatürde ilk defa, NaI(Tl) sintilasyon gama spektroskopisi ile doğal örnekler içerisindeki  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  konsantrasyonlarının tayinine uygulanmıştır.

YSA'nın HPGe detektörünün enerji kalibrasyonu uygulamasında, girdi data büyüklüğünü azaltmak için, daha önce bahsedilen araştırmacılar gibi, yalnızca spektrumdaki piklere karşılık gelen enerjiler, girdi datası olarak kullanılmıştır. Bu datanın, % 80'ı eğitim aşamasında, geri kalan %20'si ise test aşamasında kullanılmıştır. YSA algoritması olarak, uygulamada sıklıkla kullanılan Geri Yayılma algoritması kullanılmıştır. Oluşturulan YSA'nın yapısı, 1 girdi tabaka (tabakadaki nöron sayısı 21 olmak üzere), 1 gizli tabaka (tabakadaki nöron sayısı 40 olmak üzere) ve 1 çıktı tabaka (tabakadaki nöron sayısı 11 olmak üzere)'dan oluşmaktadır. Çıktı tabakasındaki her bir nöron, bir radyonüklite karşılık gelmekte ve çıktı değeri ise radyonüklitin bulunma olasılığını göstermektedir. Geliştirilen YSA modelinin performansını test etmek için, Çandarlı'dan alınan deniz kumu örneklerinin gama spektrumları kullanılmıştır. Kalibrasyon denklemi kullanılarak, örneklerin spektrumlarındaki piklerin kanal numaralarına karşılık gelen enerjileri elde edilmiştir. Elde edilen bu enerjiler, daha önce YSA modeli geliştirirken kullanılan girdi datasındaki enerjilerle karşılaştırılmıştır. Böylelikle pikin konumu, bu pike karşılık gelen gama enerjisine dönüştürülerek, geliştirilen YSA modelinin performansının kontrolü için test datası hazırlanmıştır. YSA ile örnekler içerisindeki radyonüklitlerin varlıkları başarıyla tespit edilmiştir.

Çalışmada, YSA ile NaI(Tl) dedektöründe MDA'ların hesaplanmasında, Enstitüde kullanılan sayım süreleri dikkate alınarak, 5000- 87000s arası,  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  radyonüklitleri için, MDA değerleri, Curie kriterlerine dayalı olarak hesaplanmıştır. Bu 1000 s aralıkla girilen bu verilere ek olarak tekli, ikili ve üçlü kombinasyonlar oluşturulmuş ve toplamda 581 veri seti elde edilmiştir. Daha sonra bu oluşturulan veri setinin %80 ni (465 veri seti) YSA'nın eğitime aşaması için geri kalan %20 si (116 veri seti) test aşaması için kullanılmıştır. Eğitime algoritması olarak Geri-Beslemeli Algoritma (BP) kullanılmıştır. YSA'dan elde edilen MDA değerleri ile hesaplanan MDA değerleri karşılaştırıldığında, birbirleriyle örtüştüğü görülmüştür.

Geliştirilen YSA modelinin performansının kontrolü için,  $^{232}\text{Th}$ 'in,  $^{238}\text{U}$ 'in, ve  $^{40}\text{K}$ 'in hesaplanan ve YSA modelinden tahmin edilen MDA değerlerinin, eğitime ve test verileri için karşılaştırılmasıyla, performans indisleri (ortalama karesel hata kökü (RMSE) ve determinasyon katsayısı ( $R^2$ )) hesaplanmıştır.  $^{232}\text{Th}$  için,  $R^2$  değeri eğitime verisi için 0,9985 ve test verisi için ise 0,9999 olarak bulunmuştur. RMSE değeri ise, eğitime verisi için 0,16 Bq/kg, test verisi için ise 0,12 Bq/kg olarak hesaplanmıştır.  $^{238}\text{U}$  için,  $R^2$  değeri eğitime verisi için 0,9974 ve test verisi için ise 0,9999 olarak bulunmuştur. RMSE değeri ise, eğitime verisi için 0,33 Bq/kg, test verisi için ise 0,22 Bq/kg olarak hesaplanmıştır.  $^{40}\text{K}$  için,  $R^2$  değeri eğitime verisi için 0,9992 ve test verisi için ise 0,9999 olarak bulunmuştur. RMSE değeri ise, eğitime verisi için 0,99 Bq/kg, test verisi için ise 0,66 Bq/kg olarak hesaplanmıştır. Hesaplanan bu performans indisleri, geliştirilen YSA modelinin MDA değerlerini başarıyla elde ettiğini göstermiştir.

Çalışmanın son kısmında, literatürde ilk defa YSA, NaI(Tl) sintilasyon gama spektroskopisi ile doğal radyonüklit analizleri için uygulanmıştır. Bu amaçla, 126 adet değişik orijinli çevresel materyal; kayaç, toprak, granit, mermer ve gübre örneklerinin ölçümü yapılmıştır. 10000s sayım süresi için radyometrik (IAEA orijinli)  $^{238}\text{U}$ ,  $^{232}\text{Th}$  ve  $^{40}\text{K}$  standartları kullanılarak duyarlılık ve sıyırma katsayıları hesaplandıktan sonra, aynı sayım süresi için bütün örnekler sayılarak konvansiyonel analiz tekniği ile bütün örnekler içerisindeki uranyum, toryum ve potasyum konsantrasyonları hesaplanmıştır. 126 deneysel veri setinin, 101'i (yaklaşık % 80) eğitim sürecinde, geri kalan 25'i (yaklaşık %20) test aşamasında kullanılmıştır. Radyonüklitlerin her birinin konsantrasyonlarının tahmini için, üç farklı model geliştirilmiştir. Geliştirilen YSA modellerinin, radyonüklitlerin konsantrasyonlarını bulmadaki yüksek performansı hayranlık vericidir. Bu heyecan verici sonuçlar, üç radyonüklitin konsantrasyonlarının bir arada elde edildiği yeni bir modeli geliştirmeye teşvik etmiştir. Tüm modellerde, YSA algoritması olarak, radyal tabanlı algoritma (RTANN) kullanılmıştır. Konsantrasyonların tek tek (RTANN-1, RTANN-2 ve RTANN-3) ve üçünün bir arada elde edildiği (RTANN-4) modeller karşılaştırıldığında, hesaplanan performans indisleri arasında ihmal edilecek kadar küçük farklılıklar bulunmuştur. Bu nedenle, kolaylık açısından, RTANN-4 modelinin, örneklerdeki  $^{232}\text{Th}$ ,  $^{238}\text{U}$  ve  $^{40}\text{K}$  konsantrasyonlarını belirlemek için kullanılmasının daha uygun olacağını göstermektedir.

Bu tez çalışmasında oluşturulan tüm YSA modelleri, farklı laboratuvarlardaki gama spektrometrelerinde enerji kalibrasyonu, MDA hesaplamaları ve radyonüklit analizleri için başarıyla ve kolaylıkla kullanılabilir.



## KAYNAKLAR DİZİNİ

- Afşar, S.**, 2008, Yapay Sinir Ağları ve Bulanık Mantık Yöntemleri Kullanılarak Tava Buharlaştırma Tahmini Yapılması, Erciyes Üniversitesi, Yüksek Lisans Tezi, 81s.
- Akal, M.**, 2013, Optimum Öngörü Tekniğinin Seçimi, [www.sakarya.edu.tr/~hgurak/yazilar/makale/ONGOM.doc](http://www.sakarya.edu.tr/~hgurak/yazilar/makale/ONGOM.doc) (03.03.2013).
- Anderson, J.A.**, 1983, Cognitive ve psychological computation with neural models, *IEEE Transactions on Systems, Man and Cybernetics*, 13(5): 799-814 pp.
- Ardıç, S.**, 2014, Yapay Sinir Ağları Kullanılarak Santrifüj Pompalarda Performans Tayini, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 128s.
- Baeza, A., Carpintero, J.M., Guillén, J., Corbacho, J.A., and Pérez, R.**, 2011, A new approach to the analysis of alpha spectra based on neural network techniques, *Nuclear Instruments and Methods in Physics Research Section A Accelerators Spectrometers Detectors and Associated Equipment* 652(1): 450-453 pp.
- Bahadır, Y.**, 2013, Cam elyaf katkılı cephe kaplama elemanlarına yönelik teklif fiyatı tahmininde yapay sinir ağlarının (YSA) kullanılması. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü. Yüksek Lisans Tezi, 119s.
- Barradas, N.P., and Vieira, A.**, 2000, Artificial neural network algorithm for analysis of Rutherford backscattering data, *Physical Review E*, 62: 5818-5829
- Barradas, N.P., Vieira, A., and Patrício, R.**, 2002, Artificial neural networks for automation of Rutherford backscattering spectroscopy experiments and data analysis, *Physical Review E*, 262: 281
- Barradas, N.P., Patrício, R.N., Pinho, H.F.R., and Vieira, A.**, 2004, A general artificial neural network for analysis of RBS data of any element with Z between 18 and 83 implanted into any lighter one- or two-element target, *Nuclear Instruments and Methods in Physics Research Section B Beam Interactions with Materials and Atoms* 219(1):105-109

## KAYNAKLAR DİZİNİ (devam)

- Bayır, F.**, 2006, Yapay Sinir Ağları Ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksel Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, 134s.
- Baykan, U.N.**, 2007, *İnşaat Projelerinde Kaynak İhtiyacının Yapay Sinir Ağları Yaklaşımı ile Tahmini*, Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, 134s.
- Boger, Z., and Karpas, Z.**, 1994, Application of neural networks for interpretation of ion mobility and x-ray fluorescence spectra, *Analytica Chimica Acta*, 292 (3): 243-251 pp.
- Borouhaki, B.**, 2009, Numerical solution of the neutron transport equation using cellular neural networks, *Annals of Nuclear Energy* 36(1):15–27 pp.
- Bos, M., Weber, H.T., and Weber, H.T.**, 1991, Comparison of the training of neural networks for quantitative X-ray fluorescence spectrometry by a genetic algorithm and backward error propagation. *Analytica chimica acta*, 247(1) : 97-105 pp.
- Broomhead, D.S. and Lowe, D.**, 1988, Multi-Variable Functional Interpolation and Adaptive Networks. *Complex Systems*, 2: 327-355 pp.
- Castin, N., Malerba, L., Chaouadi, R.**, 2011, Prediction of radiation induced hardening of reactor pressure vessel steels using artificial neural networks, *Journal of Nuclear Materials*, 408: 30-39 pp
- Correa, R., Chesta, M.A., Morales, J.R., Dinator, M.I., Requena, I., and Vila, I.**, 2006, Artificial neural networks applied to quantitative elemental analysis of organic material using PIXE, *Nuclear Instruments and Methods in Physics Research B* 248: 324-328 pp.
- Currie, L.**, 1968, Limits for qualitative detection and quantification determination. *Analytical Chemistry* 40(3): 587-593 pp.

## KAYNAKLAR DİZİNİ (devam)

- Demeulemeester, J., Smeets, D., Barradas, N.P., Vieira, A, Comrie, C.M., Temst, K., and Vantomme, A.,** 2010, Artificial neural networks for instantaneous analysis of real-time RBS spectra, Nuclear Instruments and Methods B 268: 1676-1681.
- Doğan G.,** 2010, Yapay Sinir Ağları Kullanılarak Türkiye’deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi”, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, 126s.
- Dragovic, S., and Onjia, A.** 2005, Prediction of peak-to-background ratio in gamma-ray spectrometry using simplex optimized artificial neural network. Prediction of peak-to-background ratio in gamma-ray spectrometry using simplex, Applied Radiation and Isotopes: Including Data, Instrumentation and Methods for use in Agriculture, Industry and Medicine 63(3):363-366 pp.
- Dragovic, S., and Onjia, A.** 2007a, Classification of soil samples according to geographic origin using gamma-ray spectrometry and pattern recognition methods, Applied Radiation and Isotopes : Including Data, Instrumentation and Methods for use in Agriculture, Industry and Medicine, 65(2): 218-224 pp.
- Dragovic, S., and Onjia, A.** 2007b, Artificial neural network data analysis for classification of soils based on their radionuclide content, Russian Journal of Physical Chemistry A, 81 (9); 1477–1481 pp.
- Dragovic, S., Onjia, A., Stankovic, S., Anicin, I., and Bacic, G. ,** 2005, Artificial neural network modelling of uncertainty in gamma-ray spectrometry, Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, 540, (2–3): 455-463 pp.
- Dragovic, S., Onjia, A., Dragovic, R., Bacic, G. ,** 2007, Implementation of neural networks for classification of moss and lichen samples on the basis of gamma-ray spectrometric analysis, Environ Monit Assess 130: 245–253 pp.

## KAYNAKLAR DİZİNİ (devam)

- Dragovic, S., Onjia, A., and Bacic, G.,** 2006, Simplex optimization of artificial neural networks for the prediction of minimum detectable activity in gamma-ray spectrometry, *Nuclear Instruments and Methods in Physics Research Section A Accelerators Spectrometers Detectors and Associated Equipment* 564(1):308-314
- Eendebak, R.J.A.H., Lucassen, P.J., and Fitzsimonsi C.P.,** 2011. Nuclear receptors and microRNAs: who regulates the regulators in neural stem cells? *Federation of European Biochemical Societies Letters* 585: 717-722 pp.
- Elman, J.L.,**1990, Finding structure in time, *Cognitive Science*, 14: 179-211 pp.
- Elmas, Ç.,** 2016, Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık.
- Freemana, J., Ketchumb, W., Lewisa, J.D., Poprocki, S., Pronko, A., Rusua, V, Wittichc, P.,** 2012, An artificial neural network base b jet identification algorithm at the CDF experiment. *Nuclear Instrumental Methods Physics Research A* 663: 37-47 pp.
- Garip, Z.Ş.,** 2005, Deprem Etkisindeki Betonarme Yapılarda Yapı-Zemin Etkileşimi", Yüksek Lisans Tezi, SAÜ FBE, Sakarya.
- Gilmore, G.R.,** 2008, *Practical Gamma-Ray Spectrometry*, 2nd Edition, John Wiley & Sons, Ltd
- Gülhan, İ.E.,** 2005. Öngerilmeli Betondan Sandık Kesitli Köprülerin Yapay Sinir Ağları İle Analizi, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 100s.
- Hadad, K., Pourahmadi, M., Majidi-Maraghi, H.,** 2011, Fault diagnosis and classification based on wavelet transform and neural network, *Progress in Nuclear Energy* 53(1); 41-47 pp.
- Hamzaçebi. C.,** 2011, Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Bursa, 14-45.
- Haykin, S.,** 2005, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 9th Ed., India

## KAYNAKLAR DİZİNİ (devam)

- Hebb, D.O.**, 1949, The Organization Of Behaviour, Willey, pp. 335, New York.
- Hernandez-Caraballo, E.A., and Marco-Parra, L.M.**, 2003, Spectrochim. Acta, Part B, 58(12): 2205.
- Hopfield, J.J.**, 1982, Neural networks and physical systems with emergent collective computational abilities, *Proc.Nat.Acad.Sci.*, 79: 2254-2258 pp.
- Hopfield, J.J.**, 1982, Neural network model which combines unsupervised ve supervised learning, *IEEE Transactions on Neural Networks*, 4: 357-360 pp.
- Jiménez, R., Sánchez-Raya, M., Galan, J.A., Flores, J.L., Dueñas, J.A., and Martel, I.**, 2012, Implementation of a neural network for Digital Pulse Shape Analysis on a FPGA for on-line identification of heavy ions, Nuclear Instruments and Methods in Physics Research Section A Accelerators Spectrometers Detectors and Associated Equipment 674:99-104 pp.
- Kaastra, I. and Boyd, M.**, 1996, Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, 10: 215-236 pp.
- Kanevski, M., Arutyunyan, R., Bolshov, L., Demyanov, V., and Maignan, M.**, 1996 Artificial neural networks and spatial estimation of Chernobyl fallout. *Geoinform*, 7: 5-11 pp
- Kasaplı, K.**, 2014, İçmesuyu Şebekelerinde Maliyet Tahmini Amacıyla Yapay Sinir Ağları Kullanımı, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 130s.
- Keller, P.E., and Kouzesl, R.T.**, 1995, Gamma spectral analysis via neural networks, *IEEE Transactions On Nuclear Science*, 38 (4), 971-975 pp.
- Kılıç, Y.**, 2011, Yapay Sinir Ağları Kullanılarak Evapotranspirasyonun Tahmin Edilmesi Ve Deneysel Metotlarla Karşılaştırılması, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 81s.
- Kohonen, T.**, 1982, The self-organized formation of topography correct feature maps, *Biological Cybernetics*, 43: 59-69 pp.

## KAYNAKLAR DİZİNİ (devam)

- Kucuk, N., and Kucuk, I.**, 2006, Prediction of transmitted gamma-ray spectra measured with NaI(Tl) detector using neural network, *Annals of Nuclear Energy*, 33(5): 401-404 pp.
- Kumanhoğlu, A.A.**, 2010, Öngerilmeli Betondan Sandık Kesitli Köprülerin Yapay Sinir Ağları İle Analizi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 270s.
- Matias, V., Ohl, G., Soares, J. C., Barradas, N.P., Vieira, A., Cardoso, S., and Freitas, P.P.**, 2003, Determination of the composition of light thin films with artificial neural network analysis of Rutherford backscattering experiments, *Phys Rev E Stat Nonlin Soft Matter Phys.* 67(4): 046705
- McCulloch, W.S. and Pitts, W.**, 1943, A logical calculus of the ideas immanent in nervous activity, *Bull. Math. Biophysics*, 5: 115-133 pp.
- Medhat, M.E.**, 2012, Artificial intelligence methods applied for quantitative analysis of natural radioactive sources, *Annals of Nuclear Energy* 45:73-79 pp.
- Minsky, M.L., and Papert, S.**, 1969, *Perceptrons*, Cambridge, MA: MIT Press.
- Mól, A.C.A., Pereira, C.M.N. A. Freitas, V.G.G., and Jorge, C.A.F.**, 2011, Radiation dose rate map interpolation in nuclear plants using neural networks and virtual reality techniques, *Annals of Nuclear Energy*, 38: 705–712 pp.
- Moody, J. and Darken, C.J.**, 1989, Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1: 281-294 pp.
- Nene, N., Vieira, A., and Barradas, N.P.**, 2006, Artificial neural network analysis of RBS and ERDA spectra of multilayered multielemental samples, *Nuclear Instruments and Methods in Physics Research Section B Beam Interactions with Materials and Atoms* 246(2):471-478 pp.
- Olmos, P., Diaz, J.C., Perez, J.M., Gomez, P., Rodellar, V., Aguayo, P., Bru, A., Garcia-Belmonte, G., and Pablo, J.L. De**, 1991, A New Approach to Automatic Radiation Spectrum Analysis, *IEEE Transactions On Nuclear Science*, 38 (4), 971-975 pp.

## KAYNAKLAR DİZİNİ (devam)

- Öcal, O.**, 2007, Yapay Sinir Ağları Algoritması Kullanılarak Akarsu Havzalarında Yağış-Akış-Katı Madde İlişkisinin Belirlenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi FBE, Denizli, 105s.
- Öztemel, E.**, 2006, *Yapay Sinir Ağları*, 3. Basım, Papatya Yayıncılık, İstanbul, 25-61.
- Pilato, V., Tola, F., Martinez, J.M., and Huver, M.**, 1999, Application of neural networks to quantitative spectrometry analysis, *Nuclear Instruments and Methods in Physics Research A* 422: 423-427 pp.
- Rosenblatt, F.V.**, 1958, The perceptron : a probabilistic model for information storage and organization in the brain, *Psychological Review*, 65:386-408 pp.
- Rumelhart, D., Hinton, G., and Williams, R.**, 1986, Learning representations by back propagation error, *Nature*, 32: 533-536 pp.
- Rumelhart, D.E., and McClelland, J.L.**, 1986, *Parallel distributed processing: explorations in the microstructure of cognition*, Vol. 1, Cambridge, MA: MIT Press.
- Sahin, M.**, 2007, Karadeniz Bölgesindeki Yağış-Akış İlişkisinin Farklı Yapay Sinir Ağları Metotlarıyla Belirlenmesi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü. Yüksek Lisans Tezi,
- Santhosh, T.V., Kumar, M., Thangamani, I., Srivastava, A., Dutta, A., Verma, V., Mukhopadhyay, D., Ganju, S., Chatterjee, B., Rao, V.V.S.S., Lele, H.G., Ghosh, A.K.**, 2011, A diagnostic system for identifying accident conditions in a nuclear reactor, *Nuclear Engineering and Design* 241(1): 177-184 pp.
- Saritha, M., and Nampoori, V.P.N.**, 2009, Identification of spectral lines of elements using artificial neural networks, *Microchemical Journal* 91: 170 - 175 pp.
- Soycan, Y.T.**, 2008, Yapay Sinir Ağları Yaklaşımı İle Kompaksiyon Parametrelerinin Tahmini, Niğde Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 157s.

## KAYNAKLAR DİZİNİ (devam)

- Specht, D.F.**, 1991, A general regression neural network. IEEE Transactions on Neural Networks, 2 (6): 568 – 576 pp.
- Specht, D.F.**, 1988, Probabilistic neural networks for classification, mapping or associative memory. IEEE Conference on Neural Networks kitabı içinde (525- 532). San Diego.
- Subaşı, H.**, 2010, Yapay Sinir Ağı İle Atıksu Arıtma Performansının Modellenmesi, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 113s.
- Tuo, X., Cheng, B., Mu, K., Li, Z.**, 2008, Neural network-based matrix effect correction in EDXRF analysis, Nuclear Science and Techniques, 19(5): 278-281 pp.
- Tüzün, M.F.**, 2012, Türkiye Turizm Gelirinin Öngörüsünde Zaman Serilerinin Bileşenlerine Ayrıştırılarak Yapay Sinir Ağları Ve Box-Jenkins Yöntemleri İle Karşılaştırmalı Analizi, Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi,
- Şen, Z.**, 2004, Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları: İstanbul.
- Ulucan, Z.Ç., Güneş, N. ve Erdoğan, A.S.**, 1997, Yapay Sinir Ağlarıyla Tablalı Kiriş Kesitlerinin Betonarme Hesabı”, Türkiye İnşaat Mühendisliği 14. Teknik Kongresi, TMMOB İnşaat Mühendisleri Odası İzmir Şubesi, İzmir, 23-25 Ekim 1997.
- Wei, L.**, 2000, Neural Network Model For Distorsional Buckling Behaviour Of Cold-Formed Steel Compression Members, Thesis for the Degree of Licentiate of Science in Technology, University of Helsinki.
- Widrow, G. and Hoff, M.**, 1960, Adaptive Switching Circuit, IRE Western Electronic Show And Convection, Coonvection Record, pp. 96-104

**KAYNAKLAR DİZİNİ (devam)**

- Yaprak, G.**, 1995, Yapay Sinir Ağları Ve Tahmin Modellemesi Üzerine Bir Uygulama, Doktora Tezi, Ege Üniversitesi, Fen Bilimler Enstitüsü, Nükleer Anabilim Dalı.
- Yoshidaa, E., Shizumaa, K., Endoa, S., and Okab, T.**, 2002. Application of neural networks for the analysis of gamma-ray spectra measured with a Ge spectrometer, Nuclear Instruments and Methods in Physics Research A 484: 557–563
- Yurdakul, E.M.**, 2014, Türkiye'de İthalatın Gelişimi Ve İthalatın Yapay Sinir Ağları Yöntemi İle Tahmin Edilebilirliğine Yönelik Bir Analiz, Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi
- Yurtoğlu, H.**, 2005, Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makro Ekonomik Değişkenler İçin Türkiye Örneği, Devlet Planlama Teşkilatı Uzmanlık Tezi, Yayın No: 2683, Ankara.
- Zhang, G., Eddy, P., and Hu, B.Y.**,1998, Forecasting with artificial neural networks, the state of the art, *International Journal of Forecasting*, 14(1): 35-62 pp.

## TEŞEKKÜR

Bu çalışma süresince, her türlü destek ve yardımlarından yararlandığım Tez Danışmanın Sayın Prof. Dr. Günseli YAPRAK'a, ve her türlü konuda yardımını esirgemeyen Ar. Gör. Caner TAŞKÖPRÜ'ye teşekkürü bir borç bilirim.

Sadece tez çalışmamda değil yaşamımın her anında bana olan desteğini ve inancını hiç esirgemeyen eşim Yusuf ERZİN'e sonsuz teşekkürlerimi sunarım

18/ 07/ 2019

Selin ERZİN

## ÖZGEÇMİŞ

1971 yılında Sivas’da doğdum. İlk, orta ve lise eğitimime Sivas’da tamamladıktan sonra, 1987 yılında Cumhuriyet Üniversitesi Fizik Bölümü’nde lisans eğitimime başladım ve 1991 yılında bölüm birincisi olarak mezun oldum. 1992 yılında, aynı üniversitenin fen bilimleri enstitüsünde katıhal fiziği anabilim dalında yüksek lisans eğitimime başladım. Aynı yıl içerisinde, araştırma görevlisi olarak Fizik Bölününde çalışmaya başladım. 1995 yılında yüksek lisans eğitimimi tamamladım. 2008 yılında Ege Üniversitesi Nükleer Bilimler Enstitüsü, Nükleer Bilimler Anabilim Dalında doktora eğitimime başladım. 2000 yılından bu yana Dokuz Eylül Üniversitesi Fen Fakültesi Fizik Bölümü’nde Öğretim görevlisi olarak çalışmaktayım. Evli ve bir erkek çocuğu sahibiyim.