

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TEK A'LI ÇEKİRDEKLERİN TABAN-DURUM MANYETİK
MOMENTLERİNİN SİNİRSEL-BULANIK SİSTEMİYLE
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Bürüce ÖZTÜRK

Biyomedikal Mühendisliği Anabilim Dalı

TEMMUZ 2023

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TEK A'LI ÇEKİRDEKLERİN TABAN-DURUM MANYETİK
MOMENTLERİNİN SİNİRSEL-BULANIK SİSTEMİYLE
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Bürüce ÖZTÜRK

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Hakan YAKUT

TEMMUZ 2023

Bürce Öztürk tarafından hazırlanan “TEK A’LI ÇEKİRDEKLERİN TABAN-DURUM MANYETİK MOMENTLERİNİN SİNİRSEL-BULANIK SİSTEMİYLE BELİRLENMESİ ” adlı tez çalışması 03.07.2023 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı’nda **Yüksek Lisans tezi** olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Hakan Yakut (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Emre TABAR Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Yakup BORAN Sakarya Uygulamalı Bilimler Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “TEK A’LI ÇEKİRDEKLERİN TABAN-DURUM MANYETİK MOMENTLERİNİN SİNİRSEL-BULANIK SİSTEMİYLE BELİRLENMESİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete ’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(03/07/2023)

Bürce ÖZTÜRK





John McCarthy ve Marie Curie' ye ithafen



TEŞEKKÜR

Yüksek Lisans eğitimim boyunca danışmanlığımı üstlenen, tecrübelerini hiçbir zaman esirgemeyen, çalışmalarımı titizlikle yönlendiren ve fikirlerime her zaman değer veren sevgili hocam ve danışmanım Prof. Dr. Hakan YAKUT'a teşekkür ederim.

Çalışmalarımın her aşamasında bana yardımcı olan, her türlü konuda bilgisini ve desteğini üzerimde hissettiğim değerli hocam Doç. Dr. Emre TABAR'a teşekkür ederim.

Yüksek lisans eğitimim boyunca yaptığım çalışmalarda, katkı ve yardımlarının yanı sıra, moral ve motivasyon olarak da sürekli yanımda olan değerli hocalarım Dr. Elif KEMAH ve Dr. Gamze HOŞGÖR'e teşekkür ederim.

Yüksek lisans eğitimimin maddi açıdan desteklenmesine olanak sağlayan Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) Komisyon Başkanlığına (Proje No: 121F267) teşekkür ederim.

Hayatım boyunca maddi ve manevi açıdan her türlü desteklerini üzerimde hissettiğim aileme teşekkür ederim.

Önlerindeki en iyi örnek olabilmek için, her gün daha başarılı ve daha iyi bir insan olmak için çabaladığım yeğenlerim Emir Ahlas YILMAZ ve Rüya PAYZA'nın varlığı için minnettarım.

Bürce ÖZTÜRK



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Manyetik Moment Çalışmaları	1
1.2. Yapay Zekâ Çalışmaları	2
2. TIPTA YAPAY ZEKA UYGULAMALARI	7
2.1. Tıpta Nöro-Bulanık Sistemler	11
3. MATERYAL VE METOD	17
3.1. Yapay Zekâ Yöntemleri	17
3.1.2. Bulanık mantık	19
3.1.2.1. Takagi-Sugeno tipi modelleme	22
3.1.3. Sinirsel (nöro)-bulanık mantık	23
3.1.4. Uyarlamalı sinirsel bulanık çıkarım sistemi (Anfis)	24
3.2. Kuaziparçacık Fonon Nükleer Model (QPNM)	27
4. ARAŞTIRMA BULGULARI	31
4.1. Sayısal Hesaplamalar	31
5. SONUÇ VE ÖNERİLER	43
KAYNAKLAR	45
EKLER	55
ÖZGEÇMİŞ	67



KISALTMALAR

AE	: Oto-Kodlayıcı
ANFIS	: Uyarlanabilir Sinir-Bulanık Çıkarım Sistemi
ANN	: Uyarlanabilir Sinir Ağı
ANOVA	: Varyans Analizi
BCS	: Süperiletkenlik Teorisi
CBR	: Durum Temelli Akıl Yürütme
CNN	: Evrişimli Sinir Ağları
CPI	: Bileşik-Protein Etkileşimi
CT	: Bilgisayarlı Tomografi
DCT	: Ayrık Kosinüs Dönüşümü
DL-CPI	: Derin Öğrenmeye Dayalı Bileşik-Protein Etkileşimi
DNN	: Derin Sinir Ağları
EEG	: Elektroansefalogram
FANFIS	: Hızlı Uyarlanabilir Sinir-Bulanık Çıkarım Sistemi
FIS	: Bulanık Çıkarım Sistemi
FMRI	: Fonksiyonel Manyetik Rezonans Görüntüleme
GARIC	: Genetik Algoritma Destekli Rastgele İzleyici Çizgiler
GLCM	: Gri Seviye Eşleme Matrisi
ILD	: İnterstisyel Akciğer Hastalığı
KPM	: Kuliev-Pyatov Metot
LDA	: Latent Dirichlet Tahsifatı Öğrenme Yöntemi
LSE	: Hata Kare Tahmini
MKL	: Çoklu Çekirdek Öğrenme
MRI	: Manyetik Rezonans Görüntüleme
NEFCIASS	: Nöro-Bulanık Sınıflandırma
NEFCON	: Nöro-Bulanık Kontrolcüsü
NFS	: Nöro-Bulanık Sistem
NON-NPC	: Nöral Olmayan Progenitör
NPC	: Nöral Progenitör

NMR	: Manyetik Rezonans Spektroskopisi
PCA	: Temel Bileşen Analizi
PSO-ANN	: Parçacık Sürü Optimizasyonu Yapay Sinir Ağları
QPNM	: Kuaziparçacık Fonon Nükleer Model
QTDA	: Kuaziparçacık Tamm-Dancoff Yaklaşımı
RMSE	: Kök Kare Ortalama Hatası
SPM	: Tek Parçacık Model
TS	: Takagi-Sugeno
YSA	: Yapay Sinir Ağlar



SİMGELER

A	: Kütle Numarası
Z	: Proton Numarası
W	: Düğüm Ateşleme Kuvveti
g_K	: İçsel Manyetik Moment
g_s^{eff}	: Etkin Spin Jiromanyetik Faktörü
β	: Çekirdeğin Deformasyon Parametresi
δ	: Ortalama Alan Potansiyelinin Deformasyon Parametresi
Δ	: Gap Parametresi
g_R	: Dönme Jiromanyetik Faktörü
I	: Spin
λ	: Kimyasal Potansiyel
N	: Nötron Sayısı
π	: Parite
μ_N	: Manyetik Moment
K	: Toplam Açısal Momentumun Simetri Eksenindeki İzdüşümü
Na	: Sodyum
χ	: Kappa Değeri
σ	: Standart Sapma



TABLO LİSTESİ

Sayfa

Tablo 4.1.	Tek A'lı $^{19-33}\text{Na}$ izotoplarının λ ve Δ çiftlenim parametreleri, δ_2 ortalama alan deformasyonları, Nilsson konfigürasyonları ve deneysel manyetik momentleri verilmiştir.	32
Tablo 4.2.	$^{19-33}\text{Na}$ çekirdekleri için KPM, QTDA, SPM ve QPNM modelleri kullanılarak hesaplanan g_s^{eff}/g_s^r ve g_K değerlerinin deneysel veriler ile karşılaştırılması.....	33
Tablo 4.3.	Tek kütleli sodyum izotoplarının literatürdeki çalışmalar ile karşılaştırılması.....	42



ŞEKİL LİSTESİ

Sayfa

Şekil 3.1. Yapay Sinir Ağı Yapısı.....	17
Şekil 3.2. Bulanık Çıkarım Sistemi.	21
Şekil 3.3. Basit Bir Ağ Yapısı.....	24
Şekil 3.4. Uyarlamalı Nöro-Bulanık Çıkarım Sistemi (Anfis)	25
Şekil 4.1. Deney Sonuçları ve QPNM Hesaplamalarının Uyumı	34
Şekil 4.2. 3 3 3 bulanık kümeye bölünen verilerin eğitim ve test sonuçlarının program çıktısı verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.....	35
Şekil 4.3. 6 6 6 bulanık kümeye bölünen verilerin eğitim ve test sonuçları verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.	36
Şekil 4.4. 10 10 10 bulanık kümeye bölünen verilerin eğitim ve test sonuçları verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.....	36
Şekil 4.5. Üç girişli bir çıkışlı 10 10 10 bulanık kümeye bölünen Anfis Mimarisi ...	37
Şekil 4.6. Eğitim sürecinin veri yakalama oranı ve fit grafiği verilmiştir. Lineerlik çizgisinden sapma gösteren çekirdekler; ⁷⁷ Ga ₃₁ , ⁷⁵ Br ₃₅ , ⁷⁷ Br ₃₅ , ⁸⁵ Kr ₃₆ , ¹³³ Sb ₅₁ , ¹¹⁸ I ₅₃ , ¹⁷⁹ Re ₇₅ , ¹⁸⁵ Au ₇₉ , ²⁰⁷ Tl ₇₁ , ²¹⁷ Ac ₈₉ , ²³⁷ Np ₉₃ , ²³¹ Pa ₉₁ , ²³¹ Ra ₈₈ , ²¹³ Fr ₈₇ , ¹⁹⁹ At ₈₅ , ¹⁹⁷ At ₈₅ . Eğitim süreci için ayrılan 528 çekirdekten 16 tanesi sapma göstermiştir. Bu da eğitim çekirdeklerinin %3'üne karşılık gelmektedir. 39	
Şekil 4.7. Test sürecinin veri yakalama oranı ve fit grafiği verilmiştir. Lineerlik çizgisinden sapma gösteren çekirdekler; ⁹ Li ₃ , ³³ Al ₁₃ , ³¹ S ₁₆ , ³⁷ Cl ₁₇ , ⁴⁷ K ₁₉ , ⁵¹ Ca ₂₀ , ⁴⁹ Ti ₂₂ . Test için ayrılan 124 çekirdek arasında 7 çekirdek sapma göstermiştir. Bu da test çekirdeklerinin %5'ine karşılık gelmektedir.....	40
Şekil 4.8. Sodyum İzotoplarının Spin ve Nötron Numaralarına Göre Manyetik Moment Değerlerinin Yüzey Grafiği	41



TEK A'LI ÇEKİRDEKLERİN TABAN-DURUM MANYETİK MOMENTLERİNİN SİNİRSEL-BULANIK SİSTEMİYLE BELİRLENMESİ

ÖZET

Bu tez çalışması, yapay sinir ağları, bulanık mantık ve sinirsel-bulanık mantık gibi yaygın kullanılan yapay zekâ yöntemlerinin ayrıntılarını ele almakta ve henüz yeni uygulanmaya başlandığı nükleer fizik alanında bu yöntemlerin uygulamasını incelemektedir. Ayrıca, bu yöntemleri en yaygın olarak kullanıldığı sağlık alanında yapılan çalışmaları içeren bir literatür araştırması da sunmaktadır.

Bu tez çalışmasının uygulamasında, proton sayısı (Z) 1 ile 88 arasındaki tek-A'lı deforme çekirdeklerin taban-durum manyetik momentleri hibrit bir yapay zekâ modeli olan Anfis kullanılarak çalışılmıştır. Bu bölgede yer alan $^{19-33}\text{Na}$ çekirdekleri özel olarak incelenmiş ve bu çekirdekler için yapılan Anfis çıkarımları teorik bir yöntem olan Kuaziparçacık Fonon Nükleer Model (QPNM) ile de desteklenmiştir. Bu izotopların manyetik momentleri hem Anfis bazında hem de QPNM bazında ilk kez ele alınmıştır.

Bu bölgedeki çekirdeklerin Anfis bazındaki çıkarımında, deforme çekirdeklerin proton ve nötron sayıları (Z ve N) ve taban-durum nükleer spin değerleri (I) sisteme girdi olarak, manyetik moment değerleri (μ) ise çıktı olarak verilmiştir. $1 \leq Z \leq 88$ arasındaki tek A'lı deneysel değerleri bulunan çekirdeklerin %80'i eğitim ve %20'si test verisi olarak ayrılmıştır. Burada $1 \leq Z \leq 28$ arasındaki deneysel momenti olmayan tek A'lı çekirdekler hakkında çıkarımlarda bulunulmuştur. Örnek olarak da tek-A'lı $^{19-33}\text{Na}$ izotoplarının μ değerlerine ait çıkarımlar yapılmış ve QPNM sonuçlarıyla da teorik olarak desteklenmiştir. Ayrıca QPNM bazında yapılan hesaplamalarda, çalışılan sodyum izotoplarının taban durumlarına ait iç manyetik moment (g_K), manyetik moment (μ_N) değerleri ve efektif spin jromanyetik faktörler (g_s^{eff}) mevcut deneysel veriyle karşılaştırılmıştır. QPNM çerçevesinde yapılan hesaplamalar ayrıca Tek-Parçacık Model (SPM), Kuliev-Pyatov Metodu (KPM) ve Kuaziparçacık Tamm-Dancoff Yaklaşımı (QTDA) sonuçları ile de karşılaştırılmıştır.



DETERMINATION OF THE GROUND-STATE MAGNETIC MOMENTS OF ODD MASS NUCLEI USING NEURO-FUZZY SYSTEM

SUMMARY

This thesis study delves into the intricate details of widely used artificial intelligence methods such as artificial neural networks, fuzzy logic, and neuro-fuzzy logic. It specifically focuses on their application in the emerging field of nuclear physics. Furthermore, the study provides a comprehensive literature review encompassing research conducted in the prominent domain of healthcare, where these methods are extensively utilized.

Artificial neural networks, inspired by biological neural networks, encompass algorithms capable of performing complex computations. These methods excel in analyzing vast amounts of data, enabling pattern recognition, classification, prediction, and decision-making tasks. In the medical field, artificial neural networks have been successfully applied in various areas such as diagnostic support systems, disease prognosis, medical image analysis, and drug discovery.

Fuzzy logic, on the other hand, is a modeling and control approach used to tackle problems involving uncertainty. It operates on imprecise or vague data, resembling human thinking patterns. In medicine, fuzzy logic finds significant applications in diagnostic systems and treatment planning, effectively assessing ambiguous or fragmented information to make accurate and appropriate decisions.

Neuro-fuzzy logic, as a combination of artificial neural networks and fuzzy logic, offers a hybrid approach. This methodology integrates the neurons and weights found in artificial neural networks with fuzzy sets and rules from fuzzy logic. As a result, it facilitates the processing of complex and uncertain data, yielding more precise outcomes. In the realm of nuclear physics, these artificial intelligence methods are relatively novel but show immense potential.

This thesis study not only explores the application of these artificial intelligence methods in nuclear physics but also includes a literature review comprising studies conducted in the healthcare domain where these methods are most commonly utilized. By incorporating the principles of artificial neural networks, fuzzy logic, and neuro-fuzzy logic, researchers have achieved significant advancements in healthcare. These include improved accuracy in disease diagnosis, enhanced treatment planning, and efficient analysis of medical data.

In the practical implementation of this study, a hybrid artificial intelligence model called Adaptive Neuro-Fuzzy Inference System (ANFIS) was employed to investigate the ground-state magnetic moments of odd-A deformed nuclei with proton numbers (Z) ranging from 1 to 88. Specifically, the study focused on the $^{19-33}\text{Na}$ nuclei in this region and supported the Anfis inferences with the Quasiparticle-Phonon Nuclear

Model (QPNM), a theoretical method. The magnetic moments of these isotopes were addressed for the first time using both Anfis and QPNM approaches.

In the Anfis-based inference of nuclei in this region, the proton and neutron numbers (Z and N) of deformed nuclei, as well as the ground-state nuclear spin values (I), were considered as input parameters. Meanwhile, the magnetic moment values (μ) were treated as the output. Experimental data for odd- A nuclei with $1 \leq Z \leq 88$ were divided into 80% training and 20% testing datasets. Inferences were made for odd- A nuclei with no experimental moment data, such as those with $1 \leq Z \leq 28$. As an example, inferences were made for the magnetic moment values of odd- A isotopes $^{19-33}\text{Na}$, which were also theoretically supported by QPNM results. Furthermore, within the QPNM framework, calculations were made to compare the internal magnetic moments (g_K), magnetic moments (μ_N), and effective spin g -factors ($g_s^{\text{eff.}}$) of the studied sodium isotopes with available experimental data. These QPNM calculations were also compared with results obtained from other theoretical methods, including the Single-Particle Model (SPM), Kuliev-Pyatov Method (KPM), and Quasiparticle-Tamm-Dancoff Approximation (QTDA).

The Single-Particle Model (SPM) is a theoretical framework that describes nuclear properties by treating each nucleon as an independent particle moving in an average potential generated by the other nucleons. It simplifies the complex nuclear system by considering single-particle states and their interactions, neglecting correlations and many-body effects. The SPM provides a valuable starting point for understanding nuclear structure and properties.

The Kuliev-Pyatov Method (KPM) is another theoretical approach used in nuclear structure calculations. It is based on a phenomenological model that employs a collective Hamiltonian to describe the behavior of the nuclear system. The KPM takes into account various collective degrees of freedom, such as shape, rotation, and vibration, to provide a comprehensive description of nuclear properties.

The Quasiparticle-Tamm-Dancoff Approximation (QTDA) is a technique that combines aspects of both the SPM and the Tamm-Dancoff Approximation (TDA). The TDA includes particle-hole excitations in addition to the independent-particle states considered in the SPM. By employing the QTDA, one can incorporate both single-particle and collective excitations, allowing for a more accurate description of nuclear structure phenomena.

In the comparison of QPNM calculations with these theoretical methods, the agreement or discrepancies between the results can shed light on the strengths and limitations of each approach. By examining the consistency among different theoretical frameworks, researchers can gain deeper insights into the underlying physics and assess the reliability of predictions for various nuclear properties.

Overall, comparing QPNM with the Single-Particle Model (SPM), Kuliev-Pyatov Method (KPM), and Quasiparticle-Tamm-Dancoff Approximation (QTDA) provides a comprehensive evaluation of the QPNM's performance and its compatibility with other theoretical approaches in nuclear physics. Such comparisons enhance our understanding of nuclear structure and contribute to the refinement of theoretical models in the field.

These QPNM calculations were also compared with results from other theoretical methods such as the Single-Particle Model (SPM), Kuliev-Pyatov Method (KPM), and Quasiparticle-Tamm-Dancoff Approximation (QTDA).

This study showcases the potential and applicability of artificial neural networks, fuzzy logic, and neuro-fuzzy logic in the domain of nuclear physics. Moreover, it demonstrates the utilization of the Anfis method for predicting magnetic moments of odd-A deformed nuclei, complemented by the theoretical calculations performed through QPNM. Overall, this work sheds light on the prospects and practical application of artificial intelligence methods in nuclear physics.

This thesis studied the ground-state magnetic moments of single-A deformed nuclei between 1 and 88 with a proton number (Z) using Anfis, a hybrid artificial intelligence model. The $^{19-33}\text{Na}$ nuclei in this region were specially investigated, and the Anfis inferences for these nuclei were also supported by a theoretical method, the Quasiparticle Phonon Nuclear Model (QPNM). The magnetic moments of these isotopes have been discussed for the first time, both based on Anfis and the basis of QPNM.

In the extraction of nuclei in this region based on Anfis, the proton and neutron numbers (Z and N) and ground-state nuclear spin values (I) of deformed nuclei are given as input to the system, and magnetic moment values (μ) are given as output. Of the nuclei with single A values between $1 \leq Z \leq 88$, 80% were allocated as training data and 20% as test data. The data were arranged repeatedly until the error value for both processes was minimal. Here, inferences are made about the magnetic moments of odd-A nuclei that do not have an experimental moment between $1 \leq Z \leq 28$. As an example, the μ values of odd-A $^{19-33}\text{Na}$ isotopes were deduced, and the Anfis results were compared with other experimental studies on these nuclei in the literature. Surface plots investigated compatibility within this isotope series. The error rate in the training process was 0.04%, and the error rate in the testing process was 0.03%. R^2 values of both processes were calculated. The fact that the error rates are so minimal has made the magnetic moment inferences made by Anfis reliable. In addition, these inferences were theoretically supported by the QPNM results. In addition, in the calculations based on QPNM, the internal magnetic moment (g_K), magnetic moment (μ_N) values, and effective spin gyromagnetic factors (g_s^{eff}) of the ground states of the studied sodium isotopes were compared with the existing experimental data and these results were tabulated. Calculations made within the framework of QPNM are also compared with the results of the Single-Particle Model (SPM), Kuliev-Pyatov Method (KPM), and Quasiparticle Tamm-Dancoff Approach (QTDA).

The results demonstrate that artificial intelligence-supported systems can be successful in both theoretical and experimental studies. The Anfis system proposed in this thesis is the first system adapted for a theoretical study in nuclear structure physics.

In this study, the Anfis system was utilized to predict the magnetic moments of odd-A deformed nuclei. Anfis, which combines artificial neural networks and fuzzy logic methods, is a model capable of analyzing patterns in training data and making magnetic moment predictions. This thesis work establishes the successful application of the Anfis system in theoretical studies within the field of nuclear physics.

The Anfis system holds immense potential, particularly in theoretical studies in nuclear physics. This system has the capability to predict magnetic moment values that have

not been experimentally determined before. Therefore, even in cases where experimental data is unavailable or limited, the Anfis system can generate valuable results.

The findings of this study indicate that artificial intelligence methods can be integrated into theoretical studies in nuclear physics, offering a new approach in the field. The Anfis system can be considered a significant step towards conducting theoretical calculations and may pave the way for new discoveries in nuclear structure physics.

Furthermore, this thesis study demonstrates that artificial intelligence-supported systems can be successful not only in theoretical studies but also in experimental studies. Such systems can be utilized to obtain more comprehensive and accurate results in the field of nuclear physics, as well as potentially leading to new discoveries.

In conclusion, this thesis work illustrates the feasibility of conducting theoretical studies in nuclear physics using the Anfis system. Encouraging the further application of artificial intelligence-supported systems in nuclear physics can add a new dimension to research in the field and inspire future investigations.



1. GİRİŞ

1.1. Manyetik Moment Çalışmaları

Nükleer manyetik momentler, nükleer yapı fiziğinde uzun bir geçmişe sahip önemli bir araştırma konusudur. Bu alanda 1950'li yıllardan günümüze kadar birçok kararlı çekirdeğin nükleer manyetik momentlerinin farklı ölçüm yöntemleriyle (NMR, Lazer Spektroskopisi...vs) belirlendiği çalışmalar vardır [1]. Bu kadar büyük bir nükleer manyetik dipol moment verisini açıklayacak nükleer modeller geliştirilmiş olmasına rağmen hala bu konuda tatmin edici bilgiye ulaştıracak bir teori maalesef yapılamamıştır [2-3]. Bu nedenle, nükleer manyetik moment alanındaki teorik çalışmaların etkin şekilde desteklenmesi için yapay zekâ destekli sistemlerin kullanıldığı alternatif yöntemlere ihtiyaç vardır.

Tek A'lı çekirdeklerde çekirdeklerin yapısının anlaşılabilmesi için taban ve uyarılma durumlarının incelenmesi büyük önem taşır. Özellikle, tek-kütle numaralı çekirdeklerin düşük enerjili spektrumlarında, tek-kuaziparçacık seviyelerinin sayısı oldukça fazladır. Ayrıca çift-çift çekirdeklerde de birçok fonon titreşim modu mevcuttur. Bu iki durum bir arada ele alındığında, tek-A'lı çekirdeklerde birçok kolektif titreşim seviyesinin varlığı söz konusudur [4]. Bu kolektif titreşim durumlarından biri olan manyetik dipol uyarılmalarının çift N-çift Z ve tek-A'lı çekirdeklerde varlığı, deneysel çalışmalarla desteklenmiştir [5]. Tek-A çekirdeklerinin manyetik momentlerinin hesaplanmasında bu kolektif uyarılmaların katkısı oldukça büyüktür. Kolektif titreşim seviyelerinin yapısını anlamak için, tek kuaziparçacık seviyeleri ve fonon titreşimleri arasındaki etkileşimlerin dikkate alınması gerekmektedir [4].

Periyodik tablonun deformasyon bölgesindeki tek A'lı çekirdeklerin taban ve uyarılmış durumları, birçok teorik çalışmada incelenmiştir [6-29]. Deforme çekirdeklerde kuaziparçacıklar ve fononlar arasındaki etkileşimler üzerine yapılan ilk çalışmalar, Soloviev tarafından [30] 1965 yılında, Bes ve Cho Yi-Chung tarafından [31] 1966 yılında gerçekleştirilmiştir. Bunun yanı sıra, Soloviev ve ark. tarafından

yapılan çalışmalarda, nadir toprak bölgesinde yer alan $153 \leq A \leq 175$ aralığındaki tek-A'lı çekirdeklerin enerjileri ve dönmesiz seviye yapılarına ilişkin detaylı hesaplamalar sunulmuştur [32-34]. Gareev ve ark. (1971) tarafından aktinitler bölgesinde yer alan çekirdekler için benzer hesaplamalar yapılmıştır [35]. Bu çalışmalar temel alınarak, Soloviev ve ark. (1976) QPNM adlı daha genel bir yöntemi matematiksel olarak formüle etmişlerdir [36]. QPNM, tek kuaziparçacık seviyelerinin parçalı yapısını, bir fononlu seviyeleri ve kuaziparçacık fonon seviyelerini çok sayıda nükleer seviye üzerinden hesaplayabilme imkânı sağlar [36]. Ayrıca bu model, tek-A'lı deforme çekirdeklerin manyetik momentlerinin ve seviye yapılarının yanı sıra, tek-A'lı küresel çekirdeklerin manyetik momentleri ve seviye yapılarının da teorik olarak incelenmesinde başarılı olmuştur [37-40].

Bunun yanı sıra, tek-A'lı deforme çekirdeklerin spin polarizasyon olayının ve taban durum manyetik özelliklerinin açıklanmasında, Yakut ve diğerleri tarafından geliştirilen QPNM yaklaşımının iyi sonuçlar verdiği görülmüştür [41-44].

1.2. Yapay Zekâ Çalışmaları

Uygulama alanı oldukça geniş olan yapay zekâ kavramı için birçok tanım bulunmaktadır. Yapay zekâ, insanın öğrenmeye yönelik yeteneklerini taklit ederek, bilgisayar sisteminde bu yeteneklerin modellenmesidir. Yapay zekâ araştırmalarının amacı, insan zekâsı gerektiren durumlara cevap verebilecek bir sistem oluşturulmasıdır. İnsan zekasını taklit edip modellemek, problemlere çözüm üretmek, anlamlandırmak, genelleme yapmak, deneyimlemek ve sonrasında probleme uygun olarak karar vermek üzerine çalışmaktadır [45].

Yapay zekâ günümüzde hemen hemen her alanda kullanılabilen bir araç olmuştur. Bu alanlara örnek olarak günümüzde, özellikle sağlık alanında teşhis ve tedavileri, askeri alanda hedef tespiti, endüstriyel alan için kontrol ve tahminin yanı sıra fizik, matematik ve mühendislik gibi fen bilimleri alanında da birçok çalışma için uygulanabilir bir sistem olmuştur. Bu sistemler öğrenme ve çıkarım yapabilme özellikleri sayesinde, sayısal ifadeler ile çalışarak, matematiksel hale getirdiği problemleri kolayca çözebilme becerisine sahiptir. Kullanılan yapay zekâ yöntemlerine kısaca, yapay sinir

ağları, bulanık mantık, sinirsel bulanık mantık, genetik algoritmalar ve uzman sistemler örnek olarak verilebilir. Her bir yöntemin kendi içerisinde avantajları ve dezavantajları bulunmaktadır. Her yöntem her çalışmaya uygun değildir. Uygulanacak probleme yönelik uygun yöntem değişmektedir. Ancak son zamanlarda, yöntemlerin sadece avantajlarını kullanabilen hibrit sistemlerde oluşturulmaktadır [45].

Yapay sinir ağları ve bulanık mantık günümüzde kullanılan en popüler yapay zekâ yöntemleridir. Bulanık mantığın öğrenebilme yeteneğinin olmamasından dolayı probleme kendini adapte edememektedir. Ancak uzman bilgisi ile karar verme mekanizmasına sahiptir. YSA ise bulanık mantıkta bulunmayan öğrenme yeteneğine sahiptir ancak karar verme mekanizması yoktur. Her iki yöntem birbirinin eksik kalan yönlerini tamamlayabilmektedir [45].

Yapay sinir ağları, insan beynindeki biyolojik sinir hücrelerini (nöron) taklit eden bir modelleme yöntemidir. İlk olarak sağlık alanında başlanan çalışmalardan sonra mühendislik ve fen bilimleri alanları içinde cazip bir çalışma konusu olmuştur. YSA, tanıma ve tahmin etme gibi becerilere sahiptir. İnsan zekasına göre işlem gücü, hızı ve doğruluk performansı çok daha güçlü sistemlerdir. Bu özelliklerin dolayı, klasik yöntemler ile çözümü zor olan problemler için kullanılabilir bir yöntemdir [45].

YSA, öğrendiği problemi ezberleyip, bu problem içindeki bilgiler arasında ilişki kurabilmektedir. Sayısal veriler ile hesaplama yapması, bilgi saklaması ve sisteme sunulan bilgileri öğrenebilmesi sayesinde daha önce karşısına çıkmamış durumlara çözüm üretebilmektedir.

YSA, sisteme kendini uyarlayabilmesi sayesinde doğrusal olmayan problemlerinde çözümüne olanak sağlamaktadır. Ancak sistemin çalışmasını analiz edememe, başarısız öğrenme süreçleri gibi dezavantajlara da sahiptir. YSA, bir probleme çözüm ürettikten sonra bu çözümü nasıl ve neden ürettiği hakkında bilgi vermeden sadece sonucu verir. Ağın davranışı hakkında bilgi sahibi olamadığımız için sonucu görene kadarki sürece müdahale edemeyiz [45]. Bu durumu yaşamamak için problemin bütün verileri ağın sistemine uygun olarak girilmelidir.

Günümüzde bulanık mantık ise birçok karmaşık problemin çözümünde tercih edilmektedir. Mühendisler, matematikçiler ve bilim adamları farklı alanlardaki

alışmalarına bulanık mantık sistemleri uygulamaktadır. Bulanık mantık, zamanla deęiřebilen ve doęrusal olmayan sistemlere başarıyla uygulanabilmektedir [46].

Her bir yapay zekâ yöntemi farklı yeteneęe sahiptir. Çalışılan alana göre uygun yöntem seçilmelidir. Her yöntemin kendi avantajları ve dezavantajları vardır. YSA, eğitim ve öğretim yoluyla sınıflandırmada başarılyken; karar alma ve çıkarım yapma konusunda aynı başarıyı sağlayamamaktadır. YSA' nın başarısız olduęu bu hususta bulanık mantık oldukça başarılı sayılır. Bulanık mantık kural tabanları sayesinde iyi bir karar verme mekanizmasına sahiptir. Bulanık mantıkta ise bu kurallar kendilięinden oluşmadıęı için uzman bilgisine ihtiyaç duyulmaktadır. Yöntemlerin tek tek kullanılmasının dezavantajlarının olması sebebiyle, uzmanlar bu yöntemlerin sadece güçlü yönlerinin kullanıldıęı hibrit sistemler üzerine çalışmaya başlamıştır. Yapay sinir aęlarının ve bulanık mantığın güçlü yönlerinin kullanıldıęı hibrit yöntemlere sinir-bulanık (nöro-bulanık) yöntemi denir. Bu yöntem, YSA' nın öğrenme yeteneęi ile bulanık mantığın karar verme mekanizmasının birlikte sunulduęu bir yöntemdir. Nöro-bulanık sistemler, sayısal ve sözel verilerin birlikte açıklanmasına da olanak vermektedir. Her iki yöntemi de kapsadıęı için, öğrenme, sınıflandırma yapabilme, probleme uyum sağlayabilme ve karar verip çıkarım yapabilme özelliklerine aynı anda sahip olan avantajlı bir yöntemdir [45].

YSA ve bulanık mantık sistemleri deneysel çalışmaların yanı sıra teorik çalışmalar içinde iyi birer yardımcı olabilmektedir. Bu tez çalışmasında uygulama olarak, nükleer fizik alanında teorik bir çalışmaya destek olacak nöro-bulanık sistemi oluşturulacaktır. Sodyum izotoplarının manyetik moment hesaplaması hem teorik bir yöntem ile hem de yapay zekâ destekli bir sistem ile yapılmış ve sonuçlar karşılaştırılmıştır.

Nükleer yapı fizięinde, yapay zekâ yöntemlerinin kullanılması gün geçtikçe artmaktadır. Bu yöntemlerin deneysel çalışmalarda kullanılması daha popülerdir. Bu tez çalışması ile bu yöntemlerin teorik bir çalışmaya uyarlanması nadir örneklerden biri olacaktır. Bu alandaki örnek çalışmaları inceleyelim.

Örneęin, Yuan ve ark. (2021) Bayesian sinir aęı yöntemini kullanarak tek A'lı çekirdeklerinin manyetik momentleri hakkında tahminde bulunmuştur [47]. Athanassopoulos ve ark. (2004) sinir aęlarını kullanarak nükleer kütle sistematięini

incelemiştir [48]. Yiğit ve ark. (2022), Logitboost sınıflandırıcı ve yapay sinir ağı kullanılarak deforme olmuş çekirdekler için GDR parametreleri hesaplamıştır [49]. Wang ve ark. (2021) Bayesian ile dev dipol rezonans tahminlerinde bulundu [50]. Bai ve ark. (2021), çok görevli sinir ağları ile dev dipol rezonansın anahtar parametrelerini açıklamıştır [51]. Niu ve ark., 2018'de [52], eşleştirme ve kabuk etkileri ile Bayesian sinir ağı yaklaşımına dayalı nükleer kütle tahminlerinde bulunmuştur ve 2019'da [53] makine öğrenmesi ile nükleer β -bozunma yarı ömürleri tahminleri yapmıştır. Akkoyun (2020), Füzyon reaksiyonu kesitlerini yapay sinir ağları ile tahmin etmiştir [54].

Bu tezde kullanılan yapay zekâ yöntemi Anfis'in nükleer teknolojilerde kullanımı henüz çok yaygın değildir, ancak giderek daha popüler hale gelmesi beklenmektedir. Anfis'in bu alandaki örneklerine baktığımızda, Akın ve ark. (1991) [55], bir PWR-Tipi nükleer enerji santrali için kural tabanlı bir bulanık mantık denetleyicisi üzerinde çalışmışlardır. Heger ve ark. (1995) [56], nükleer reaktör kontrollerinde bulanık mantığı incelemiştir. Na (1999) [57] basınçlı su reaktörlerinde nöro bulanık kontrol uygulamaları yapmıştır. Zio ve ark. (2006) [58] nükleer bileşenlerde hata teşhisi için bir Nöro-bulanık modelini sınıflandırmıştır. Fayiz (2017) [59], Nükleer Santrallerde Güç Kontrolü için Anfis uygulaması üzerinde çalıştı. Luan ve ark. (2021) nükleer reaktörlerin yük izleme kontrolü için bulanık girdi-çıkı modelleri hakkında bir makale yayınlamıştır [60]. Rafiei ve ark. (2022) [61] kavramsal olarak Nöro-bulanık çıkarım sistemi aracılığıyla uranyum yakıtlı yeni bir uzay nükleer reaktörü tasarlamıştır. Akkoyun ve ark. (2021) [62] füzyon engelleri için nöro-bulanık deformasyon parametrelerini modellemiştir. Bu tez çalışmasının konusu nükleer yapı fiziğinde henüz incelenmemiştir. Bu çalışma ile nöro-bulanık sistemlerin bazı uygulamaları ilk defa bu alanda yer alacaktır.

Tek-A'lı çekirdeklerin taban-durum manyetik dipol momentleri nöro-bulanık çıkarım sistemi Anfis kullanılarak ilk defa bu tez çalışmasında ele alınmıştır. Bu tez çalışmasının birinci bölümünde, yapay zekâ yöntemleri ve nükleer manyetik moment hesaplamalarının teorik çalışmaları hakkında kısaca bilgi verilmiştir ve kullanılacak yöntemler kısaca tanıtılmıştır.

Bu tez çalışmasının birinci bölümünde, yapay zekâ yöntemleri ve nükleer manyetik moment hesaplamalarının teorik çalışmaları hakkında kısaca bilgi verilmiştir ve kullanılacak yöntemler kısaca tanıtılmıştır.

İkinci bölümde, yapay zekâ yöntemlerinden en çok faydalanan sektör olan tıp alanında yapılan çalışmalar hakkında geniş bir literatür araştırması bulunmaktadır.

Üçüncü bölümde, kullanılan yapay zekâ yöntemleri ve bu yöntemlerin sonuçları ile kıyaslanacak teorik yöntem olan QPNM hakkında matematiksel ifadeler yer verilmiştir.

Dördüncü bölümde, bu tez konusunu oluşturan tek A'lı $1 \leq Z \leq 88$ arasındaki çekirdeklerin Anfis ile yapılan çıkarım sonuçları ve bu bölgede özel olarak incelenen Sodyum izotoplarının taban durum manyetik momentlerine ait sayısal hesaplama sonuçlarına yer verilmiştir ve bu iki yöntem ve mevcut deneysel veriler karşılaştırılmıştır.

Beşinci bölümde, elde edilen sonuçlar hakkında genel bir çıkarım ve öneriler yer almaktadır.

2. TIPTA YAPAY ZEKA UYGULAMALARI

Tıp ve sađlık veri analizinde son d nemde  nemli ilerlemeler kaydedilmesine rađmen, arařtırma a ıkları ve a ık sorular keřfedilmeyi bekliyor. Bu, rastlantılılık, belirsizlik, hacim, belirsizlik, eksiklik ve eksik verilerin yanı sıra biyomedikal verilerin  eřitliliđi, hızı ve (bol ya da eksik) hacminin verimli bir řekilde ele alınması gerektiđi daha kullanıřlı karar verme sistemlerinin geliřtirilmesi i in daha fazla ve daha derin arařtırmalar gerektiriyor. Geleneksel karar destek tekniklerine kıyasla, yumuřak hesaplama temelli bulanık dil terimlerinin temsili, daha anlařılabilir, belirsizlik farkındalıđına sahip klinik sistemlerin oluřturulması i in basit bir  er eve sađlar. Yalnızca istatistiksel akıl y r tme ile  alıřan sistemlere karřı, bulanık biyomedikal sistemler, bir sađlık sorununun belirsiz kavramsal anlamlarını kodlayan modeller oluřturmanın bir yolunu sunar. Bu sadece analitik yapmakla kalmaz, aynı zamanda yorumlanabilirliđi de kapsar. Bu nedenle, belirsizlikle bařa  ıkmak i in etkili ve verimli bir bulanık sistem tasarlamak, tıp biliminde sađlık hizmetlerinde akıllı izleme, kontrol, teřhis ve tedaviyi geliřtirmek i in yeni ve umut verici bir konudur [63].

Tıpta yapay zek  uygulamaları, ilk olarak 1970'lerde ve 1980'lerde g r lmeye bařlandı. O d nemlerde, uzman sistemler ve karar destek sistemleri gibi basit yapay zek  uygulamaları kullanılmıřtı. Ancak, bug nk  geliřmiř yapay zek  uygulamaları, son yıllarda b y k veri analitiđi, makine  đrenmesi ve derin  đrenme gibi alanlardaki geliřmeler sayesinde ortaya  ıktı.

Tıpta yapay zek nın modern kullanımı, tıbbi g r nt leme ve tanı, hastalık risk fakt rlerinin tahmini ve hastalık  ng r s  gibi alanları i erir. yapay zek nın tıpta kullanımı, hastalıkların erken teřhisi, tedavi planlaması ve sonu ların iyileřtirilmesi i in potansiyel faydalar sađlamaktadır.

 rneđin, g r nt  tabanlı tanımlama ve sınıflandırma, bir ok tıbbi g r nt leme modalitesi i in yapay zek  tarafından kullanılan bir tekniktir. Bu teknik, radyoloji, n ro-radyoloji ve patoloji gibi bir ok alanda kullanılır. yapay zek  ayrıca, hastalıkların erken teřhisi i in kullanılan molek ler g r nt leme ve proteomik verilerinin analizi i in de kullanılır. Bunun yanı sıra, yapay zek , hastaların tedavi yanıtını tahmin etmek

ve hastalığı belirlemek için kullanılan birçok modelleme tekniğinde de kullanılmaktadır.

Tıp alanında derin öğrenme yöntemleri biyoinformatik uygulamalarında yaygın olarak kullanılmaktadır. Bu uygulamalardan bazıları, kanser teşhisi, gen seçimi/sınıflandırması ve gen çeşitliliğidir. 2013 yılında gen çıkarımı verilerini kullanarak farklı kanser türlerini belirlemek, kanser tanısını ve sınıflandırmasını geliştirmek için Fakoor ve ark. [64] derin öğrenme yöntemlerinden Derin Oto-Kodlayıcı yöntemini kullanmışlardır. Bu çalışma 2023 yılında Aydoğan [65] tarafından kullanılarak hastalıkları otomatik olarak tespit edebilen etkili bir sınıflandırma yaklaşımı önerilmiştir. Görüntü işleme ve metin işleme yöntemlerinin hibrit kullanımına dayalı bir yaklaşımla klinik olarak kullanılabilir bir derin makine öğrenme modeli sunulmuştur. Önerilen yöntemde ile Covid-19 hastalığı olan ve olmayan kişilerin verileri değerlendirilerek oldukça yüksek doğruluk payına sahip sonuçlar elde edilmiştir.

Nie ve ark. 2016 yılındaki çalışmalarında [66] yüksek dereceli glioma olarak isimlendirilen en agresif ve şiddetli beyin tümörünün erken teşhisi için Derin Öğrenme yöntemini kullanmışlardır. Bu çalışmalarında, yüksek dereceli glioma hastalarının çok modlu ameliyat öncesi beyin görüntülerinden özellikleri otomatik olarak çıkarmak için derin öğrenme çerçevelerinin kullanılmasını önermektedirler. Spesifik olarak, 3B evrışimli sinir ağlarını (CNN'ler) benimseyerek, çok kanallı verileri kullanmış ve denetimli özellikleri öğrenmek için yeni bir ağ mimarisi önermişlerdir.

Khademi ve ark., [67] göğüs kanserinin genetik teşhisi için 2015 yılında yaptıkları çalışmada, mikro dizilimli verilerden özellik çıkarmak ve eksik özellikleri uyarlamak ve gürültüyü gidermek için derin inanç ağları ile olasılıksal grafiksel modellerden olan Bayesian ağlarını birleştirmişlerdir. Kanserinin temelde genetik bir hastalık olduğunu mikro dizi ve klinik verilerin entegrasyonu bir öngörü modelinin doğruluğunu artırabileceğini ifade etmişlerdir. Bununla birlikte mikro dizi verileri yüksek boyutlu olduğundan genomik değişkenler de dahil olmak üzere büyük ve küçük örneklem büyüklüğü problemlerinden dolayı yapı ve parametre öğrenmede zayıf sonuçlara neden olabileceğini ifade etmişlerdir. Bu problemi manifold öğrenme ve mikro dizi verisine derin inanç ağı uygulayarak ele almışlardır. Klinik verilere yapı öğrenme algoritması uygulayarak klinik modelin yapısını otomatik olarak çıkartmışlar ve daha sonra, bu iki modeli softmax düğümlerini kullanarak entegre etmişlerdir.

2015 yılında Ramsundar ve ark. [68] derin sinir ağlarının ilaç keşfi için bir öğrenme çerçevesi sağladıklarını belirterek çalışmalarında farklı birçok kaynaktan elde edilen biyolojik verileri çok görevli sinir ağı mimarileri ile sentezleyerek ilaç tasarımı yapmaya çalışmışlardır. Bu mimarileri eğitmek için, 200'den fazla biyolojik hedefe yönelik yaklaşık 40 milyon ölçümden oluşan bir veri seti oluşturmuşlardır.

Bileşikler ve proteinler arasındaki etkileşimlerin tanımlanması, ağ farmakolojisi ve ilaç keşfinde önemli bir rol oynar. Bununla birlikte, bileşik-protein etkileşimlerini (CPI'ler) deneysel olarak belirlemek genellikle pahalıdır ve zaman alıcıdır, bu nedenle hesaplamalı yaklaşımlar tanıtılmıştır. Bunlar arasında makine öğrenimi tabanlı yöntemler önemli bir başarı elde etmiştir. Ancak biyolojik verilerin doğrusal olmayan ve dengesiz doğası nedeniyle birçok makine öğrenimi yaklaşımının kendi sınırlamaları vardır. Son zamanlarda, derin öğrenme teknikleri, bazı uygulamalarda son teknoloji birçok makine öğrenme yöntemine göre avantajlar göstermektedir. Tian ve ark. [69] 2016 yılında yaptıkları çalışma ile, derin öğrenmeye dayalı CPI tahmininin performansını iyileştirmeyi hedeflemişler ve bileşik-protein çiftlerinin gösterimlerini etkin bir şekilde öğrenmek için derin sinir ağı (DNN) kullanan DL-CPI (Deep Learning for Compound-Protein Interactions) adlı bir yöntem önermişlerdir. Kapsamlı deneyler, DL-CPI'nin bileşik protein çiftlerinin faydalı özelliklerini katman bazında bir soyutlama ile öğrenebildiğini ve böylece hem dengeli hem de dengesiz veri setlerinde mevcut yöntemlerden daha iyi tahmin performans elde ettiğini göstermişlerdir.

2016 yılında Anthimopoulos ve ark. [70] ILD modellerinin sınıflandırılması için tasarlanmış bir evrişimli sinir ağı (CNN) önermişler ve bunu değerlendirmişlerdir. Önerilen ağ, 2×2 çekirdeğe ve LeakyReLU aktivasyonlarına sahip 5 evrişimli katmandan oluşmaktadır. CNN'yi eğitmek ve değerlendirmek için, farklı tarayıcılardan ve hastanelerden alınan 120 CT taramasından elde edilen 14696 görüntü parçasından oluşan bir veri seti kullanılmış bu set, belirli bir sorun için tasarlanmış ilk derin CNN'dir.

Jiang ve ark. (2015) [71] nöral progenitor hücreleri kısaca NPC'leri ve nöral olmayan progenitor hücreler non-NPC'leri istatistiksel olarak analiz etmek için niceliksel bir hesaplama aracı sağlamak üzere evrişimli Sinir Ağı temeline dayanan bir tanıma sistemi önermişlerdir. Bu sistem iki süreç içerir: görüntü ön işleme ve öğrenme. İlk süreçte amaç, kırılmış hücre görüntülerini normalleştirmek, ardından normalize

edilmiş görüntüleri geliştirmektedir. İkincisinde, tüm bu işlenmiş görüntüler, derin öğrenme tekniği CNN'ler tarafından sağlanan son işlemeyle beslenir. Deneysel sonuçlar, önerilen NPC'lerin CNN'lere dayalı hücre tanıma sisteminin, bilgi teknolojileri yoluyla hücre morfolojisindeki değişiklikleri gözlemlemek, analiz etmek ve tanımlamak için basit ama etkili bir araç olduğunu desteklemektedir.

Xu ve ark. (2016) [72] servikal displazinin tanısal doğruluğunu artırmak için evrimsel sinir ağlarını kullanarak düşük seviyeli görüntü verilerini diğer görüntüsüz modellerle birleştirebilen bir özellik vektörüne dönüştüren çok modlu derin öğrenme yöntemini tasarlamışlardır. Derin sinir ağındaki tüm yöntemler arasındaki doğrusal olmayan korelasyonlar beraber öğrenilmektedir.

2016 yılında Hu ve ark. [73] beyin hastalıklarının teşhisinde ve klinik karar desteği sağlamada derin öğrenmenin avantajlarını göstermek için Alzheimer hastalığını çalışmalarında örnek olarak kullanmışlardır. Öncelikle, ham FMRI 90 beyin bölgesine ait aktiviteleri temsil eden bir matrise dönüştürmüşlerdir. Daha sonra, farklı beyin bölgeleri arasındaki fonksiyonel bağlantıyı göstermek için her bir beyin bölgesi çifti arasındaki korelasyonun hesaplanmasıyla bir korelasyon matrisi oluşturmuşlardır. Sonraki aşamada da Alzheimer hastalığına duyarlı bir korelasyon matrisini sınıflandırmak için oto-kodlayıcı (AE) bir ağ oluşturmuşlardır. Hastalık tahmini ile ilgili deneysel sonuçlar kullandıkları yöntemin geleneksel yöntemlere göre daha başarılı olduğunu göstermiştir.

Beyin işlevleri ile ilgili klinik elektroensefalografi dalga formları için yarı danışmanlı anomali tespitinde derin inanç ağları kullanan Wulsin ve ark. (2011) [74] uyguladıkları yöntem de başarı göstermiştir.

2018 yılında Pereira ve ark. [75] yaptıkları çalışmada bireyin değerlendirilmesi sırasında farklı bilgileri yakalayan, el yazısı dinamikleri tarafından üretilen görüntülerden özellikleri öğrenmek için evrimsel sinir ağlarını tanıtmışlar ve ayrıca bilgisayar destekli Parkinson hastalığı teşhisi ile ilgili araştırmayı desteklemek için görüntülerden ve sinyal tabanlı verilerden oluşan bir veri seti hazırlamışlardır. Yaklaşımları ham veriler ve doku temelli tanımlayıcılarla karşılaştırılarak uygun sonuçlar veren temel olarak erken aşama tespiti bağlamında yaklaşık %95 e varan sonuçlar ortaya koymuşlardır. Derin öğrenme teknikleri kullanılarak el yazısı

dinamiklerinin analizinin, el yapımı özelliklerden daha iyi performans göstermesinin yanı sıra otomatik Parkinson hastalığı tanımlaması için yararlı olduğu gösterilmiştir.

2.1. Tıpta Nöro-Bulanık Sistemler

Hastalıkların erken evrelerinde teşhis edilmesi ve doğru teşhisi farklı durumlara bağlı ölüm oranını azaltacaktır. Bir hastalığın varlığını bulmak için birçok klinik test yapılmaktadır. Son on yılda, tıbbi sistemlerdeki nöro-bulanık uygulamalar bu durumlarda farklı biçimlerde kolaylıklar sağladığından ve doğru sonuçlar sunduğundan yoğun bir ilgi görmüş ve araştırmacılar tarafından zengin bir çalışma alanı haline gelmiştir. NFS, beyin bozukluğu, kalp hastalığı, meme kanseri, Alzheimer, tiroit bozukluğu, lösemi, hipotansiyon, kalp hastalığı vb. gibi çeşitli tipik hastalık teşhisleri için kullanılmaktadır.

2003 yılında Neagoe ve ark. [76] uygulanan Temel Bileşen Analizi (PCA) ve Ayrık Kosinüs Dönüşümü (DCT) yardımıyla iskemik kalp hastalığı teşhisi için EKG sinyallerini tanımak üzere bulanık bir Gauss sinir ağı önermiştir.

2005 yılında Güler ve ark. [77], klinik olarak beyin bozukluklarını araştırmak için kullanılan elektroansefalogram (EEG) sinyallerinin sınıflandırılması için uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) modeli önermiştir.

2011'de Kumar ve ark. [78], kanser oluşumunu saptamak için hızlı uyarlanabilir nöro-bulanık çıkarım sistemi (FANFIS), varyans analizi (ANOVA) adı verilen bir gen sıralama tekniği ile uygulayarak hızlı Anfis'i önermişlerdir.

Sharma ve Mukharjee [79] 2012 yılında bir adaptif nöro-bulanık çıkarım (ANFIS) hibrit genetik algoritması kullanarak Astrocytoma beyin tümörünü tespit etmek için bir görüntü bölütleme tekniği uyguladılar. Bu çalışmayı gerçekleştirmek için yazarlar, Beyin Web'den elde edilen MRI görüntü veri tabanını kullanmışlardır. Görüntü kalitesini artırmak için, öncelikle beyin taramaları histogram eşitleme ve morfolojik işlemler kullanılarak iyileştirildi. Ardından, bulanık C-ortalama algoritması kullanılarak girdi verileri beyaz madde, gri madde, beyin omurilik sıvısı ve anormal tümör bölgesi gibi dört gruba ayrıldı. Daha sonra, Gri Seviye Eşleşme Matrisi (GLCM) kullanılarak özellikler çıkarıldı. Seçim aşamasında, kontrast, homojenlik, entropi gibi yedi önemli ve bilgilendirici özellik genetik algoritma kullanılarak seçildi. Seçilen özellikler daha sonra sınıflandırma için Anfis modeline aktarılmıştır.

Huang ve ark. [80] yine 2012 yılında meme kanseri teşhisinde adaptif nöro-bulanık çıkarım sistemlerinin etkinliğini değerlendirmek için iki makine öğrenme tekniği olan parçacık sürü optimizasyonlu yapay sinir ağı (PSO-ANN) ve durum temelli akıl yürütme (CBR) lojistik regresyon modeli ile karşılaştırmalı bir analiz yapmışlardır. Yazarlar, UCI makine öğrenimi deposundan elde edilen Mammographic Mass Data Set'i kullanmışlar ve deney sonuçları, Anfis'in diğer iki yöntemden daha etkili olduğunu göstermiştir. Anfis %92,8 doğruluğa ulaşırken, PSO-ANN ve CBR tabanlı sınıflandırma yöntemleri sırasıyla %91,10 ve %83,60 doğruluğa sahip olduklarını ifade etmişlerdir.

Kar ve Majumder (2016) [81] aynı yıl içinde, meme kanseri teşhisi için matematiksel şekil teorisi uygulamasıyla nöro-bulanık yaklaşım geliştirdiler. Önerilen yöntem, ön işleme ve bölütleme işlemini içeriyordu ve görüntülerin kalitesini artırmak için gürültü ve istenmeyen bölgelerin kaldırılması yapıldı. Daha sonra, şekil tabanlı özellikler çıkarıldı ve şekil mesafesi ve şekil benzerlik ölçüleri gibi özellikler, tümör tespiti için Anfis'e girdi parametreleri olarak sunuldu ve 10 bulanık kuralı ile kullanıldı.

Manogaran ve ark. [82] yine 2018 yılında uyumlu sinir-bulanık çıkarım sistemi ile çoklu çekirdek öğrenme (MKL) kullanarak kalp hastalıkları teşhisi için bir uzman sistem sunmuştur. Önerilen sistem, yaş, kan basıncı, kan şekeri, kalp atış hızı, vücut sıcaklığı, kolesterol ve göğüs ağrısı türü gibi 7 giriş parametresi ve kalp krizi gibi 1 çıkış parametresi ile her biri 123 kalp hastası verisini kullanmıştır. Bu model, MKL stratejisi kullanarak parametreleri kalp hastalığı olan bireyler ve normal bireyler arasında ayırmayı amaçlamış ve çıktıyı oluşturmak için Sugeno tabanlı Anfis'e sağlamıştır. Bu sayede kalp hastalığı olan hastalar sınıflandırılmıştır.

Beyin tümörünün en tehlikeli nörolojik bozukluklardan biri olması ve bu nörolojik bozukluğun, insan vücudu üzerindeki tehlikeli etkisini azaltacak özel tedaviye sahip olabilmesi için doğru bir şekilde tespit edilmesi gerektiğinden araştırmacılar tarafından yoğun bir şekilde çalışılmaktadır. Günümüzde kullanılan yöntem oldukça zaman alıcı bir süreçtir ve insan hatası olasılığı vardır. Bu dezavantajları ortadan kaldırmak için, beyin tümörlerinin karakterizasyonu için hibrid bir yaklaşım Kshirsagar ve ark. (2020) [83] tarafından ortaya atılmıştır. Önerdikleri çalışmada, beyin tümörlerinin tespiti ve karakterizasyonu için yapay sinir ağı kullanılmıştır. Bu çalışmanın amacı, beyin tümörünü sadece tespit etmekle kalmayıp erken ve doğru bir şekilde sınıflandıran adımların doğruluğunu artırmaktır. Gereken sonucu elde etmek için, üç aşamada

çalışma yapılmıştır: Ön işleme, özellik çıkarımı ve sınıflandırma. Ön işleme tekniği, Gürültüyü gidermek için Gauss filtreleme, görüntü segmentasyonu ve görüntü geliştirme işlemi içermektedir. Özellik çıkarımı için GLCM (Gri Seviye Ko-özüt Matrisi) sistemi kullanılmıştır. Homojenlik, Kontrast, Açısız İkinci Anlık, Entropi, Enerji gibi farklı dokusal özellikler görüntülerden çıkarılır. Karakterizasyon amaçlı olarak nöro-bulanık sınıflandırıcısı kullanılmıştır. Bu önerilen çalışmada kullanılan Anfis sistemi ile görüntüyü ve tümör türünü sınıflandırılmakta ve bu önerilen prosedürle %99,3 doğruluk elde edilmiştir.

2022 yılında Das ve ark. [84] tarafından sunulan çalışmada biyomedikal görüntü sınıflandırması için bulanık yığılmış sınıflandırıcıya sahip bir derin öğrenme modeli önerilmektedir. Önerilen model, sağlıklı ve tümörlü görüntüler içeren beyin görüntüleri veri kümesinde ve Covid hastası sınıflandırması için göğüs X-ışını görüntüleri üzerinde iyi test edilmiş ve doğrulanmıştır.

2023 yılında Kumar ve ark. [85] yaptıkları çalışmada Hindistan'da olası bir salgını öngörmek için bir Anfis tabanlı makine öğrenimi tekniği sunmaktadırlar. Önerilen Anfis tabanlı tahmin sistemi, bulut bilişimden alınan önceki veri kümelerine dayanarak salgının büyümesini takip etmektedir. Önerilen Anfis, sayısal ve dilbilimsel bilgiye sahip olmasının yanı sıra verileri sınıflandırma ve desenleri tanıma yeteneğine sahip olduğu için bu çalışma için seçilmiştir. Önerilen teknik, sadece salgını tahmin etmekle kalmaz, aynı zamanda hastalığı takip eder ve Covid-19 salgını yönetmek için ölçülebilir bir politika da önermektedir. Elde edilen tahmin, Covid-19 salgınının büyümesini çok etkili bir şekilde takip ettiğini göstermektedir. Sonuç, enfeksiyon oranının 2020'nin sonunda azaldığını ve salgın zirvesinin 40-60 gün geciktiğini göstermektedir. Önerilen Anfis tekniği kullanılarak elde edilen tahmin sonucu, 1.184×10^{-3} düşük Ortalama Kare Hata (MSE) ile %86 doğrulukla gösterilmiştir. Çalışma, Covid-19 salgınına kontrol etmek için halk sağlığı sağlayıcıları ve hükümetler için önemli bilgiler sağlamaktadır.

E. Punarselvam 2023 yılında yaptığı çalışmada [86] sağlık bakımı alanındaki en son IoT gelişmeleriyle, ses sinyali analizine dayalı zeki ve akıllı bir Parkinson hastalığı tespit sistemi önermektedir. Parkinson hastalığının tespitine ek olarak, Parkinson hastasının aktivitelerini sürekli olarak izleyen ve teşhis eden uzaktan sağlık izleme özelliği önerilmektedir. Tüm görevleri verimli bir şekilde gerçekleştirmek için önerilen model izleme, teşhis ve analiz olmak üzere üç aşamaya ayrılmaktadır. İzleme

aşamasında, Parkinson hastasının ses sinyali IoT sensör özellikli akıllı telefon cihazı aracılığıyla izlenir ve yakalanır. Bu ses sinyali, teşhis aşamasında MEC sunucusu üzerinden PD tespiti için işlenir. Bu işlenmiş özellikler, Parkinson hastalığını tespit etmek için Anfis sistemine uygulanmaktadır. Parkinson tespit edildiğinde, önerilen sağlık izleme sistemi hemen hasta için bildirim oluşturmakta ve aynı anda tespit raporunu merkezi sağlık bulut sistemine göndermektedir. Bu Parkinson hastalığı tespiti raporu, analiz aşamasında sağlık uzmanı tarafından incelenmekte ve Parkinson hastası kişiye veya bakıcısına uygun tedavi ve ilaç gönderilmektedir. Önerilen hibrit sınıflandırıcı diğer sınıflandırıcılarla karşılaştırarak doğruluk, duyarlılık ve özgüllük parametreleri üzerinden analiz edilmiştir. Sonuç analizi temelinde, önerilen hibrit sınıflandırıcının diğer sınıflandırıcılara kıyasla %98,23 doğruluk, %99,1 duyarlılık ve %95,3 özgüllük sağladığı gözlemlenmiştir.

Lösemi için teşhis ve sınıflandırma sistemlerine yardımcı olan Anfis gibi birçok araç tanıtılmış ve mükemmel bir işlev yaklaşımı aracı olarak da gösterilmiştir. Anfis, nöro-bulanık sistemlerin özelliklerini sonuçlandırmak için kullanılan ANN (adaptif sinir ağı) teorisini de kullanır. Ancak doğruluk seviyesi yeterli değildir. Bu dezavantajı aşmak için, özellik eğitim verisi ile test özellik verisi arasındaki mesafeyi ölçmek için Öklid mesafesi kullanarak lösemi verilerini tahmin etmek için geliştirilmiş Anfis modeli Rejula ve ark. [87] tarafından 2023 yılında önerilmiştir. Giriş uzayının bulanık kümelerle bölümlenmesine yardımcı olan geliştirilmiş uyarlanabilir bulanık sinir ağı tanıtılmıştır. Bu, hesaplama karmaşıklığı azaltılan bir yaklaşımdır ve geçerlilik fonksiyonuna göre kümeler arasındaki ayrım ve sıkışıklığa dayanarak bulanık kural sayısı belirlenmektedir. Daha sonra, önsel parametreler ve sonuç parametreleri ileri ve geri geçişleri kullanan hibrit bir öğrenme algoritması ile eğitilip, ilkelerin parametreleri sırayla düzenlendikten sonra, 4. katmana kadar olan bir düğüm, her düğüm için sonuç parametrelerini Hata Kare Tahmini (LSE) kullanarak hesaplamakta ve her düğüm için bir hata ölçüsü hesaplanmaktadır. Geriye doğru geçişle gradyan düşüşü kullanılarak hata sinyalleri ilkesel parametreleri güncellemek için dağıtılmaktadır. İyileştirilmiş Anfis, tüm hücre tipleri için özellikle mikroskobik kan hücresi veri setinde en iyi doğruluğu, hassasiyeti ve özgüllüğü (%97 %96 ve %90) sağlamaktadır.

Tıpta Anfis ve yapay zekâ teknolojileri yukarıda sadece birkaç tanesi verilen örneklerde görüldüğü gibi son yıllarda önemli bir ilerleme kaydetmiştir. Bu

teknolojiler, hastalıkların teşhis ve tedavisinde, ilaç keşfi ve geliştirme sürecinde, medikal görüntü işleme ve analizinde, sağlık hizmetlerinin planlanmasında ve yönetiminde önemli bir rol oynamaktadır.

Özetle, Anfis, sinir ağı ve bulanık mantık sistemlerinin birleşiminden oluşan bir yapay zekâ modelidir. Bu model, karmaşık veri setleri üzerinde doğru sonuçlar üretme kabiliyeti sayesinde tıpta kullanımı giderek artmaktadır. Anfis, tıbbi verileri analiz etmek ve hastalıkların teşhisinde yardımcı olmak için kullanılan bir araçtır. Yapay zekâ teknolojileri de tıp alanında büyük bir potansiyele sahiptir. Bu teknolojiler, büyük veri kümelerini analiz ederek hastalıkların teşhis ve tedavisinde yardımcı olmak, ilaç keşfi ve geliştirme süreçlerini hızlandırmak ve sağlık hizmetlerinin planlanmasını ve yönetimini optimize etmek için kullanılmaktadır.

Sonuç olarak, tıpta Anfis ve yapay zekâ teknolojileri, hastalıkların teşhis ve tedavisinde, ilaç keşfi ve geliştirme sürecinde, medikal görüntü işleme ve analizinde, sağlık hizmetlerinin planlanması ve yönetiminde önemli bir rol oynamaktadır. Bu teknolojilerin kullanımı sayesinde, tıp alanında daha doğru, hızlı ve etkili sonuçlar elde edilebilmektedir.




3. MATERYAL VE METOD

3.1. Yapay Zekâ Yöntemleri

3.1.1. Yapay sinir ağları (YSA)

Sinir hücreleri, birbirlerine bağlı, paralel işleyen bir ağ yapısı oluşturmaktadır. Bu ağ yapısı, öğrenme ve uyum sağlama yeteneğine aksonlar sayesinde sahip olmaktadır. Aksonlar, insanların sinir hücrelerine gelen sinyalleri diğer sinir hücrelerine aktarmakla görevli elemanlardır. Yapay sinirlerde de öğrenme süreçlerinde girdi değerleri ağ boyunca aksonlar yardımıyla iletilmektedir. Bu yüzden aksonlar ağ yapıları için önemli bir parametredir. Bir yapay sinir ağı; Girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş temel süreç elemanından oluşmaktadır [45].



Şekil 3.1. Yapay Sinir Ağı Yapısı.

Şekil 3.1’de $X_{1,2,...,m}$ değerleri girişleri temsil etmektedir. Bu değerler ağırlık değerleri olan $W_{1,2,k}$ değerleri ile çarpıldıktan sonra elde edilen bilgiye bias denilen eşik değeri eklenir. Sonrasında aktivasyon fonksiyonu uygulanır ve nihai çıktı bilgisi ağdan alınmış olur. Burada ağırlık değerleri değiştirildikçe ağın vereceği çıktılar değişmektedir. Ağırlık değerleri, girdilerin ağ yapısına olan etkisini gösteren katsayılardır. Bu katsayı büyükse çıktığında, ağırlığa ait giriş önemli kabul edilmektedir; ancak küçük bir değer ise ağ yapısını çok etkilemediği anlamına gelmektedir. Toplama fonksiyonu ise, sinir hücresine gelen tüm girdilerin ağırlıklarla,

çarpıldıktan veya toplandıktan sonra sinir hücresinin net girdi değerini gösteren bir fonksiyondur. Toplama fonksiyonunun belirlenmesinde girdilerin sayısı dikkate alınmalıdır; ancak belirli bir kıstasa sahip değildir, deneme yanılma yolu ile belirlenmektedir. Aktivasyon fonksiyonu ise, toplama fonksiyonundan sinir hücresine gönderilen net girdiye karşılık üretilecek net çıktıyı hesaplayan fonksiyondur. Probleme göre aktivasyon fonksiyonu türü belirlenmektedir. Doğrusal olmayan bir probleme uygun bir sonuç oluşturulması için doğrusal olmayan fonksiyonlar tercih edilmelidir. Geri beslemeli ağlarda, geriye yönelik hesap yapılırken aktivasyon fonksiyonunun türevi alınmaktadır. Burada hesaplama maliyetinin artmaması için kolay türevlenebilen fonksiyonlar tercih edilmektedir. Çok katmanlı sinir ağlarında, doğrusal olmayan problemlerde, kolay türevlenebilir olmasından dolayı sigmoid fonksiyonu kullanılmaktadır [45].

$$F(NE) = \frac{1}{1 + e^{-NE}} \quad (3.1)$$

Sigmoid fonksiyonu, türevi alınabilen sürekli bir fonksiyondur. Bu nedenle çoğunlukla doğrusal olmayan problemler için kullanılmaktadır. Fonksiyon girdilerine karşılık 0 ile 1 arasında bir değer üretmektedir [45].

YSA için öğrenme işleminde giriş verileri dış dünyadan sisteme verilir. Sonrasında bu veriler işlenir ve sistem bir çıkış değeri üretir. Sistemin çıkışı eğitim verilerinden girişe karşılık gelmesi gereken değer ile beklenen değer karşılaştırılarak hata oranı bulunur. Öğrenme algoritmaları değiştirilerek hata değeri azaltılmaya çalışılır ve beklenen çıkış değerine yaklaşılması beklenir. Ağ öğrendikten sonra, sisteme daha önce verilmeyen test değerleri çıkışları verilmeden sunulur. Eğer ki ağ, daha önce karşılaşmadığı bu giriş değerlerine de iyi sonuç veriyorsa, ağ problemi ezberlemeden öğrenmiş demektir. Eğitim setindeki veriler ağa sunularak, verileri öğrenmesi sağlanır. Sonrasında test verileri girilerek ağın performansı ölçülür. Öğrenme sürecinde bazen hata oranı istenen seviyenin altına inmeyebilir. Bu durumda ağın yapısında, eğitim ve test verilerinde, bu verilerin sayısında ve öğrenme algoritmalarında değişiklik yaparak sistem tekrar eğitim sürecine girmelidir.

3.1.2. Bulanık mantık

İnsanların günlük hayatta karşılaştıkları problemlerin bazıları kolayca tanımlanıp çözüme ulaşabilirken; bazı problemler belirsizlik içerdiğinden çözümü zorlaşmaktadır. Düşünce sisteminin bazı durumlarda yetersiz kalması, zihnin bazı olayları kavrayamaması belirsizliklerin ortaya çıkmasına sebep olur. Bu belirsizlikler bulanıklık olarak tanımlanır. 1965 yılında Lutfi Zadeh tarafında geliştirilen bulanık küme mantığı, klasik mantığa belirsizlik katmıştır [88]. Klasik küme mantığı, “Bir değer bir kümenin elemanıdır ya da o kümenin elemanı değildir “üzerine kuruludur. Bu elemanların kümeye ait olmaları 1 ve 0 değerlerinin atanmasıyla belirlenir. Klasik kümelerde, bir X kümesinin ait olduğu bir A alt kümesi için, kümeye ait karakteristik fonksiyon X_A olarak tanımlanır. X kümesine ait elemanlar karakteristik fonksiyon yardımıyla $\{0,1\}$ elemanlarına dönüştürülür. Bu şekilde kümenin tanımı [89] :

$$X_A : X \rightarrow \{0,1\} \quad (3.2)$$

olarak verilir. Fonksiyonda 1 değerine sahip elemanlar kümenin elemanı iken 0 değerine sahip elemanlar kümenin elemanı değildir. Bu mantık dahilinde kısmi üyelikten söz edilemez. Üyelik derecelerinin ön plana çıktığı kümeler ise bulanık kümelerdir. Bulanık kümenin elemanlarının belirlenmesinde, kümeye aittlik derecesi önem taşımaktadır. Bu derecelendirmelerden ötürü küme sınırları belirsizleşmektedir. Belirsizliğin ölçülmesi için bir fonksiyon tanımlanır. Bu fonksiyon, küme elemanlarını derecelendirir. Üyelik derecesinin belirlenmesi için kullanılan bu fonksiyon üyelik fonksiyonu; oluşturulan kümede bulanık küme olarak tanımlanır. Bulanık kümelerde bir eleman kümeye, biraz ait ya da biraz ait olmayabilir. Aynı üyelik derecesi ile farklı iki kümeye veya farklı dereceler ile aynı kümeye de ait olabilir. Bulanık kümelerde, klasik kümelerdeki gibi keskin sınırlar yoktur, esnek bir yapıya sahiptir. Problem uzayında, eğer ki çözüm yöntemi belirlenmişse, üyelik derecelerinin sınırları olmadığından problemi hızlı bir şekilde çözmeyi sağlamaktadır. Ancak üyelik derecelerinin ve fonksiyonlarının belirlenmesinde belirli bir yöntem yoktur. Probleme en uygun yöntem deneme-yanılma ile bulunmaktadır. Bu yüzden sistem için optimum bir model oluşturmak zaman alabilmektedir. Sistemin nasıl bir cevap vereceğinin kestirimi önceden yapılamaz ancak benzer çalışmalardan çıkarım yapılabilmektedir.

Üyelik derecelerinin belirlenebilmesi için çok sayıda üyelik fonksiyonu bulunmaktadır. En çok kullanılan üyelik fonksiyonları, üçgen, yamuk, çan eğrisi ve Gaussian fonksiyonlarıdır [45].

Üçgen üyelik fonksiyonunda, başlangıç(a), bitiş(c) ve en çok üyelik derecesine sahip olunan noktalar(b) olmak üzere üç parametre bulunmaktadır. En çok üyelik derecesine sahip olma durumu tek bir nokta bulunması gereken durumlarda tercih edilmektedir [90].

$$f(x, a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (3.3)$$

Yamuk üyelik fonksiyonlarında, fonksiyonun başlangıcı(a), bitiş(d), en çok üyelik derecesine sahip olma durumu başlangıcı(b) ve bitiş(c) olmak üzere dört parametreden oluşmaktadır. En fazla üyelik derecesine sahip olma durumu süreklilik taşıyan durumlarda tercih edilmelidir [91].

$$f(x, a, b, c) = \max \left\{ \min \left\{ \frac{x-a}{b-a}, 1, \frac{d-x}{d-c}, 0 \right\} \right\} \quad (3.4)$$

Gaussian üyelik fonksiyonlarında, merkez(c) ve standart sapma(σ) parametreleri kullanılır [92].


$$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (3.5)$$

Çan eğrisi üyelik fonksiyonunda (a,b,c) olmak üzere üç parametre bulunmaktadır [93].

$$f(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad (3.6)$$

Her fonksiyon çalışma konusuna uygun olarak seçilmeli ve girişler fonksiyonların formüllerine uyarlanmalıdır.

Bulanık mantık algoritmalarında birbirini takip eden üç birim bulunmaktadır. Her bir birim farklı bir işlem basamağını temsil eder ve birimler birbirleri ile ilişkilidir.



Şekil 3.2. Bulanık Çıkarım Sistemi.

Sistemin çalışmaya başlayabilmesi için öncelikle, çözülmesi istenen probleme ait giriş verileri sisteme dahil edilir. Bulanık kümelerde giriş verilerinin belirsizlik ilkesini sağlaması için, algoritmanın ilk birimi olan bulanıklaştırma işlemi yapılmaktadır. Bulanıklaştırma işlemi, probleme uygun olan üyelik fonksiyonları ile bulanık kümelerin oluşturulmasıdır. Bu işlem ile verilerin kümeye aitlik dereceleri belirlenir [94].

Bulanıklaşmış veriler sistemin çıkarım motoru birimine gelir. Burada, sisteme kural tabanları sunularak, tüm giriş-çıkış verilerinin kontrolü sağlanır. Bulanık çıkarım motoru, sistemin karar vermesine yardımcı olmak için bu kuralları tek tek işleyerek çıkardığı sonuçları toplar. Kural tabanları, giriş birimindeki verileri, çıkış birimindeki veriler ile IF-THEN kuralları çerçevesinde ilişkilendirir. Sistemin, bu kurallar sayesinde mantıklı bir karar vermesi sağlanır. Bir kural tabanı, “IF A=x VE B=y THEN N=k” şeklinde tanımlanır. Burada A ve B problemin giriş değerlerini, x ve y kümelerdeki üyelik derecelerini temsil etmektedir. Problemin gerektirdiği şekilde, parametreler VE/VEYA işlemleri ile toplanır veya çarpılır.

Kural tabanları yardımıyla sistemin oluşturduğu çıkarımlara, çıkışa verilmeden önce durulaştırma işlemi yapılması gerekmektedir. Durulaştırma, bulanık haldeki verilerin gerçek sayı değerlerine dönüştürülmesidir. Bulanık yapıdan çıkan gerçek sayılar çıkışa sistemin çıkarım sonucu olarak verilmektedir.

Bulanık çıkarım sistemlerinde, Mamdani tipi ve Takagi-Sugeno tipi olmak üzere iki ana modelleme yöntemi bulunmaktadır. Mamdani yöntemi, sezgisel hesaplama yetkinliği nedeniyle sözel verilerin modellenmesi için kullanılır. Mamdani tipinde

modelleme basittir ve diğer bulanık mantık tipleri bu model temel alınarak oluşturulmuştur. İnsan davranışlarına ve sezgisel yaklaşımlarına benzerdir [45].

3.1.2.1. Takagi-Sugeno tipi modelleme

1985 yılında oluşturulan Takagi-Sugeno tipi modelleme sistemi çıkarım yapabilmek için matematiksel ifadeleri kullanmaktadır. Bu model, Mamdani tipinin matematiksel bir uyarlaması olarak gösterilmektedir. Mamdani tipinin kullanımı çok daha kolaydır ancak Takagi-Sugeno gösterim açısından daha elverişlidir. Her iki yöntemde de bulanıklaştırma ve diğer işlemler aynı sırayla yapılırsa da T-S tipinin çıkışı matematiksel olarak lineer veya sabit sonuçlar içermektedir [45].

Örnek olarak iki girişi (x_1, x_2) ve bir çıkışı (f) olan bir T-S sistemi için “IF-THEN” kuralları şu şekilde verilmektedir [95].

Kural 1= IF $x_1=A_1$ ve $x_2=B_1$ THEN $f_1(x,y)=p_1x+q_1y+r_1$

Kural 2= IF $x_1=A_2$ ve $x_2=B_2$ THEN $f_2(x,y)=p_2x+q_2y+r_2$

Bu eşitliklerde A ve B’ler bulanık kümelerdeki üyelik fonksiyonlarını, x ve y girişlerin bulanık kümelerini, f çıkış değişkenini ve p,q,r sonuç parametrelerini temsil etmektedir [96]. Oluşturulan küme sayısına göre kural sayısı ve devamında eşitliklerin indisleri değiştirilmelidir.

T-S tipi modellenmenin matematiksel yönü kuvvetli olduğundan hesaplama yapmak için çok uygundur. T-S sistemi, karmaşık bir doğrusal olmayan sistemi bir dizi daha basit doğrusal model olarak temsil etme fikrine dayanmaktadır [89]. Bazı problem için matematiksel denklemler kuralların çıkışlarını direk hesaplayabiliyorsa, sistemde durulaştırma işlemi yapmaya gerek yoktur. Doğrusal olmayan sistemlerin çözümü için de kullanılabilen karmaşık yapıları bir modelleme tipidir [97].

T-S bulanık mantık sistemi, her kuralın yerel bir doğrusal modele karşılık geldiği bir dizi bulanık IF-THEN kuralından oluşur [98-100]. T-S bulanık mantık sistemi, kontrol mühendisliği, sinyal işleme ve örüntü tanıma dahil olmak üzere birçok alanda yaygın olarak kullanılmaktadır. Karmaşık doğrusal olmayan sistemleri ve


belirsizlikleri ve uygulama kolaylığını ele alma yeteneđi, onu birçok uygulamada popüler bir seçim haline getirir.

3.1.3. Sinirsel (nöro)-bulanık mantık

Bulanık mantık yönteminde giriş parametrelerinin belirlenmesinde belirli bir yöntem olmadığından deneme-yanılma yöntemi ile belirlendiğinden bahsedilmişti. Nöro-bulanık sistemlerde bu parametrelerinin belirlenmesinde bazı öğrenme yöntemleri kullanılmaktadır. Hesaplanacak deęişken sayısı, kural sayıları ve girişlerin üyelik fonksiyon aralıklarının öğrenme süreci başlamadan belirlenmesi gerekmektedir. Nöro-Bulanık yöntemi ile oluşturulan sistemler genel olarak çok katman olarak oluşturulmaktadır. Anfis, Garic, Nefclass ve Nefcon gibi mimariler bu sisteme örnek olarak verilebilir [101-103]. Bu örnekler arasında en popüler olanı Anfis mimarileridir. Anfis, Sugeno tipi bir mantık sistemiyken; dięer örnekler Mamdani tipi mantık sistemleridir.

Nöro-bulanık sistemlerle öğrenme yöntemleri, bulanık mantık prensipleri ile davranan, sinir aęları gibi öğrenen modeller geliştirmeyi sağlamaktadır. Bu sebeple hem YSA ile çözülebilen problemlere hem de bulanık mantık ile çıkarım yapılabilen durumlara kolaylıkla uygulanabilmektedir. Teşhis, tanıma, sınıflandırma, karar verme, hesaplama yapabilme gibi doğrusal ve doğrusal olmayan birçok probleme çözüm getirebilmektedir. Dolısıyla birçok alana uyarlanabilmektedir. Hibrit sistemlerde hesaplama zamanı ve performans seviyesi, yöntemlerin tek tek kullanılmasından çok daha iyidir ancak öğrenme süreci uzun sürüp maliyetli olabilmektedir.

Nöro-Bulanık aę yapıları içerisinde giriş bilgileri ile katmanlar arasındaki bağlantılar bulunmaktadır. Aę yapısının içerisine giriş bilgileri verilir ve bu bilgiler bir sonraki katmana iletilerek en son bir çıkış deęeri üretilir.



Şekil 3.3. Basit Bir Ağ Yapısı.

i.düğüm için; Çıkış_{1, i}= x₁w_i olarak ifade edilir. Her çıkıştan elde edilen ürünler toplanarak ağın çıkış ürünleri hesaplanır [45].


$$Ağ = Çıkış_{ilk, i} + \dots + Çıkış_{son, i} = x_{ilk}w_{ilk} + \dots + x_{son}w_{son}$$

Sonrasında ağ yapısına uygun olarak bir aktivasyon fonksiyonu seçilir ve ağ çıkışı hesaplanır.

3.1.4. Uyarlamalı sinirsel bulanık çıkarım sistemi (Anfis)

Anfis, uyarlamalı sinirsel bulanık çıkarım sistemi anlamına gelen, öğrenme yeteneği olan bir sinirsel ağ yapısıdır. Bu yapı, sinir ağlarının öğrenme yeteneği ile bulanık mantığın çıkarım yapabilme özelliklerini eş zamanlı yapabilen melez bir yapay zekâ yöntemidir. 1993 yılında Jang tarafından geliştirilen, Takagi-Sugeno tipi modelleme sistemi tabanlı bir yöntemdir [94]. Bu sistem çözümü zor, doğrusal olmayan problemlerde bile iyi sonuçlar üretebilmektedir [89]. Giriş ve çıkış verileri arasında ilişki kurarak probleme uygun kuralları sistem kendi oluşturabilmektedir. Bu sayede bulanık mantık formülleri ile işleyen ve sinir ağı yapısıyla öğrenen avantajlı bir sistem olmaktadır.

Anfis birbirleri ile ilişkili katmanların düğümler ile birleştirilerek oluşturulduğu bir mimaridir [89]. Bu mimari beş katmandan oluşmaktadır. Her bir düğüm farklı bir işlem birimini temsil etmektedir.



Şekil 3.4. Uyarlamalı sinirsel-bulanık Çıkarım Sistemi (Anfis).

İlk katmandaki her düğüm, girdi verilerinin üyelik derecelerinin üretilmeye başlandığı yeri temsil etmektedir. Probleme uygun olarak seçilen üyelik fonksiyonunun matematiksel formülü, girdi sayısına göre uyarlanır. Örneğin, Gaussian fonksiyonu uygulanan iki girişli bir sistemi ele aldığımızda, bu üyelik derecesi şu şekilde formüle edilmektedir [92];

$$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (3.5)$$

eşitliği Gaussian fonksiyonunu temsil etmekteydi. Bu fonksiyon içerisinde standart sapmayı (σ) ve ortalamayı (c) belirtmek için parametreler kullanılır. Bu formülü x_1 ve x_2 olan iki girişli bir sisteme adapte etmek istersek;

$$Q_{1,i} = \mu_{A_i}(x_1(t)) = e^{\frac{1}{2} \left(\frac{x_1 - c_i^{x_1}}{\sigma_i^{x_1}} \right)^2} \quad (3.6)$$

$$Q_{1,i} = \mu_{B_{i-1}}(x_2(t-1)) = e^{\frac{1}{2} \left(\frac{x_2 - c_i^{x_2}}{\sigma_i^{x_2}} \right)^2} \quad (3.7)$$

şeklinde Gaussian formülünü iki girişimize de uyarlamamız gerekmektedir. Burada $Q_{1,i}$, 1. katmandaki i düğümünü temsil etmektedir. A_i ve B_{i-1} değerleri bulanık kümeleri, t ve $t-1$ ise girişlerin düğümlere göre sırasını göstermektedir. Bu işlem ile girdi değerlerinin bulanık kümeye ait olmak derecesini hesaplamış olmaktadır.

Katman 2'deki her düğüm, öncesinde probleme uygun olarak oluşturulan bulanık kuralların etkisinin sisteme tanıtıldığı kısımdır. Burada 1. katmandaki üyelik dereceleri VE/VEYA operatörleri ile işleme alınır. Örnek sistemimizde VE operatörünü ele aldığımızda bu katmandaki bulanık işlemde çarpma işlemi yapılır ve şu şekilde ifade edilmektedir;

$$Q_{2,i} = W_i = (\mu_{A_i}(x_1(t))) \cdot (\mu_{B_{i-1}}(x_2(t-1))) \quad (3.8)$$

Katman 3'teki her düğüm sabit bir düğümdür. Burada 1. katmandaki bulanıklaştırılan veriler i. düğümdeki ateşleme gücünün diğer tüm kuralların ateşleme güçlerinin toplamına oranı hesaplanarak ateşleme gücü normalleştirilir.

$$Q_{3,i} = W'_i = \frac{W_i}{W_1 + W_2 + \dots + W_k} \quad (3.9)$$

Burada ateşleme kuvvetleri, Anfis sisteminin içerisinde her bir girdinin ayrıldığı bulanık küme sayısı kadardır. Örneğin, iki girdi değeri 5'er kümeye ayrıldıysa, ateşleme kuvveti olan W_k değeri W_5 'e kadar hesaplanmalıdır.

Katmandaki 4'teki i düğümü, Anfis yapısına girerken bulanıklaştırılan değerlere durulaştırma işlemi yapılarak, sistemden çıktı değeri almaya yakınlaştırmaktadır. İlk katmanlarda oluşturulan bulanık kuralların seçim parametreleri bulanıklaştırma işleminde olduğu gibi, durulaştırma işleminde de etkili olmaktadır [104].

$$Q_{4,i} = W'_i f_i = W'_i (p_i X_1 + q_i X_2 + r_i) \quad (3.10)$$

Katman 5'teki tek düğüm, her bir kuralın katkısını toplayarak genel çıktıyı hesaplamaktadır.

$$Q_{5,i} = \sum_{i=1}^k W'_i f_i = \frac{\sum_{i=1}^k W_i f_i}{\sum_{i=1}^k W_i} \quad (3.11)$$

Buradaki k değeri, önceki katmanlarda da olduğu gibi, girdilerin ayrıldığı bulanık küme sayısına göre uyarlanmalıdır.

Anfis yapısına girdiler tanıtılıp bulanık kurallar uygulandıktan sonra çıktı değeri alınmaktadır. Alınan bu çıktıdan sonra sistemin hata oranları hesaplanmaya

başlanmalıdır. Anfis 'in oluşturduğu bilgisayar programları bu hatayı sistem çalışırken otomatik olarak hesaplayıp program arayüzünde göstermektedir. Bu sayede eğer ki öğrenim algoritması düzgün ilerlemiyorsa programı yarıda kesip tekrar düzenleyebilme şansımız vardır. Bu hata oranlarını ne kadar sistem kendisi hesaplıyor olsa da bu işlem matematiksel formüllere dayanmaktadır. Anfis içerisinde hata oranlarını hesaplayan birçok değer bulunmaktadır ancak bunlar arasında en çok kullanılan değerler R^2 ve Kök kare ortalama hatası (RMSE) değerleridir. (3.12) ve (3.13) denklemlerinde, bu değerlerin matematiksel formülleri verilmektedir [105-106].

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (p_i - A_i)^2}{\sum_{i=1}^n A_i^2} \right) \quad (3.12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |p_i - A_i|^2} \quad (3.13)$$

p_i , veri noktasında tahmin edilen veya ölçülen değeri; A_i , veri noktasındaki gerçek değeri; n ise veri noktalarının sayısını temsil etmektedir.

Sistemin verdiği hata oranları problem için yeterli dereceye gelene kadar, eğitim ve test süreçleri sürekli tekrarlanmalıdır. Hata oranının her denemede azalması beklenmektedir [107].

3.2. Kuaziparçacık Fonon Nükleer Model (QPNM)

QPNM birçok çekirdek için; tek-kuaziparçacık, bir fonon ve kuaziparçacık $\otimes$ fonon durumlarını ve bu durumların parçalanmalarının hesaplanabilmesine yardımcı olmaktadır [108]. Bu yöntemle çekirdeklerin temel durumuna ait teorik iç manyetik momenti (g_K), etkin spin jiromanyetik faktörünü (g_s^{eff}) ve manyetik momentini (μ_N) hesaplamaktadır. Bu hesaplama çerçevesinde her bir çekirdek için spin-spin polarizasyonu belirlenebilmektedir. Spin polarizasyon etkilerinin manyetik moment hesaplamasına etkisi literatürdeki birçok makalede bildirilmiştir [109-112]. QPNM'in başarılı uygulamaları literatürde birçok çalışmada bulunmaktadır [41-44,113-124].

Eksenel olarak simetrik ortalama bölgedeki nükleon sisteminin çiftlenim ve spin-spin kuvvetleri aracılığıyla etkileştiği dikkate alındığında, detayları referans [42-44]'da verilen QPNM Hamiltoniyeni aşağıdaki gibi bir yapıya sahiptir;

$$H \approx H_{sqp} + H_{coll.} + H_{int.} \quad (3.14)$$

H_{sqp} tek kuaziparçacık hareketini tanımlar. H_{coll} çift-çift kordaki 1^+ fonon uyarılmalarını, H_{int} ise kolektif hareketler ve tek-parçacık arasındaki ilişkiyi ifade eden Hamiltoniyendir. Bu terimlerin ayrıntılı açıklamaları [42-44]'de bulunabilir.

Tek kütle numaralı korun $\langle \phi_K^j(\tau) | \phi_K^j(\tau) \rangle = N_K^{j^2} + \sum_{i,v} (G_{i,j}^{KK_v})^2 = 1$ normalizasyon şartı ile dalga denklemi;

$$\phi_K^j(\tau) = \left\{ N_K^j(\tau) \alpha_K^+(\tau) + \sum_{i,v} G_{i,j}^{KK_v} \alpha_{K_v}^+(\tau) Q_i^+ \right\} \Psi_0 \quad (3.15)$$

şeklinde. $N_{K_j}(\tau)$ ve $G_{i,j}^{K_j K_v}(\tau, \tau')$ büyüklükleri, sırasıyla bir kuaziparçacık ve kuaziparçacık $\otimes$ fonon seviyelerinin dalga denkleminde katkılarını belirler.

$Q_i^+ = \frac{1}{\sqrt{2}} \sum_{ss'} (\Psi_{ss'}^i C_{ss'}^+ - \phi_{ss'}^i C_{ss'})$ fonon oluşturma operatörüdür. Kaynaklar [42-44]'den ve varyasyon ilkesi kullanılarak seküler denklem aşağıdaki gibi belirlenir:

$$P(\eta_K^j) \equiv \varepsilon_K - \eta_K^j - \sum_i \sum_v \frac{1}{(\chi F_n)^2} \frac{M_{KK_v}^2 \sigma_{KK_v}^2}{Z(\omega_i) \varepsilon_{K_v} + \omega_i - \eta_K^j} = 0 \quad (3.16)$$

Burada,

$$Z(\omega_i) = \frac{1}{(-\chi F_n)^2} Y_n(\omega_i) + \frac{q^2}{(1 + \chi F_p)^2} Y_p(\omega_i) \quad (3.17)$$

ve

$$Y_r(\omega_i) = 4\omega_i \sum_{ss'} \frac{\varepsilon_{ss'} \sigma_{ss'}^2 L_{ss'}^2}{(\varepsilon_{ss'}^2 - \omega_i^2)^2} \quad F_r(\omega_i) = 2 \sum_{ss'} \frac{\varepsilon_{ss'} \sigma_{ss'}^2 L_{ss'}^2}{\varepsilon_{ss'}^2 - \omega_i^2} \quad (3.18)$$

dir. Burada, ω_i çift kordaki kolektif 1^+ uyarılma durumlarının enerjileridir. Seküler denklemin kökleri ($\eta_K^j, j = 1, 2, 3 \dots$) tek kütle numaralı çekirdeğin enerjisini verir.

Notasyonlar kaynaklar [42-44]' de verilenlerle aynıdır. Dalga denkleminin normalizasyon şartı denklem (3.15) ve seküler denklem (3.16) kullanılarak N_K^j ve $G_{ij}^{KK_v}$ fonksiyonları kolaylıkla türetilebilir [42-44].

Burada,

$$N_K^{j-2} = 1 + \sum_{i,v} \frac{1}{(\chi F_n)^2 Z(\omega_i)} \frac{\sigma_{KK_v}^2 M_{KK_v}^2}{(\varepsilon_{K_v} + \omega_i - \eta_K^j)^2} \quad (3.19)$$

$$G_{ij}^{KK_v} = - \frac{1}{\chi F_n \sqrt{Z(\omega_i)}} \frac{\sigma_{KK_v} M_{KK_v}}{\varepsilon_{K_v} + \omega_i - \eta_K} N_K^j \quad (3.20)$$

dir.

Tek kütle numaralı bir korun $K > 1/2$ durumu için, gerçek manyetik moment manyetik dipol operatörünün z bileşeninin beklenti değeridir. $\mu = \langle \phi_K^j(\tau) | \mu_z \phi_K^j(\tau) \rangle$ nin Nilsson formülü ile karşılaştırılmasıyla tek nötron kor için efektif spin jirömanyetik faktör [42-44]' deki gibi elde edilebilir.

$$\mu_K = \left\{ \begin{aligned} &g_s^n \left(1 + 2N_K^{j2} \frac{1}{\chi^2 F_n Z(\omega_i)} \frac{M_{KK_v}(\tau)}{(\varepsilon_{K_v}(\tau) + \omega_i - \eta_K(\tau))} \right) - \\ &-(g_s^p - g_l^p) 2N_K^{j2} \frac{qF_p}{\chi F_n (1 + \chi F_p) Z(\omega_i)} \frac{M_{KK_v}(\tau)}{(\varepsilon_{K_v}(\tau) + \omega_i - \eta_K(\tau))} \end{aligned} \right\} \frac{\sigma_{KK_v}}{2} + g_\ell^p K \quad (3.21)$$

Bu ifade geleneksel Nilsson formülü;

$$\mu_K = g_K K = \frac{1}{2} (g_s^{eff} - g_l^\tau) \sigma_{KK}^{(z)} + g_l^\tau K \quad (3.22)$$

ile verilen manyetik moment ifadesiyle karşılaştırarak efektif spin g_s faktör için aşağıdaki analitik ifade elde edilir:

$$g_s^{eff} - g_l^\tau = (g_s^\tau - g_l^\tau) \left\{ 1 - 2N_K^2(\tau) \sum_i \frac{\kappa R_q^i(\tau, \tau') R_\tau^i}{(\varepsilon_K(\tau) + \omega_i(\tau) - \eta_K(\tau))} \right\} - \\ - (g_s^{\tau'} - g_l^{\tau'}) 2N_K^2(\tau) \sum_i \frac{\kappa R_q^i(\tau, \tau') R_{\tau'}^i}{(\varepsilon_K(\tau) + \omega_i(\tau) - \eta_K(\tau))} \quad (3.23)$$

Burada tek kütleli çekirdeğin, dıştaki tek nükleonu çift korun tek-fononlu 1^+ durumlarından saçılarak korun polarizasyonuna neden olur. Denklem (3.23)'ün sağ tarafındaki ikinci ve üçüncü terimler polarize olmuş korda kuaziparçacık-fonon etkileşmelerinden gelen koherent katkısı ifade etmektedir. Bu katkıdan dolayı spin g_s faktöründe bir azalma olmaktadır. Denklem (3.23)'te sağ tarafındaki ikinci terim ve üçüncü terimler tek-N'li çekirdekler için tek nükleonun sırasıyla çift korun nötron ve proton sistemleriyle etkileşmesinden ileri gelmektedir. Tek-Z'lu çekirdekler için bu terimler sırasıyla tek nükleonun çift korun proton ve nötron sistemleriyle etkileşmesinden oluşmaktadır. (3.23) genel bağlantısı tek-N'li ve tek-Z'li çekirdekler için ayrı ayrı incelendiğinde tek-N ve tek-Z çekirdekleri için denklem (3.24) ifadesi elde edilir.

$$\frac{g_s^{eff}}{g_s^p} = \left(1 + 2N_K^{j2} \sum_i \frac{1}{\chi^2 F_n(\omega_i) Z(\omega_i)} \frac{1}{(\varepsilon_K(\tau) + \omega_i - \eta_K^j(\tau))} \right) - \frac{(g_s^n - g_i^n)}{g_s^p} 2N_K^{j2} \sum_i \frac{qF_p(\omega_i)}{\chi F_n(\omega_i)(1 + \chi F_p(\omega_i)) Z(\omega_i)} \frac{1}{(\varepsilon_K(\tau) + \omega_i - \eta_K^j(\tau))} \quad (3.24)$$

Yakut ve ark. tarafından geliştirilen bu yaklaşım tek kütle numaralı deforme çekirdeklerin spin polarizasyon olayını ve taban durum manyetik özelliklerinin açıklanmasında iyi sonuçlar verdiği görülmüştür [41-44].

4. ARAŞTIRMA BULGULARI

Bu kısımda öncelikle sodyum çekirdeklerinin izotopları üzerinde manyetik moment verileri Yakut (2009) [41] tarafından geliştirilen teorik bir yöntem olan QPNM ile hesaplanacaktır. Sonrasında ise bu veriler hibrit bir yapay zekâ yöntemi olan Anfis ile analiz edilecektir. Bu iki yöntemin birbirine, literatürdeki diğer çalışmalara ve deneysel değerlerine olan yakınlığı tartışılacaktır.

4.1. Sayısal Hesaplamalar

4.1.1. Manyetik moment değerlerinin QPNM ile hesaplanması

Tek A'lı çekirdeklerin taban durum manyetik özelliklerinin teorik olarak incelenmesi büyük önem taşımaktadır. Sodyum izotopları ($^{19-33}\text{Na}$) için yapılan taban durum hesaplamalarında çift korun $I^\pi K=1^+0$ fononları kullanılmıştır. Çünkü mikroskopik modelde, tek A'lı çekirdeklerin taban durum ve bazı düşük enerjili uyarılma seviyeleri tek kalan nükleon ile korun $K=0$ fononlarının etkileşmesi ile oluşmaktadır [125].

Hesaplamalarda kullanılacak, ortalama alan deformasyon parametreleri (δ_2), ref. [126]'da bulunan deneysel kuadropol moment değerleri baz alınarak ve (β_2) deformasyon parametreleri $\delta_2 = 0,945\beta_2[1 - 2,56A^{-2/3}] + 0,34\beta_2^2$ denklemi ref. [127] kullanılarak hesaplanmıştır [42]. Çiftlenim parametreleri ref. [36]'dan alınmıştır.

$^{19-33}\text{Na}$ izotoplarının çiftlenim parametreleri (λ ve Δ), ortalama alan deformasyonları (δ_2), taban durum Nilsson konfigürasyonları ve deneysel manyetik moment verileri Tablo 4.1'de verilmiştir.

Tablo 4.1. Tek A'lı $^{19-33}\text{Na}$ izotoplarının λ ve Δ çiftlenim parametreleri, δ_2 ortalama alan deformasyonları, Nilsson konfigürasyonları ve deneysel manyetik momentleri verilmiştir.

İzotop	g_R (Z/A) Ref. [129]	$I^\pi[\text{Nn}_z\Lambda]\Sigma$ Ref. [130]	β_2 Ref. [126]	δ_2	Δ_n (MeV)	Δ_p (MeV)	λ_n (MeV)	λ_p (MeV)	μ_{deney} Ref. [128] (μ_N)
$^{19}_{11}\text{Na}_8$	0.578	$\frac{5^+}{2}$ [202]	0.694	0.453	3.295	2.473	-13.703	-3.8364	-
$^{21}_{11}\text{Na}_{10}$	0.523	$\frac{3^+}{2}$ [211]	0.727	0.491	3.042	2.042	-12.491	-7.986	2.38 (10)
$^{23}_{11}\text{Na}_{12}$	0.478	$\frac{3^+}{2}$ [211]	0.562	0.383	2.750	2.619	-9.156	-11.522	2.217 (3)
$^{25}_{11}\text{Na}_{14}$	0.440	$\frac{5^+}{2}$ [202]	0.450	0.383	2.426	2.645	-6.700	-14.806	3.683 (4)
$^{27}_{11}\text{Na}_{16}$	0.407	$\frac{5^+}{2}$ [202]	0.413	0.352	2.225	2.586	-4.624	-18.078	3.895 (5)
$^{29}_{11}\text{Na}_{18}$	0.379	$\frac{3^+}{2}$ [211]	0.500	0.359	1.996	2.559	-2.963	-20.953	2.449 (8)
$^{31}_{11}\text{Na}_{20}$	0.354	$\frac{3^+}{2}$ [211]	0.450	0.326	1.886	2.552	-1.820	-23.496	2.305 (2)
$^{33}_{11}\text{Na}_{22}$	0.333	$\frac{3^+}{2}$ [211]	0.473	0.348	1.690	2.681	-0.893	-25.864	-

Daha önce yapılan manyetik moment çalışmalarında [42-44,116-119], manyetik momentin izoskaler kısmında nötron ve proton g_s faktörleri birbirini güçlü bir şekilde yok ettiği görülmüştür. Bu nedenle manyetik moment hesaplamalarında izovektör kısım daha baskındır. Bu sebeple nötron-proton etkileşiminin en kuvvetli etkisinin $q=-1$ 'de ortaya çıktığı anlaşılmıştır. Bu değerdeki χ etkisi incelendiğinde, $^{19-33}\text{Na}$ çekirdekleri hafif çekirdekler olduğu için χ etkisi büyük bir fark oluşturmadığı gözlenmiştir. Bu sebeple $q=-1$ 'de χ değeri $\chi \sim 10$ MeV/A gibi küçük bir değer olarak belirlenmiştir.

Kuaziparçacık fonon karışımlarının tek çekirdeklerin taban durum seviye yapılarına etkisi çok küçük olmasına rağmen, bu karışımların koherent katkılarının tek çekirdeklerin taban durumlarının taban durum g_K ve $g_s^{\text{eff}} / g_s^{\tau}$ faktörleri üzerinde etkisi büyüktür. Tablo 4.2'de SPM (Tek Parçacık Model), KPM (Kuliev-Pyatov Metodu), QTDA (Kuaziparçacık Tamm-Dancoff Yaklaşımı) ve QPNM modelleri kullanılarak g_K ve g_s^{eff} hesaplamaları yapılmış ve bu sonuçlar deneysel veriler ile karşılaştırılmıştır.


Tablo 4.2. $^{19-33}\text{Na}$ çekirdekleri için KPM, QTDA, SPM ve QPNM modelleri kullanılarak hesaplanan g_s^{eff}/g_s^τ ve g_K değerlerinin deneysel veriler ile karşılaştırılması.

Çekirdek	g_s^{eff} / g_s^τ					g_K			
	KPM	QTDA	QPNM	Deney	SPM	KPM	QTDA	QPNM	Deney
^{19}Na	0.9532	0.9533	0.9571	0.926(1)	1.9167	2.0806	1.8646	1.8688	1.834(1)
^{21}Na	0.9326	0.9328	0.9405	0.923(0)	2.4389	2.3207	2.3310	2.3346	2.305(0)
^{23}Na	0.9126	0.9339	0.9257	0.8662(0)	2.3840	2.2366	2.2725	2.2588	2.151(0)
^{25}Na	0.9017	0.9278	0.9182	0.973(2)	1.9165	1.8068	1.8360	1.8252	1.886(2)
^{27}Na	0.8992	0.9413	0.9165	1.094(3)	1.9164	1.8039	1.8509	1.8232	2.021(3)
^{29}Na	0.9012	0.9560	0.9180	1.114(6)	2.2953	2.1395	2.2260	2.1659	2.474(9)
^{31}Na	0.9407	0.9751	0.9468	0.998(5)	2.3309	2.2347	2.2905	2.2446	2.328(9)
^{33}Na	0.8992	0.9000	0.9168	1.052(0)	2.3455	2.1802	2.1816	2.2091	2.431(0)

Tablo 4.2’de bulunan SPM, KPM ve QTDA yöntemlerini kısaca ele alalım. KPM’de tek çekirdeğin dalga fonksiyonu tek ve üç kuaziparçacık bileşenlerinden oluşur ve sadece kuaziparçacık etkileşmelerini konu almaktadır. Ancak çalışmalar, tek A’lı çekirdeklerde seviye yapılarının uygun bir şekilde açıklanmasının sadece kuaziparçacık etkileşimlerini dikkate alarak değil bunun yanı sıra kuaziparçacık ve fononlar arasındaki etkileşmelerin de hesaba katılmasıyla mümkün olabileceğini söylemektedir [36-40,108]. QTDA ise bağımsız kuaziparçacık vakumudur. Ayrıntılı bilgiler Ref. [6-29,41-44,113]’de yer almaktadır.

Tablo 4.2 ‘de görüldüğü gibi teorik modeller arasında, deneysel sonuçlar ile en iyi uyum QPNM metoduyla yapılan hesaplamalarda elde edilmiştir. Bunun yanı sıra KPM ve QTDA ile yapılan hesaplama sonuçlarının da birbirine yakın olduğu görülmektedir. Bunun sebebi her iki modelde de BCS vakumunun tek çekirdeğin çift-çift koruna eşdeğer olmasıdır [113]. SPM modelinin sonuçları ile deneysel veriler oldukça uyumludur. Bunun nedeni sodyum çekirdekleri, kapalı kabuk yapısında olduğu için tek parçacık yapısına sahiptir. Bundan dolayı spin etkileşmelerinin, bu yapıdaki çekirdeklere katkı vermediği sonucuna ulaşılmaktadır. Bu teorik yöntemler arasında deneysel verilere en yakın QPNM methodu olduğundan kısım (4.1.2)’de Anfis sonuçlarının karşılaştırılmasında QPNM ile hesaplanan μ_N değerleri dikkate alınacaktır. Çekirdekler için yapılan hesaplamalar sonucunda g_K ve g_s^{eff} değerlerinin

izotop serisi içindeki dağılım ile uyum göstermektedir ve elde edilen g_s^{eff}/g_s^{τ} sonuçları, fenomenolojik değer ($g_s^{eff}/g_s^{\tau} = 0.90-0.98g_s^{\tau}$) ile uyum içindedir.



Şekil 4.1. Deney Sonuçları ve QPNM hesaplamalarının Uyumu.

Şekil 4.1'de sodyum izotoplarının deneysel verileri ve QPNM ile hesaplanan sonuçlarının birbiriyle uyumu verilmiştir.

^{19}Na ve ^{33}Na izotoplarının manyetik dipol momentlerinin deneysel değerleri henüz ölçülmemiş olup teorik olarak hesaplanması ve Anfis kullanılarak çıkarım yapılması mümkündür. ^{19}Na ve ^{33}Na izotoplarının QPNM yaklaşımı kullanılarak hesaplanan manyetik moment değerleri sırasıyla $\mu=3.744 \mu_N$ ve $\mu=2.186 \mu_N$ tür. Şekil 4.1' den görüldüğü üzere çekirdek spini ve Nilsson konfigürasyonunun manyetik moment üzerine etkisi büyüktür. Aynı spin ve konfigürasyona sahip olan Na izotoplarının hem ölçülen hem de tahmin edilen manyetik momentleri neredeyse sabittir.

QPNM yaklaşımı gibi mikroskobik teorilerle hesap yapılırken çekirdeklerin nükleer spinleri, taban durum konfigürasyonları ve spin matris elemanlarını doğrudan etkileyen deformasyon parametreleri gibi özellikleri büyük önem taşımaktadır. Ancak çekirdeklerin bir kısmının burada sayılan özelliklerinin çoğu belirlenemediği için bilinmemekte olup ve bu da teorik çalışmaların yapılmasında bazı sınırlamalara sebep olmaktadır. Teorik olarak sınırlı düzeyde açıklanabilen özellikler, teorinin desteklendiği yapay zekâ destekli sistemler kullanılarak daha iyi tahmin edilebilmektedir. Yapay zekâ destekli sistemler esnek yapısıyla ve var olandan çıkarım yapabilme özelliği sayesinde teorik çalışmaların desteklenmesine ve tahmin gücünün artmasına büyük ölçüde katkıda bulunabilmektedir.


Bu çalışmada ayrıntıları Bölüm 3 kısım (3.1.3.1)' te bahsedilen hibrit bir yapay zekâ modeli olan Uyarlamalı Sinirsel-Bulanık Çıkarım Sistemi (Anfis) kullanılmıştır.

4.1.2. Manyetik moment değerlerinin Anfis ile hesaplanması

Manyetik moment verilerinin analizi için i7 işlemcili masaüstü bir bilgisayar ve MATLAB (Matlab R2022b) programı kullanılmıştır. Verilerin eğitim süreci öncesinde proton sayısı 1 ile 88 arasındaki 652 çekirdeğin giriş ve çıkış verileri Excel ortamında hazırlanmıştır. Bu çekirdeklere ait proton sayıları (Z), nötron sayıları (N), spin değerleri (I) giriş verisi olarak, manyetik moment (μ) verileri de çıkış verisi kullanılmıştır. Giriş Verilerin %20'si test sürecine, %80'i ise eğitim sürecine ayrılmıştır. Giriş ve çıkış verileri [128] referansından alınmıştır.

Anfis 'de eğitim ve test süreçleri, ancak veriler uygun bulanık kümelerle bölündüğünde başarılı olabilmektedir. Burada uygun üyelik fonksiyonları ile sistem başarılı bir sonuç verene kadar küme sayıları denenmelidir. Verilerde üç giriş parametresi bulunmaktadır ve her bir giriş parametresi kendi içinde bulanık kümelerle bölünmektedir. Bu çalışmada var olan üyelik fonksiyonları denendikten sonra uygun sonuçlar Gaussian (gaussmf) fonksiyonu ile alınmıştır ve bütün denemeler bu fonksiyon ile devam ettirilmiştir.


Öncelikle giriş verileri 3 3 3 bulanık kümeye bölünerek sistemin vereceği hata oranı hesaplanmıştır.



Şekil 4.2. 3 3 3 bulanık kümeye bölünen verilerin eğitim ve test sonuçlarının program çıktısı verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.


Şekil 4.2 'de görüldüğü gibi her iki süreçte de veriler uyum yakalayamamıştır. Burada RMSE değeri %13 olarak hesaplanmıştır. Bu küme sayılarının hata oranı çok yüksek

olduğundan verilerin küme sayıları tekrar tekrar değiştirilerek iki sürecinde hata oranları hesaplanmıştır.



Şekil 4.3. 6 6 6 bulanık kümeye bölünen verilerin eğitim ve test sonuçları verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.


Şekil 4.3'de görüldüğü gibi her iki süreçte henüz başarı yakalayamamaktadır ve RMSE değeri %5 olarak hesaplanmıştır. Ancak küme sayısı arttıkça verilerin birbirlerine yaklaştıkları görülmektedir.



Şekil 4.4. 10 10 10 bulanık kümeye bölünen verilerin eğitim ve test sonuçları verilmektedir. Mavi renkler gerçek verileri, kırmızı renkler Anfis 'in tahmin ettiği değerleri temsil etmektedir. FIS(Fuzzy Inference System): Bulanık Çıkarım Sisteminin tahmin ettiği değeri temsil etmektedir.

Şekil 4.4'te görüldüğü gibi hem eğitim süreci hem de test süreci başarılı sonuç vermiştir. Eğitim ve test süreçlerinin her çekirdek için nümerik sonuçları EK-B'de verilmiştir. Her iki süreçte de veriler uyum yakalamıştır ve bu sayede çalışmamıza uygun olan küme sayısı bulunmuştur.

Bu çalışmadaki veriler 10 10 10 bulanık kümeye bölünmüştür ve sonrasında eğitim ve test süreçleri başlatılmıştır. Verilerin 10'ar kümeye bölünmesiyle, üç girişli ve bir çıkışlı Anfis mimarisinin tasarımı şekil 4.5' te verilmiştir.



Şekil 4.5. Üç Girişli Bir Çıkışlı 10 10 10 Bulanık Kümeye Bölünen Anfis Mimarisi

Şekil 4.5'te verilen mimarinin 1.katmanı üyelik fonksiyonuna sisteme girmeden önce bulanıklaştırma işleminin uygulandığı katmandır. Bu çalışmada kullanılan üyelik fonksiyonu Gaussian (gaussmf) fonksiyonudur ve denklem (3.5)'de Gaussian üyelik fonksiyonu verilmektedir.

Her katmandaki matematiksel formüller, Jang (1993) [94] temel alınarak bu çalışmaya uyarlanmıştır. Her giriş değeri için Gauss üyelik fonksiyonu baz alınarak girişlerin üyelik değerleri hesaplanmaktadır.

$$Q_{1,i} \triangleright \mu_{A_i}(Z(t)) = e^{\frac{1}{2} \left(\frac{Z - c_i^Z}{\sigma_i^Z} \right)^2} \quad (4.1)$$

$$Q_{1,i} \triangleright \mu_{B_{i-1}}(N(t-1)) = e^{\frac{1}{2} \left(\frac{N - c_i^N}{\sigma_i^N} \right)^2} \quad (4.2)$$

$$Q_{1,i} \triangleright \mu_{C_{i-2}}(I(t-2)) = e^{\frac{1}{2} \left(\frac{I - c_i^I}{\sigma_i^I} \right)^2} \quad (4.3)$$

Burada $Q_{1,i}$, katman 1'deki i düğümünü, A_i , B_{i-2} ve C_{i-3} bulanık kümeleri ve $Z(t)$, $N(t-1)$ ve $I(t-2)$, çalışmanın i . düğümündeki giriş değerlerini temsil etmektedir. Bu

denklemler, giriş değerlerinin bulanık kümeye ait olma derecesini gösteren üyelik değerlerini vermektedir.

Katman 2'deki her düğüm, her bir bulanık kuralın etkisinin VE (AND) işlemiyle çarpılmasıyla hesaplanmaktadır.

$$Q_{2,i} = W_i = \mu_{A_i}(Z(t)) \text{ AND } \mu_{B_{i-1}}(N(t-1)) \text{ AND } \mu_{C_{i-2}}(I(t-2)) \quad (4.4)$$

Katman 3'teki normalleştirme denklemi (4.5)'de verilmiştir.

$$Q_{3,i} = W'_i = \frac{W_i}{W_1 + W_2 + \dots + W_{10}} \quad (4.5)$$

Katmandaki 4'teki i düğümünün durulaştırma denklemi (4.6)'da verilmiştir.

$$Q_{4,i} = W'_i f_i = W'_i (p_i Z + q_i N + r_i I) \quad (4.6)$$


Katman 5'teki tek düğüm, her bir kuralın katkısını toplayarak genel çıktıyı hesaplamaktadır.

$$Q_{5,i} = \sum_{i=1}^{10} W'_i f_i = \frac{\sum_{i=1}^{10} W_i f_i}{\sum_{i=1}^{10} W_i} \quad (4.7)$$

Buradaki matematiksel formüllerin her biri üç girişli bir çıkışlı, 10'ar bulanık kümeye bölünen bir Anfis yapısına uyarlanarak çıkartılmıştır.


Sistemin test ve eğitim süreçleri bittikten sonra RMSE değeri hesaplanmıştır. Denklem (3.12) 'deki RMSE formülü baz alınarak eğitim süreci için hata oranı %0.046, test süreci için hata oranı %0.036 olarak hesaplanmıştır. Her iki süreci ayrı ayrı inceleyelim.

Şekil 4.6'da eğitim sürecinde Anfis 'in her bir verinin manyetik moment değerinin, deneysel değerlerini yakalama oranı ve buna bağlı olarak fit grafiği görülmektedir.



Şekil 4.6. Eğitim sürecinin veri yakalama oranı ve fit grafiği verilmiştir. Lineerlik çizgisinden sapma gösteren çekirdekler; $^{77}\text{Ga}_{31}$, $^{75}\text{Br}_{35}$, $^{77}\text{Br}_{35}$, $^{85}\text{Kr}_{36}$, $^{133}\text{Sb}_{51}$, $^{118}\text{I}_{53}$, $^{179}\text{Re}_{75}$, $^{185}\text{Au}_{79}$, $^{207}\text{Tl}_{71}$, $^{217}\text{Ac}_{89}$, $^{237}\text{Np}_{93}$, $^{231}\text{Pa}_{91}$, $^{231}\text{Ra}_{88}$, $^{213}\text{Fr}_{87}$, $^{199}\text{At}_{85}$, $^{197}\text{At}_{85}$. Eğitim süreci için ayrılan 528 çekirdekten 16 tanesi sapma göstermiştir. Bu da eğitim çekirdeklerinin %3'üne karşılık gelmektedir.

Şekil 4.6'da görüldüğü gibi eğitim süreci başarılı bir şekilde tamamlanmıştır. Burada R^2 değeri denklem (3.12) ile %99 hesaplanmıştır. Eğitim sürecinin bu başarısıyla birlikte test sürecine gidilmiştir.




Şekil 4.7. Test sürecinin veri yakalama oranı ve fit grafiği verilmiştir. Lineerlik çizgisinden sapma gösteren çekirdekler; ${}^9\text{Li}_3$, ${}^{33}\text{Al}_{13}$, ${}^{31}\text{S}_{16}$, ${}^{37}\text{Cl}_{17}$, ${}^{47}\text{K}_{19}$, ${}^{51}\text{Ca}_{20}$, ${}^{49}\text{Ti}_{22}$. Test için ayrılan 124 çekirdek arasında 7 çekirdek sapma göstermiştir. Bu da test çekirdeklerinin %5'ine karşılık gelmektedir.

Şekil 4.7'de verildiği gibi test sürecinin de başarısı R^2 değerinin %98 olması ile kanıtlanmıştır. Her iki süreç içinde hata oranlarının çok düşük olması sistemin güvenilirliği kanıtlanmış ve çıkarım yapmaya hazır hale geldiğini göstermiştir.

Sisteme giriş verisi olarak atom numarası (Z ; proton sayısı) 1 ile 88 arasında olan tüm tek kütleli çekirdeklerin deneysel olarak ölçülmüş manyetik moment verileri girilmiştir [128]. Ancak Ayrıca bu bölgede deneysel olarak manyetik momenti belirlenmemiş olan 165 adet tek- A 'lı çekirdek bulunmaktadır. Manyetik moment değeri bilinmeyen bu çekirdeklerin manyetik momentlerinin tahmin edilmesi nükleer yapı fiziği ve teorisi için oldukça önemlidir. Bu nedenle nükleer fizikte bilinmeyen

verilerin çıkarımının yapılması ve literatüre kazandırılması amacıyla yapay zekâ ve veri analizi uygulamaları üzerine son zamanlarda birçok çalışma yapılmaktadır. Eğitim ve test verileriyle birlikte deneysel gözlenmemiş çekirdekler için yapılan manyetik moment çıkarımlarının olduğu veri tabloları EK A'da verilmiştir.

Bu çalışmada sodyum izotopları, örnek olması için ayrıca verilmiştir. Şekil 4.8'de spin değeri ve nötron numaralarına göre Sodyum izotoplarının manyetik moment değerlerinin kendi içinde uyumunu gösteren bir yüzey grafiği verilmiştir.



Şekil 4.8. Sodyum izotoplarının spin ve nötron numaralarına göre manyetik moment değerlerinin yüzey grafiği.

Şekil 4.8'de Sodyum izotoplarının deneysel manyetik moment değerleri ile Anfis ile yapılan çıkarım sonuçları birlikte verilmiştir. İzotopların Spin değerleri ve nötron numaralarının manyetik moment sonuçlarına göre çizilen bu grafik, pürüzsüz bir yüzey göstererek çıkarım yapılan değerlerinde izotop serisine uyumlu olduğunu göstermiştir.

Sodyum çekirdeğinin literatürde ^{19,21,23,25,27,29,31,33}Na olmak üzere tek kütle numaralı sekiz adet izotopu bulunmaktadır. Burada ¹⁹Na ve ³³Na haricindeki diğer izotopların deneysel manyetik moment değerleri bulunmaktadır. Kısım 3.1.1'de SPM, KPM, QTDA ve QPNM yöntemleri ile manyetik moment değerleri hesaplanmıştı ve bu değerler izotopların deneysel değerleri ile karşılaştırılıp yöntemlerin verdiği sonuçlar tartışılmıştı. Tablo 4.3'te İzotopların deneysel verilere en yakın sonuçları veren QPNM yöntemi ile bu kısımda kullanılan Anfis yönteminin karşılaştırılması verilmiştir.

Tablo 4.3. Tek kütleli sodyum izotoplarının literatürdeki çalışmaları ile karşılaştırılması.

<i>Çekirdek</i>	μ_N Huber[129]	μ_N Endt[132]	μ_N Keim [131]	μ_N sd-shell [131]	μ_N QPNM	μ_N Anfis
^{19}Na	-		-	-	3.744	3.823
^{21}Na	2.836 (10)	2.386 (10)	-	-	2.255	2.589
^{23}Na	2.217 (22)	2.217 (2)	-	-	2.172	2.217
^{25}Na	3.683 (4)	3.684 (4)	-	-	3.493	3.692
^{27}Na	3.895 (5)	3.895	3.894 (3)	3.711	3.494	3.898
^{29}Na	2.449 (8)	2.449	2.457 (2)	2.455	2.408	2.589
^{31}Na	2.283 (38)	2.035 (8)	2.655	2.655	2.414	2.315
^{33}Na	-	-	-	-	2.186	2.334

Bahsedildiği gibi ^{19}Na ve ^{33}Na izotoplarının deneysel değerleri bulunmamaktadır ancak kısım 4.1.1’de QPNM ile her iki izotop içinde hesaplama yapılmıştır. Bu izotoplar için QPNM ile hesaplanan değerlerin, Anfis’in çıkarım sonucu ile uyumlu olduğu görülmektedir. Literatürdeki tek kütle numaralı $^{21-31}\text{Na}$ izotoplarına ait manyetik moment ölçümleri tablo (4.3) ‘de verilmiştir. Huber ve ark. ‘nın (1978) lazer spektroskopisi ile yaptığı ölçümler ile Endt’nin (1990) NMR ile yaptığı ölçümlerin birbiriyle hemen hemen aynı olduğu tablo (4.3)’de görülmektedir. Bunların yanı sıra Keim (2000), $^{27-31}\text{Na}$ izotoplarının manyetik dipol moment değerlerini, β -ışını algılanan nükleer manyetik rezonans spektroskopisi (β -NMR) ile ölçerek bu sonuçları sd-shell model ile karşılaştırmıştır. Literatürdeki bu veriler ile bu çalışmada yapılan QPNM hesaplamaları ve Anfis çıkarımları birlikte incelendiğinde birbirlerini doğruladıkları görülmektedir. Bu durum göstermiştir ki, yapay zekâ sistemleri birçok deneysel çalışmaya yardımcı olabilmemesinin yanı sıra, teorik çalışmalar için de etkili bir karar destek sistemi sağlamaktadır.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında proton numarası 1 ile 88 arasındaki tek kütle numaralı deforme çekirdeklerin taban durum manyetik momentleri hakkında hibrit bir yapay zekâ modeli olan Anfis ile çıkarım yapılmıştır. Bu bölgede bulunan sodyum izotopları hakkında özel bir inceleme yapılmıştır. $^{19-33}\text{Na}$ izotopları için yapılan Anfis çıkarımları teorik bir yöntem olan Kuaziparçacık Fonon Nükleer Model (QPNM) ile desteklenmiştir. Elde edilen sonuçlar mevcut deneysel veriler ile karşılaştırılmıştır.

Bu tez çalışmasında incelenen tek kütleli $^{19-33}\text{Na}$ çekirdeklerin taban durum manyetik özellikleri hem Anfis ile hem de QPNM ilk kez ele alınmıştır. QPNM bazında elde edilen önemli sonuçlar aşağıda maddeler halinde verilmiştir.

- Teorik hesaplamaların sonuçları tek kütle numaralı tüm çekirdeklerde spin polarizasyonun etkin olduğunu göstermiş ve spin-spin kuvvetlerinin izovektör ($q=-1$) kısmının daha baskın olduğunu ortaya koymuştur.
- Tek kütle numaralı hafif çekirdeklerde χ etkisi büyük bir fark oluşturmadığı gözlenmiştir. Bu sebeple $q=-1$ 'de χ değeri $\chi \sim 10 \text{ MeV/A}$ gibi küçük bir değer olarak belirlenebilmektedir.
- Na izotoplarının QPNM yaklaşımı kullanılarak hesaplanan manyetik moment değerleri göz önüne alındığında, çekirdek spininin ve Nilsson konfigürasyonunun manyetik moment üzerine etkisi büyük olduğu sonucuna varılmıştır. Aynı spin ve konfigürasyona sahip olan Na izotoplarının hem ölçülen hem de tahmin edilen manyetik momentleri neredeyse sabittir.

Bu tez çalışmasında incelenen tek kütleli $^{19-33}\text{Na}$ çekirdeklerin taban durum manyetik momentlerinin Anfis ile incelenmesi ile elde edilen sonuçlar aşağıda maddeler halinde verilmiştir.

- Nükleer yapı fiziğinde, yapay zekâ yöntemlerinin kullanılması gün geçtikçe artmaktadır. Bu yöntemlerin deneysel çalışmalarda kullanılması daha popülerdir. Bu tez çalışması ile bu yöntemlerin teorik bir çalışmaya uyarlanması nadir örneklerden biri olmaktadır.

- b. Manyetik moment deęerleri, doęrusal olmayan bir sistem çözüldüęünden, bu alanda karmaşık sistemler için bile kolay bir çözüm üretebilen Anfis yöntemi kullanılmıştır. Manyetik moment deęerleri için deneme yanılma yöntemi ile en uygun doęrusal olmayan fonksiyonun Gaussian fonksiyonu olduęu bulunmuştur. Anfis sistemi en az hatayı Gaussian ile çözümlemede vermiştir.
- c. Anfis 'de eğitim ve test süreçleri, ancak veriler uygun bulanık kümelere bölündüęünde başarılı olabilmektedir. Bu sistem için en uygun kümeleme üç giriş bir çıkış verisi için 10 10 10 olarak çözümlenmiştir ve uygun formülasyon yapılmıştır.
- d. Anfis ile yapılan eğitim ve test süreçlerinin sonuçları mevcut deneysel sonuçlar ile uyumlu olduęu ve deneysel verileri olmayan çekirdekler hakkında da yapılan çıkarımların her bir izotop serisi içinde benzer olduęu görölmüştür.
- e. Yapay zekâ yöntemleri günümüzde gittikçe daha popüler hale gelmektedir. Birçok çalışma bu yöntemleri yeni karar destek sistemi olarak kullanmaktadır. Bu çalışmada kullanılan Anfis çıkarım sistemi Nükleer fizik alanında henüz yeni olsa da bu tez çalışmasıyla bu alandaki birçok çalışmaya uyum sağlayabileceęi gösterilmektedir.

Bu çalışma, Anfis 'in tek-A 'lı $1 \leq Z \leq 88$ çekirdek serileri için kullanıldıęı ilk çalışmadır. Elde edilen sonuçlar literatürdeki eksik deneysel verilerin giderilmesi açısından oldukça önemlidir. Anfis sistemlerinin teorik çalışmalarda kullanılması oldukça nadirdir ve bu çalışma ile deneysel çalışmaların yanı sıra teorik çalışmalarda da hibrit modellerin kullanılabileceęi gösterilmiştir.

Bu tez çalışması, nükleer teknolojilerin bir alt alanı olan nükleer yapı fiziğinde daha önce ele alınmamış bir konuyu sunmaktadır. Bu çalışmanın ilerideki birçok çalışmaya iyi bir referans olması hedeflenmektedir. Aynı zamanda bu tez çalışmasında yapılan tıp alanındaki literatür çalışması ilerideki akademik çalışmalar için bir ön hazırlık nitelięi taşımaktadır.

KAYNAKLAR

- [1] Neyens G., (2003). Rep. Prog. Phys. 66, 633.
- [2] Li J., Meng J., Ring P., Yao J. M. & Arima A., (2011). Prog. Theor. Phys. 125, 1185.
- [3] Li J., Meng J., Ring P., Yao J. M. & Arima A., (2011). Sci. China Phys. Mech. Astron. 52, 204.
- [4] Bunker, M.E., Reich, C.W., (1971). A survey of nonrotational states of deformed odd-A nuclei ($150 < A < 190$). Reviews of Modern Physics, 43, 348-423.
- [5] Jain, A.K., Sheline, R.K., Sood, P.C., Jain, K., (1990). Intrinsic states of deformed odd-A nuclei in the mass regions ($151 \leq A \leq 193$) and ($A \geq 221$). Reviews of Modern Physics, 62, 393-509.
- [6] Hamamoto, I., Åberg, S., (1984). Microscopic description of a low-lying $K^\pi = 1^+$ mode in ^{156}Gd . Physics Letters B, 145, 163-166.
- [7] Barrett, B., Halse, P., (1985). M1 transition strength in the SU(3) limit of the generalized IBM-2. Physics Letters B, 155, 133-136.
- [8] Scholten, O., Heyde, K., Van Isacker, P., Jolie, J., Moreau, J., Waroquier, M., Sau, J., (1985). Mixed-symmetry states in the neutron-proton interacting boson model. Nuclear Physics A, 438, 41-77.
- [9] Zamick, L., (1985). Comparison of magnetic dipole excitations in the 7/2 shell region with the new collective excitations in ^{156}Gd Physical Review C, 31, 1955.
- [10] Faessler, A., Nojarov, R., (1986). Low-energy isovector quadrupole vibrations. Physics Letters B, 166, 367-371.
- [11] Hammaren, E., Schmid, K., Faessler, A., Grümmer, F., (1986). Microscopic prediction of the M1 strength distributions in medium heavy nuclei. Physics Letters B, 171, 347-352.
- [12] Nojarov, R., Bochnacki, Z., Faessler, A., (1986). Microscopic calculation of the restoring force for scissor isovector vibrations. Zeitschrift für Physik A Hadrons and Nuclei, 324, 289-298.
- [13] Castel, B., Zamick, L., (1987). New spin excitation modes in nuclei. Physics Reports, 148, 217-247.
- [14] Liu, H., Zamick, L., (1987). Rotational model and shell model pictures of magnetic dipole excitations. Physical Review C, 36, 2057.
- [15] Iudice, N.L., Richter, A., (1989). Orbital magnetic dipole excitations in deformed nuclei and the scissors mode. Physics Letters B, 228, 291-298.

- [16] Faessler, A., Khoa, D.T., Grigorescu, M., Nojarov, R., (1990). Low-lying magnetic dipole excitations in actinide nuclei. *Physical review letters*, 65, 2978.
- [17] Faessler, A., Nojarov, R., Scholtz, F., (1990). Magnetic dipole electroexcitations in rare earth nuclei. *Nuclear Physics A*, 515, 237-272.
- [18] Zawischa, D., Speth, J., (1990). Spin-flip magnetic dipole states in deformed nuclei. *Physics Letters B*, 252, 4-8.
- [19] De Coster, C., Heyde, K., (1991). Magnetic dipole spin resonance in rare-earth nuclei. *Physical review letters*, 66, 2456-2459.
- [20] Hamamoto, I., Magnusson, C., (1991). Deformation dependence of magnetic dipole strength below 4 MeV in doubly even rare earth nuclei. *Physics Letters B*, 260, 6-10.
- [21] Rangacharyulu, C., Richter, A., Wörtche, H., Ziegler, W., Casten, R., (1991). Strong correlation and saturation of E2 and M1 transition strengths in even-even rare-earth nuclei. *Physical Review C*, 43, R949.
- [22] Sarriguren, P., de Guerra, E.M., Nojarov, R., Faessler, A., (1993). M1 spin strength distribution in ^{154}Sm . *Journal of Physics G: Nuclear and Particle Physics*, 19, 291.
- [23] Raduta, A., Iudice, N.L., Ursu, I., (1995). Description of orbital and spin excitations within a projected spherical single-particle basis. *Nuclear Physics A*, 584, 84- 102.
- [24] Kuliev, A.A., Akkaya, R., Ilhan, M., Guliyev, E., Salamov, C., Selvi, S., (2000). Rotational-Invariant Model of the States with $K^\pi = 1^+$ and their Contribution to the Scissors Mode. *International Journal of Modern Physics E*, 9, 249-261.
- [25] Kuliev, A.A., Guliyev, E., Gerçeklioğlu, M., (2002). The dependence of the scissors mode on the deformation in the $^{140-150}\text{Ce}$ isotopes. *Journal of Physics G: Nuclear and Particle Physics*, 28, 407-414.
- [26] Bektaşoğlu, M., Yakut, H., (2006). Low-Lying Dipole Strengths in $^{162,164}\text{Dy}$ Nuclei. *Acta Physica Polonica B*, 37, 2705-2712.
- [27] Guliyev, E., Ertuğral, F., Kuliev, A.A., (2006). Low-lying magnetic dipole strength distribution in the γ -soft even-even $^{130-136}\text{Ba}$. *The European Physical Journal A Hadrons and Nuclei*, 27, 313-320.
- [28] Ertuğral, F., Guliyev, E., Kuliev, A.A., (2007). Low lying magnetic and electric dipole strength distribution in the even-even 164–170Er. *AIP, AIP Conference Proceedings*, 899, 109-110.
- [29] Guliyev, E., Kuliev, A.A., Ertugral, F., (2009). Low-lying dipole excitations in the deformed even-even isotopes $^{154-160}\text{Gd}$. *Acta Physica Polonica B*, 40, 829-837.

- [30] Soloviev, V.G., (2009). On collective nonrotational states of odd-mass deformed nuclei. *Physics Letters*, 16, 308-311, 1965.
- [31] Bes, D.R., Yi-Chung, C., (1966). The γ -vibrations in odd-mass rare-earth nuclei. *Nuclear Physics*, 86, 581-610.
- [32] Soloviev, V.G., Vogel, P., (1967). Structure of the ground and excited states of oddmass deformed nuclei in the region $153 \leq A \leq 187$. *Nuclear Physics A*, 92, 449-474,
- [33] Soloviev, V.G., Malov, L.A., (1972). A model for describing the structure of highly excited states in deformed nuclei (I). *Nuclear Physics A*, 196, 433-451.
- [34] Soloviev, V.G., Nesterenko, V.O., Bastrukov, S.I., (1983). On vibrational states in deformed odd-A nuclei. *Zeitschrift für Physik A Hadrons and Nuclei*, 309, 353-361.
- [35] Gareev, F.A., Ivanova, S.P., Malov, L.A., Soloviev, V.G., (1971). Single-particle energies and wave functions for the saxon-woods potential and the levels of odd-A nuclei in the actinide region. *Nuclear Physics A*, 171, 134-164.
- [36] Soloviev, V.G., (1976). Theory of complex nuclei. New York: Pergamon Press.
- [37] Gorbachev, B.I., Levon, A., Nemets, O.F., Fedotkin, S.N., Stepanenko, V.A., (1984). Magnetic moments of isomeric states in ^{141}Pr and ^{143}Pm and paramagnetism of the promethium and praseodymium. *Zhurnal Eksperimental'noj i Teoreticheskoy Fiziki*, 87, 3 13.
- [38] Levon, A., Fedotkin, S.N., Vdovin, A., (1986). Magnetic moments of odd spherical nuclei. *Soviet Journal of Nuclear Physics*, 43, 912-917.
- [39] Ponomarev, V.Y., Safarov, R.R., (1988). The contribution of "quasiparti⊗phonon" components into magnetic moments of lowlying states in odd spherical nuclei. *P4*, 88-146.
- [40] Vdovin, A., Safarov, R.R., Galinskij, E.M., (1988). Pauli principle and magnetic moments of odd spherical nuclei. *P4*, 88-170.
- [41] Yakut, H., (2009). *Nadir toprak deforme çekirdeklerinde kolektif dipol seviyelerinin elektrik ve manyetik dipol özelliklerinin incelenmesi*. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- [42] Yakut, H., Guliyev, E., Guner, M., Tabar, E., Zenginerler, Z., (2012). QPNM calculation for the ground state magnetic moments of odd-mass deformed nuclei: $^{157-167}\text{Er}$ isotopes. *Nuclear Physics A*, 888, 23-33.
- [43] Yakut, H., Tabar, E., Kuliev, A.A., Zenginerler, Z., Kaplan, P., (2013). Ground state magnetic properties of odd neutron Dy isotopes. *International Journal of Modern Physics E*, 22, 1350076(1-13).

- [44] Yakut, H., Tabar, E., Kuliev, A.A., Guliyev, E., (2014). The ground-state magnetic moments of odd-mass Hf isotopes. *Central European Journal of Physics*, 12, 843-850.
- [45] Yılmaz, A. (2021). *Yapay Zeka*. (2. Basım) İstanbul: Kodlab Yayın Dağıtım Yazılım LTD ŞTİ.
- [46] Mousavi J., Ponnambalam K., Karray F., (2007). Inferring operating rules for reservoir operations using fuzzy regression and ANFIS, *Fuzzy Sets and Systems, Elsevier*, vol. 158, pp. 1064–1082.
- [47] Yuan Z., Tian D., Li J., Niu Z., (2021). Magnetic moment predictions of odd-A nuclei with the Bayesian neural network *approach* ' *Chinese Physics C* Vol. 45, No. 12 (2021) 124107.
- [48] Athanassopoulos S., Mavrommatis E., Gernoth K.A, Clark J.W., (2004). Nuclear mass systematics using neural networks, *Nuclear Physics A* 743, 222–235.
- [49] Üncü Y., Danışman T., Özdoğan H., (2022). Calculations of GDR parameters for deformed nuclei using LogitBoost classifier and artificial neural network, Vol.37, No.13.
- [50] Wang X., Zhu L. & Su J., (2021). *Phys. Rev. C* 104, 034317.
- [51] Bai J., Niu Z., Sun B. & Niu Y., (2021). *Phys. Lett. B* 815, 136147.
- [52] Niu Z., Liang H., (2018). *Phys. Lett. B* 778, 48.
- [53] Niu Z. M., Liang H. M., Sun B. H., Long W.H. & Niu Y.F., (2019). *Phys. Rev. C* 99, 064307.
- [54] Akkoyun S., (2020). *Nucl. Instrum. Methods Phys. Res. B* 462, 51.
- [55] Akin H.L., Altin V., (1991). Rule-based fuzzy logic controller for a PWR-type nuclear power plant, *IEEE Trans. Nucl. Sci.*, vol. 38.
- [56] Heger A.S., Alang-Rashid N. K, & Jamshidi M., (1995). Application of fuzzy logic in nuclear reactor control—Part 1: An assessment of state-of-the-art, *Nucl. Safety*, vol. 36, no. 1, pp. 109–121.
- [57] Na M. G., (1999). Neuro-fuzzy control applications in pressurized water reactors” in *Fuzzy Systems and Soft Computing in Nuclear Engineering* Da Ruan, Ed. New York: Springer-Verlag, pp. 172–207.
- [58] Zio E., Gola G. (2006)., Neuro-fuzzy pattern classification for fault diagnosis in nuclear components, *Annals of Nuclear Energy* 33, 415–426.
- [59] AL M. Fayiz H., (2017). Adaptive Neural Network Algorithm for Power Control in Nuclear Power Plants, *Journal of Physics: Conf. Series*, vol. 781, p. 012052.

- [60] Luan X., Wang J., Yang Z., Zhou J., (2021). Load-following control of nuclear reactors based on the fuzzy input-output model, *Annals of Nuclear Energy*, vol.151, p. 107857, <https://doi.org/10.1016/j.anucene.2020.107857>.
- [61] Rafiei M., Ansarifard G., (2022). , Conceptual design of a new space nuclear reactor with low-enriched uranium fuel based on the optimization of fuel composition and reflector geometry via optimized adaptive neuro-fuzzy inference system as well as investigation of fresh core cycle length, *Int J Energy Res.*;46:9456–9485.
- [62] Akkoyun S. & Torun Y., (2021)., Neuro-fuzzy modeling of deformation parameters for fusion-barriers, *Nuclear Engineering and Technology*, 53 1612-1618.
- [63] Ding, W., Perez, J. A., Cheung, Y. M., Das, S., Yue, X., & Mrozek, D. (2022). Special issue on fuzzy systems for biomedical science in healthcare. *Applied Soft Computing*, 109834.
- [64] Fakoor R., Ladhak F., Nazi A. & Huber M., (2013). Using deep learning to enhance cancer diagnosis and classification, *Proc. Int. Conf. Mach. Learn.*, 1-7.
- [65] Aydoğan M., (2023). A hybrid deep neural network-based automated diagnosis system using x-ray images and clinical findings. *Int J Imaging Syst Technol*: 1-15. <http://dx.doi.org/10.1002/ima.22856>.
- [66] Nie D., Zhang H., Adeli E., Liu L. & Shen D., (2016). 3d deep learning for multi-modal imaging-guided survival time prediction of brain tumor patients, *Proc. MICCAI*, 212-220, http://dx.doi.org/10.1007/978-3-319-46723-8_25.
- [67] Khademi, M., Nedialkov, N. S. (2015). Probabilistic graphical models and deep belief networks for prognosis of breast cancer, *IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*, Miami, FL, 727-732.
- [68] Ramsundar, B., Kearnes, S., Riley, P., Webster, D., Konerding, D., Pande, V. (2015). Massively multitask networks for drug discovery, *arXiv:1502.02072*.
- [69] Tian, K., Shao, M., Wang, Y., Zhou, S., Guan, J. (2016). Boosting compound-protein interaction prediction by deep learning, *Methods*, 110, 64-72.
- [70] Anthimopoulos M., Christodoulidis S., Ebner L., Chrsite A. & Mougiakakou S., (2016)., Lung pattern classification for interstitial lung diseases using a deep convolutional neural network, *IEEE Trans. Med. Imag.* 35,4, 1207-1216.
- [71] Jiang, B., Wang, X., Luo, J., Zhang, X., Xiong, Y., Pang, H. (2015). Convolutional neural networks in automatic recognition of trans-differentiated neural progenitor cells under bright-field microscopy, *Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC)*, Qinhuangdao, 122-126.

- [72] Xu T., Zhang H., Huang X., Zhang S. & Metaxas D. N, (2016),Multimodal deep learning for cervical dysplasia diagnosis, *Proc. MICCAI*, 115-123, http://dx.doi.org/10.1007/978-3-319-46723-8_14.
- [73] Hu, C., Ju, R., Shen, Y., Zhou, P., Li, Q. (2016). Clinical decision support for alzheimer's disease based on deep learning and brain network, *IEEE International Conference on Communications (ICC)*, Kuala Lumpur, 1-6.
- [74] Wulsin, D. F., Gupta, J. R., Mâni, R., Blanco, J. A., Litt, B. (2011). Modeling electroencephalography waveforms with semi supervised deep belief nets: fast classification and anomaly measurement, *Journal of Neural Engineering*, 8, 3, 036015.
- [75] Pereira, C. R., Pereira, D. R., Rosa, G. H., Albuquerque, V H. C., Weber, S. A. T., Hook, C., Papa, J. P. (2018). Handwritten assessment through convolutional neural networks: an application to Parkinson's disease identification, *Artificial Intelligence in Medicine*, 87, 67-77.
- [76] Neagoe V.E, Latin L.F., Grunwald S., (2003). A neuro-fuzzy approach to classification of ECG signals for ischemic heart disease diagnosis, in: *AMIA, Annual Symposium Proceedings*, pp. 494–498.
- [77] Guler I., Ubeyli E.D, (2005). Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients, *Journal of Neuroscience Methods* 148 (2).113–121.
- [78] Kumar K.A., Punithavalli M., (2011). Efficient cancer classification using fast adaptive neuro-fuzzy inference system (FANFIS) based on statistical techniques, *International Journal of Advanced Computer Science and Applications, Special Issue on Artificial Intelligence*, 132–137.
- [79] Sharma M, Mukharjee S. (2012). Brain tumor segmentation using hybrid genetic algorithm and artificial neural network fuzzy inference system (ANFIS). *Int J Fuzzy Log Syst*. <https://doi.org/10.5121/ijfls.2012.2403>.
- [80] Huang ML, Hung YH, Lee WM, Li RK, Wang TH (2012) Usage of case-based reasoning, neural network and adaptive neuro-fuzzy inference system classification techniques in breast cancer dataset classification diagnosis. *J Med Syst* 36(2):407–414. <https://doi.org/10.1007/s10916-010-9485-0>.
- [81] Kar S, Majumder D.D, (2016) An investigative study on early diagnosis of breast cancer using a new approach of mathematical shape theory and neuro-fuzzy classification system. *Int J Fuzzy Syst* 18(3):349–366. <https://doi.org/10.1007/s40815-015-0087-3>.
- [82] Manogaran G, Varatharajan R, Priyan MK (2018) Hybrid recommendation system for heart disease diagnosis based on multiple kernel learning with adaptive neuro-fuzzy inference system. *Multimed Tools Appl*. 77(4):4379–4399.

- [83] Pravin R. Kshirsagar, Arpit D. Yadav, Kirti A. Joshi, Pranav Chippalkatti, Rinali Y., (2020) Classification and Detection of Brain Tumor by using GLCM Texture Feature and ANFIS, *Journal of Research in Image and Signal Processing*, 5,1, 15-31.
- [84] Das A., Mohapatra S.K., Mohanty M.N. (2022). Design of deep ensemble classifier with fuzzy decision method for biomedical image classification, *Appl.Soft.Comput.*,115.Article108178,<https://doi.org/10.1016/j.asoc.2021.1081782>.
- [85] Kumar, R., Al-Turjman, F., Srinivas, L.N.B. (2023). ANFIS for prediction of epidemic peak and infected cases for COVID-19 in India. *Neural Comput & Applic* 35, 7207–7220. <https://doi.org/10.1007/s00521-021-06412-w>.
- [86] Punarselvam E., (2023). A pragmatic approach of Parkinson disease detection using hybrid case-based reasoning neuro-fuzzy classification system over Mobile edge computing, *Journal of Intelligent & Fuzzy Systems*, 1-16.
- [87] Rejula, M.A., Amutha, S. & Shilpa, G.M. (2023). Classification of acute lymphoblastic leukemia using improved ANFIS. *Multimed Tools Appl.* <https://doi.org/10.1007/s11042-023-15113-6>.
- [88] Zadeh L. A. (1965). Fuzzy sets. *Information and Control*, 8:338–353.
- [89] Walia N., Singh H., Sharma A., (2015). ANFIS: Adaptive Neuro-Fuzzy Inference System- A Survey, *International Journal of Computer Applications* (0975 – 8887) Volume 123 – No.13.
- [90] Matlab Help Center (2023, 5 Mayıs), Trimf https://www.mathworks.com/help/fuzzy/trimf.html?s_tid=doc_ta. 5 mayıs tarihinde alınmıştır.
- [91] Matlab Help Center (2023, 5 Mayıs), Trapmf https://www.mathworks.com/help/fuzzy/trapmf.html?s_tid=doc_ta. 5 mayıs tarihinde alınmıştır.
- [92] Matlab Help Center (2023, 5 Mayıs), Gaussmf <https://www.mathworks.com/help/fuzzy/gaussmf.html>. 5 mayıs tarihinde alınmıştır.
- [93] Matlab Help Center (2023, 5 Mayıs), Gbellmf https://www.mathworks.com/help/fuzzy/gbellmf.html?s_tid=doc_ta. 5 Mayıs tarihinde alınmıştır.
- [94] Jang J.-S. R., (1993)., ANFIS: adaptive-network-based fuzzy inference system, *IEEE Trans. Syst. Man. Cybern.*, vol. 23, no. 3, pp. 665–685, 1993, DOI: 10.1109/21.256541.
- [95] Nikam S.R., Nikumbh P.J. & Kulkarni S.P. (2012). Fuzzy Logic and Neuro-Fuzzy Modeling, *Journal of Artificial Intelligence* ISSN: 2229-3965 & E-ISSN: 2229-3973, Volume 3, Issue 2, pp.-74-84.

- [96] Pratama M., Rajab S., Joo E., (2011). Extended Approach of ANFIS in Cascade Control, *International Journal of Computer and Electrical Engineering*, Vol. 3, No. 4, pp. 1-5.
- [97] Sugeno M. & Kang G.T, (1988). Structure identification of fuzzy model, *Fuzzy Sets and Systems*, vol. 28, no. 1, pp. 15-33.
- [98] Rezaei K., Hosseini R., Mazinani M., (2014). A Fuzzy Inference System for Assessment of the Severity of the peptic ulcers, *Computer Science & Information Technology*, DOI:10.5121/ csit.2014.4527, pp. 263-271, 2014.
- [99] Kaur A., Kaur A., (2012). Comparison of Mamdani-Type and Sugeno-Type Fuzzy Inference Systems for Air Conditioning System, *International Journal of Soft Computing and Engineering*, ISSN: 2231-2307, no. 2, pp. 323-325.
- [100] Efosa C., Akwukwuma N., (2013). Knowledge based Fuzzy Inference System for Sepsis Diagnosis, *International Journal of Computational Science and Information Technology*, Vol.1, No. 3, pp. 1-7.
- [101] Berenji H. R. & Khedkar P. (1992). Learning and Tuning Fuzzy Logic Controllers through Reinforcement, *IEEE Transactions on Neural Networks*, 1992, Vol. 3, pp. 724-740.
- [102] Sulzberger S, Tschichold N. & Vestli S., (1993), FUN: Optimization of Fuzzy Rule Based Systems Using Neural Networks, *Proceedings of IEEE Conference on Neural Networks, San Francisco*, pp. 312-316.
- [103] Nauck D., Kursse R., (1997) Neuro-Fuzzy Systems for Function Approximation”, *4th International Workshop Fuzzy-Neuro Systems*. Italya.
- [104] Roy S., (2005). Design of adaptive neuro-fuzzy inference system for predicting surface roughness in turning operation, *Journal of Scientific & Industrial Research*, vol. 64, no. September, pp. 653-659.
- [105] MatlabHelpCenter(2023,10cak)RMSE,https://www.mathworks.com/help/matlab/ref/rmse.html?searchHighlight=rmse&s_tid=srchtitle_rmse_1.
- [106] Norhayati I, Rashid M., (2018). Adaptive neuro-fuzzy prediction of carbon monoxide emission from a clinical waste incineration. *Neural Comput & Applic*, 30:3049–3061.
- [107] Uc T., Karahoca A., Karahoca D., (2013). Tuberculosis disease diagnosis by using adaptive neuro-fuzzy inference system and rough sets, *Neural Comput & Applications*, Springer, DOI 10.1007/s00521-012-0942-1, pp. 471-483.
- [108] Soloviev V.G., (1992). Theory of atomic nuclei: Quasiparticles and phonons. *Institute of Physics Publishing Bristol and Philadelphia*.

- [109] Bochnacki, Z., Ogaza, S., (1965). Spin polarization effect and the magnetic moments of odd-mass deformed nuclei, *Nuclear Physics*, 69,1, pp. 186-192.
- [110] Migdal, A. B., (1966). Nuclear magnetic moments, *Nuclear Physics*, 75, 2, pp. 441-469.
- [111] Rapoport, L.P., Chernyshev, A.S., (1968). *Yad. Fiz.*, 7, 309.
- [112] Bodensadt, E., Rogers, J. D., In *Perturbed Angular Correlations*, (1964) vol. 1, NorthHolland, Amsterdam.
- [113] Tabar, E., (2015), *Tek Kütle Numaralı Nadir Toprak Deforme Çekirdeklerinin Makas Mod Uyarılmalarının İncelenmesi*. Doktora Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- [114] Tabar, E., Yakut, H., Kuliev, A.A., (2016). Microscopic description of ground state magnetic moment and low-lying magnetic dipole excitations in heavy odd mass ^{181}Ta nucleus. *International Journal of Modern Physics E*, 25, 1650053.
- [115] Tabar, E., Kuliev, A.A., (2017). Microscopic investigation of the low-lying magnetic dipole transitions in the odd-mass $^{155-169}\text{Ho}$ isotopes. *Nuclear Physics A*, 964, 1-17.
- [116] Yakut H, Kuliev A, AGuliyev E, (2008). Investigations of the g_k -factors in the $^{175,177,179}\text{Hf}$ Isotopes”, *AIP Conference Proceedings* 1072, 258.
- [117] Yakut H, Kuliev A, A Guliyev E, Zenginerler Z, (2009), Intrinsic $g(k)$ factors of odd-mass Lu167-179 isotopes”, *Pramana* 73(5):829-83.
- [118] Hoşgör G, Yakut H, Tabar E,(2017), Spin polarization effects on magnetic dipole moment of $^{153,155}\text{Eu}$ ”, *AIP Conference Proceedings* 1815, 060011.
- [119] Tabar E, Yakut H, Kuliev A.A, Quliyev H, Hoşgör G,(2017). Magnetic moments and g-factors in odd-A Ho isotopes”, *Chinese Phys. C* 41 074101,
- [120] Yakut H, Tabar E, Hoşgör G, (2019). Effects of the isoscalar and isovector interaction on the ground-state magnetic moments of odd-mass $^{137-145}\text{Ce}$ nuclei, *Canadian Journal of Physics*, Volume 97 • Number 11 1187 – 1190.
- [121] Tabar E, (2019). Magnetic properties of $K = 1/2$ states in deformed odd-mass nuclei. *Nucl. Phys. A*, 986, pp. 150-166.
- [122] Tabar E, (2019). A theoretical investigation of the magnetic dipole moment of the ground- and excited-states below 600keV in well-deformed $^{183,185}\text{W}$, $^{185,187}\text{Re}$ and $^{187,189}\text{Os}$ ”, *International Journal of Modern Physics E* VOL. 28, NO. 06.
- [123] Tabar E, (2019). A theoretical study on the ground and low-energy magnetic dipole characteristics of ^{239}Pu nucleus. *Nuclear Physics A*. Volume 987, Pp 202-221.

- [124] Tabar E, Kemah E, Yakut H, Hoşgör G, (2022) First Theoretical Identification of the Magnetic Dipole Moment of the 97.43 keV State in ^{153}Eu ” *Sakarya University Journal of Science*, Volume 26, Issue 5, 967 – 973.
- [125] Bauske, I., Arias, J.M., Von Brentano, P., Frank, A., Friedrichs, H., Heil, R.D., Herzberg, R.-D., Hoyler, F., Van Isacker, P., Kneissl, U., (1993). First observation of scissors mode states in an odd-mass nucleus. *Physical review letters*, 71, 975-978.
- [126] Raman, S., Nestor, C.W., Tikkanen, P., (2001). Transition probability from the ground to the first-excited 2^+ state of even–even nuclides. *Atomic Data and Nuclear Data Tables*, 78, 1-128.
- [127] Bohr, A., Mottelson, B., (1969). *Nuclear Structure*, Benjamin, New York and Amsterdam. Vol. 1.
- [128] Stone, N.J., (2005). Table of nuclear magnetic dipole and electric quadrupole moments. *Atomic Data and Nuclear Data Tables*, 90, 75-176.
- [129] Huber G., Touchard F., Büttgenbach S., Thibault C., Klapisch R., Duong H.T., Liberman S., Pinard J., Vialle J.L, Juncar P, Jacquinet P.,(1978). *Phys. Rev. C* **18**, 2343.
- [130] Audi G., Bersillon O., Blachot J., Wapstra A.H., (2003). The NUBASE evaluation of nuclear and decay properties, *Nuclear Physics A* 729. 3–128.
- [131] Keim M., Georg U., Klein A., Neugart R., Neuroth M., Wilbert S., Lievens P., Vermeeren L., Brown B.A, & the Isolde Collaboration. (2000). Measurement of the electric quadrupole moments of $^{26-29}\text{Na}$. *Eur. Phys. J. A* **8**, 31–40.
- [132] Endt P.M. (1990). Energy Levels of $A = 21-44$ Nuclei (VII), 1-830, North-Holland, *Nuclear Physics A*, 521.

EKLER

EK-A

Tablo A.1. Proton sayısı 2-28 arasındaki manyetik momenti belirlenmemiş tek A'lı çekirdeklerin Anfis ile manyetik momentlerinin tahminleri

Çekirdek	A	Z	N	I	μ_{Anfis}	Çekirdek	A	Z	N	I	μ_{Anfis}
$^5\text{He}_3$	5	2	3	3/2 ⁻	-2.5760	$^{53}\text{K}_{34}$	53	19	34	3/2 ⁺	0.22000
$^7\text{He}_5$	7	2	5	3/2 ⁻	-2.5567	$^{55}\text{K}_{36}$	55	19	36	3/2 ⁺	0.387500
$^9\text{He}_7$	9	2	7	1/2 ⁺	-2.1135	$^{35}\text{Ca}_{15}$	35	20	15	1/2 ⁺	-1.31470
$^5\text{Li}_2$	5	3	2	3/2 ⁻	3.2789	$^{37}\text{Ca}_{17}$	37	20	17	3/2 ⁺	-1.39110
$^{13}\text{Be}_9$	13	4	9	1/2 ⁻	-1.6400	$^{53}\text{Ca}_{33}$	53	20	33	1/2 ⁻	-1.32440
$^{15}\text{Be}_{11}$	15	4	11	5/2 ⁺	-1.5744	$^{55}\text{Ca}_{35}$	55	20	35	5/2 ⁻	-1.57880
$^7\text{B}_2$	7	5	2	3/2 ⁻	2.69456	$^{57}\text{Ca}_{37}$	57	20	37	5/2 ⁻	-1.52330
$^9\text{B}_4$	9	5	4	3/2 ⁻	2.4567	$^{39}\text{Sc}_{18}$	39	21	18	7/2 ⁻	5.5222
$^{19}\text{B}_{12}$	19	5	12	3/2 ⁻	2.5500	$^{41}\text{Sc}_{20}$	41	21	20	7/2 ⁻	5.4400
$^{21}\text{B}_{16}$	21	5	16	3/2 ⁻	2.5879	$^{51}\text{Sc}_{30}$	51	21	30	7/2 ⁻	4.97530
$^{19}\text{C}_{13}$	19	6	13	1/2 ⁺	1.4234	$^{53}\text{Sc}_{32}$	53	21	32	7/2 ⁻	5.71110
$^{11}\text{N}_4$	11	7	4	1/2 ⁺	0.7370	$^{55}\text{Sc}_{34}$	55	21	34	7/2 ⁻	5.34000
$^{11}\text{O}_3$	11	8	3	1/2 ⁻	0.73450	$^{57}\text{Sc}_{36}$	57	21	36	7/2 ⁻	5.6122
$^{21}\text{O}_{13}$	21	8	13	5/2 ⁺	1.55670	$^{59}\text{Sc}_{38}$	59	21	38	7/2 ⁻	5.33310
$^{23}\text{O}_{15}$	23	8	15	1/2 ⁺	0.79540	$^{61}\text{Sc}_{40}$	61	21	40	7/2 ⁻	5.41110
$^{13}\text{F}_4$	13	9	4	5/2 ⁺	3.47890	$^{39}\text{Ti}_{17}$	39	22	17	3/2 ⁺	-1.2111
$^{15}\text{F}_6$	15	9	6	1/2 ⁺	3.3300	$^{41}\text{Ti}_{19}$	41	22	19	3/2 ⁺	1.00890
$^{23}\text{F}_{14}$	23	9	14	5/2 ⁺	3.28990	$^{51}\text{Ti}_{29}$	51	22	29	3/2 ⁻	0.0991
$^{25}\text{F}_{16}$	25	9	16	5/2 ⁺	3.4423	$^{53}\text{Ti}_{31}$	53	22	31	3/2 ⁻	0.8599
$^{27}\text{F}_{18}$	27	9	18	5/2 ⁺	3.29980	$^{55}\text{Ti}_{33}$	55	22	33	1/2 ⁻	-1.2221
$^{15}\text{Ne}_5$	15	10	5	3/2 ⁻	-0.6634	$^{57}\text{Ti}_{35}$	57	22	35	5/2 ⁻	-0.71231
$^{27}\text{Ne}_{17}$	27	10	17	3/2 ⁺	-0.6234	$^{59}\text{Ti}_{37}$	59	22	37	5/2 ⁻	-0.74555
$^{29}\text{Ne}_{19}$	29	10	19	3/2 ⁺	-0.6912	$^{61}\text{Ti}_{39}$	61	22	39	1/2 ⁻	-1.00110
$^{31}\text{Ne}_{21}$	31	10	21	3/2 ⁻	-0.6349	$^{63}\text{Ti}_{41}$	63	22	41	1/2 ⁻	-1.11700
$^{19}\text{Na}_8$	19	11	8	5/2 ⁺	3.8231	$^{47}\text{V}_{24}$	47	23	24	3/2 ⁻	3.8990
$^{33}\text{Na}_{22}$	33	11	22	3/2 ⁺	2.33460	$^{53}\text{V}_{30}$	53	23	30	7/2 ⁻	4.67110
$^{19}\text{Mg}_7$	19	12	7	1/2 ⁻	-0.4512	$^{55}\text{V}_{32}$	55	23	32	7/2 ⁻	5.11200
$^{35}\text{Mg}_{23}$	35	12	23	1/2 ⁻	-0.9276	$^{43}\text{Cr}_{19}$	43	24	19	3/2 ⁺	-0.45540
$^{21}\text{Al}_8$	21	13	8	5/2 ⁺	3.8569	$^{45}\text{Cr}_{21}$	45	24	21	7/2 ⁻	-0.91120
$^{35}\text{Al}_{22}$	35	13	22	5/2 ⁺	3.7200	$^{47}\text{Cr}_{23}$	47	24	23	3/2 ⁻	-0.42440
$^{39}\text{Al}_{26}$	39	13	26	5/2 ⁺	3.6895	$^{55}\text{Cr}_{31}$	55	24	31	3/2 ⁻	-0.7240
$^{23}\text{Si}_9$	23	14	9	5/2 ⁺	-0.8853	$^{57}\text{Cr}_{33}$	57	24	33	3/2 ⁻	-0.46110

Tablo A.1. (Devamı) Proton sayısı 2-28 arasındaki Manyetik Momenti belirlenmemiş tek A'lı çekirdeklerin Anfis ile Manyetik Momentlerinin tahminleri

Çekirdek	A	Z	N	I	μ_{Anfis}	Çekirdek	A	Z	N	I	μ_{Anfis}
³¹ Si ₇	31	14	7	3/2 ⁺	1.2309	⁵⁷ Mn ₃₂	57	25	32	5/2 ⁻	3.5012
³⁷ Si ₂₃	37	14	23	5/2 ⁻	-0.8812	⁶³ Mn ₃₈	63	25	38	5/2 ⁻	3.4400
³⁹ Si ₂₅	39	14	25	5/2 ⁻	-0.8154	⁶³ Mn ₃₈	63	25	38	5/2 ⁻	3.4400
⁴¹ Si ₂₇	41	14	27	7/2 ⁻	-1.6612	⁶⁵ Mn ₄₀	65	25	40	5/2 ⁻	3.57810
⁴³ Si ₂₉	43	14	29	3/2 ⁻	1.25880	⁶⁷ Mn ₄₂	67	25	42	5/2 ⁻	3.5351
²⁵ P ₁₀	25	15	10	1/2 ⁺	1.1789	⁶⁷ Mn ₄₂	67	25	42	5/2 ⁻	3.5351
³³ P ₁₈	33	15	18	1/2 ⁺	1.1009	⁷¹ Mn ₄₆	71	25	46	5/2 ⁻	3.34550
³⁵ P ₂₀	35	15	20	1/2 ⁺	1.2198	⁷³ Mn ₄₈	73	25	48	5/2 ⁻	3.55580
³⁷ P ₂₂	37	15	22	1/2 ⁺	1.2511	⁴⁵ Fe ₁₉	45	26	19	3/2 ⁺	-0.38910
³⁹ P ₂₄	39	15	24	1/2 ⁺	1.2300	⁴⁷ Fe ₂₁	47	26	21	7/2 ⁻	-1.0089
⁴¹ P ₂₆	41	15	26	1/2 ⁺	1.1160	⁴⁹ Fe ₂₃	49	26	23	7/2 ⁻	-1.0199
⁴³ P ₂₈	43	15	28	1/2 ⁺	1.2364	⁵¹ Fe ₂₅	51	26	25	5/2 ⁻	2.72213
⁴⁵ P ₃₀	45	15	30	1/2 ⁺	1.1031	⁵³ Fe ₂₇	53	26	27	7/2 ⁻	-1.03677
²⁷ S ₁₁	27	16	11	5/2 ⁺	1.1145	⁵⁵ Fe ₂₉	55	26	29	3/2 ⁻	-0.38879
²⁹ S ₁₃	29	16	13	5/2 ⁺	1.0091	⁶¹ Fe ₃₅	61	26	35	3/2 ⁻	-0.49932
³⁷ S ₂₁	37	16	21	7/2 ⁻	1.1239	⁶³ Fe ₃₇	63	26	37	5/2 ⁻	2.20000
³⁹ S ₂₃	39	16	23	7/2 ⁻	1.11480	⁶⁵ Fe ₃₉	65	26	39	1/2 ⁻	-1.1600
⁴¹ S ₂₅	41	16	25	7/2 ⁻	1.14532	⁶⁷ Fe ₄₁	67	26	41	5/2 ⁺	2.91220
⁴³ S ₂₇	43	16	27	3/2 ⁻	0.6678	⁶⁹ Fe ₄₃	69	26	43	1/2 ⁻	0.11440
⁴⁵ S ₂₉	45	16	29	3/2 ⁺	0.6432	⁷¹ Fe ₄₅	71	26	45	7/2 ⁺	-1.0221
²⁹ S ₁₃	29	16	13	5/2 ⁺	1.0091	⁷³ Fe ₄₇	73	26	47	7/2 ⁺	-1.0411
³⁷ S ₂₁	37	16	21	7/2 ⁻	1.1239	⁷⁵ Fe ₄₉	75	26	49	7/2 ⁺	-1.1009
³⁹ S ₂₃	39	16	23	7/2 ⁻	1.11480	⁴⁷ Co ₂₀	47	27	20	7/2 ⁻	4.87900
⁴¹ S ₂₅	41	16	25	7/2 ⁻	1.1453	⁴⁹ Co ₂₂	49	27	22	7/2 ⁻	4.54270
⁴³ S ₂₇	43	16	27	3/2 ⁻	0.6678	⁵¹ Co ₂₄	51	27	24	7/2 ⁻	4.63580
⁴⁵ S ₂₉	45	16	29	3/2 ⁺	0.6432	⁵³ Co ₂₆	53	27	26	7/2 ⁻	4.9120
⁴⁷ S ₃₁	47	16	31	3/2 ⁻	0.7812	⁶¹ Co ₃₄	61	27	34	7/2 ⁻	4.67330
⁴⁹ S ₃₃	49	16	33	3/2 ⁻	0.72120	⁶³ Co ₃₆	63	27	36	7/2 ⁻	4.63224
²⁹ Cl ₁₂	29	17	12	1/2 ⁺	0.68145	⁶⁵ Co ₃₈	65	27	38	7/2 ⁻	4.5330
³¹ Cl ₁₄	31	17	14	3/2 ⁺	0.88230	⁶⁷ Co ₄₀	67	27	40	7/2 ⁻	4.9509
³⁹ Cl ₂₂	39	17	22	3/2 ⁺	0.79110	⁶⁹ Co ₄₂	69	27	42	7/2 ⁻	4.62240
⁴¹ Cl ₂₄	41	17	24	1/2 ⁺	0.6410	⁷¹ Co ₄₄	71	27	44	7/2 ⁻	4.8334
⁴³ Cl ₂₆	43	17	26	1/2 ⁺	0.6912	⁷³ Co ₄₆	73	27	46	7/2 ⁻	4.8434
⁴⁵ Cl ₂₈	45	17	28	1/2 ⁺	0.72470	⁷⁵ Co ₄₈	75	27	48	7/2 ⁻	4.90345
⁴⁹ Cl ₃₂	49	17	32	3/2 ⁺	0.81220	⁷⁷ Co ₅₀	77	27	50	7/2 ⁻	4.77850
⁵¹ Cl ₃₄	51	17	34	3/2 ⁺	0.74950	⁴⁹ Ni ₂₁	49	28	21	7/2 ⁻	0.3222

Tablo A.1. (Devamı) Proton sayısı 2-28 arasındaki Manyetik Momenti belirlenmemiş tek A'lı çekirdeklerin Anfis ile Manyetik Momentlerinin tahminleri

Çekirdek	A	Z	N	I	μ_{Anfis}	Çekirdek	A	Z	N	I	μ_{Anfis}
$^{31}\text{Ar}_{13}$	31	18	13	$5/2^+$	-1.01120	$^{51}\text{Ni}_{23}$	51	28	23	$7/2^-$	-0.61223
$^{45}\text{Ar}_{27}$	45	18	27	$5/2^-$	-1.00970	$^{53}\text{Ni}_{25}$	53	28	25	$7/2^-$	-0.6911
$^{47}\text{Ar}_{29}$	47	18	29	$3/2^-$	1.15230	$^{55}\text{Ni}_{27}$	55	28	27	$7/2^-$	-0.79008
$^{49}\text{Ar}_{31}$	49	18	31	$3/2^-$	1.15410	$^{59}\text{Ni}_{31}$	59	28	31	$3/2^-$	-0.8889
$^{53}\text{Ar}_{35}$	53	18	35	$5/2^-$	-1.02110	$^{63}\text{Ni}_{35}$	63	28	35	$1/2^-$	0.654560
$^{31}\text{K}_{12}$	31	19	12	$3/2^+$	0.19220	$^{69}\text{Ni}_{41}$	69	28	41	$9/2^+$	0.7798
$^{49}\text{K}_{30}$	49	19	30	$1/2^+$	1.34000	$^{25}\text{Si}_{11}$	25	14	11	$5/2^+$	-0.8234
$^{59}\text{Cr}_{35}$	59	24	35	$1/2^-$	0.4990						

EK-B

Tablo B.2. $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^1H [$1/2^+$]	2.7928473	2.8924	^{21}Ne [$3/2^+$]	-0.661797	-0.661
^3H [$1/2^+$]	2.9789624	2.96895	^{23}Ne [$5/2^+$]	1.0817	1.112
^3He [$1/2^+$]	-2.1274977	-2.258977	^{25}Ne [$1/2^+$]	-1.0062	-1.112
^7Li [$3/2^-$]	3.256427	3.389427	^{21}Mg [$5/2^+$]	-0.983	-0.990
^9Li [$3/2^-$]	3.43678	3.89578	^{23}Mg [$3/2^+$]	0.5364	0.5512
^{11}Li [$3/2^-$]	3.6712	3.7580	^{25}Mg [$5/2^+$]	-0.85545	-0.855
^7Be [$3/2^-$]	-1.39928	-1.4858	^{27}Mg [$1/2^+$]	-0.411	-0.5001
^9Be [$3/2^-$]	-1.177432	-1.25832	^{29}Mg [$3/2^+$]	0.9780	0.9881
^{11}Be [$3/2^-$]	-1.6814	-1.6584	^{31}Mg [$1/2^+$]	-0.88355	-0.8835
^{11}B [$3/2^-$]	2.6886489	2.789548	^{33}Mg [$3/2^+$]	-0.7456	-0.7456
^{13}B [$3/2^-$]	3.1778	3.1778	^{23}Al [$5/2^+$]	3.889	3.889
^{15}B [$3/2^-$]	2.659	2.896	^{25}Al [$5/2^+$]	3.6455	3.6112
^{17}B [$3/2^-$]	2.55	2.5897	^{27}Al [$5/2^+$]	3.6415069	3.666
^9C [$3/2^-$]	-1.3914	-1.4414	^{31}Al [$5/2^+$]	3.830	3.6004
^{11}C [$3/2^-$]	-0.964	-1.008	^{33}Al [$5/2^+$]	4.088	3.679
^{13}C [$1/2^-$]	0.70241	0.7298	^{27}Si [$5/2^+$]	-0.8652	-0.8652
^{15}C [$1/2^+$]	1.32	1.440	^{29}Si [$1/2^+$]	-0.55529	-0.555
^{17}C [$3/2^+$]	0.758	0.8274	^{33}Si [$3/2^+$]	1.21	1.00
^{13}N [$1/2^-$]	0.3222	0.3582	^{35}Si [$7/2^-$]	-1.638	-1.638
^{15}N [$1/2^-$]	-0.28318	-0.283	^{29}P [$1/2^+$]	1.2346	1.23
^{17}N [$1/2^-$]	0.3551	0.3551	^{31}P [$1/2^+$]	1.13160	1.1316
^{19}N [$1/2^-$]	0.305	0.3050	^{31}S [$1/2^+$]	0.48793	0.4879
^{13}O [$3/2^-$]	1.3891	1.38910	^{33}S [$3/2^+$]	0.64382	0.4912
^{15}O [$1/2^-$]	0.71951	0.72547	^{35}S [$3/2^+$]	1.00	0.878
^{17}O [$5/2^+$]	-1.89379	-1.8937	^{43}S [$7/2^-$]	1.110	1.110
^{19}O [$5/2^+$]	1.53195	1.5368	^{33}Cl [$3/2^+$]	0.7549	0.750
^{17}F [$5/2^+$]	4.7213	4.7689	^{35}Cl [$3/2^+$]	0.82187	0.821
^{19}F [$1/2^+$]	2.628868	2.634568	^{37}Cl [$3/2^+$]	0.68412	0.6665
^{21}F [$5/2^+$]	3.9194	3.7854	^{33}Ar [$1/2^+$]	-0.723	-0.712
^{17}Ne [$1/2^-$]	0.7873	0.72580	^{35}Ar [$3/2^+$]	0.6322	0.6322
^{19}Ne [$1/2^+$]	-1.8846	-1.89240	^{37}Ar [$3/2^+$]	1.145	1.145
^{39}Ar [$7/2^-$]	-1.590	-1.67580	^{55}Co [$7/2^-$]	4.822	4.645
^{41}Ar [$7/2^-$]	-1.309	1.0714	^{57}Co [$7/2^-$]	4.720	4.617
^{43}Ar [$5/2^-$]	-1.022	-1.0062	^{59}Co [$7/2^-$]	4.627	4.627
^{35}K [$3/2^+$]	0.392	0.38800	^{55}Ni [$3/2^-$]	-0.98	-0.98
^{37}K [$3/2^+$]	0.20321	0.25770	^{57}Ni [$3/2^-$]	-0.7975	-0.932

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{39}K [3/2 ⁺]	0.39147	0.37121	^{59}Ni [5/2 ⁻]	0.35	0.35
^{41}K [3/2 ⁺]	0.2148701	0.2599	^{61}Ni [3/2 ⁻]	-0.75002	-0.733
^{43}K [3/2 ⁺]	0.1633	0.1633	^{63}Ni [5/2 ⁺]	0.752	0.62
^{45}K [3/2 ⁺]	0.1734	0.1734	^{65}Ni [5/2 ⁻]	0.69	0.678
^{47}K [1/2 ⁺]	1.933	1.3001	^{67}Ni [1/2 ⁻]	0.601	0.643
^{49}K [1/2 ⁺]	1.3386	1.33	^{57}Cu [3/2 ⁻]	2.582	2.580
^{51}K [3/2 ⁺]	0.513	0.634	^{59}Cu [3/2 ⁻]	1.8910	2.145
^{39}Ca [3/2 ⁺]	1.02168	1.0091	^{61}Cu [3/2 ⁻]	2.1083	2.112
^{41}Ca [7/2 ⁻]	-1.594781	-1.375	^{63}Cu [3/2 ⁻]	2.2236	2.254
^{43}Ca [7/2 ⁻]	-1.3173	-1.344	^{65}Cu [3/2 ⁻]	2.3817	2.2455
^{45}Ca [7/2 ⁻]	-1.3274	-1.327	^{67}Cu [3/2 ⁻]	2.5142	2.555
^{47}Ca [7/2 ⁻]	-1.38	-1.38	^{69}Cu [3/2 ⁻]	2.8383	2.442
^{49}Ca [3/2 ⁻]	-1.38	-1.38	^{71}Cu [3/2 ⁻]	2.2747	2.2988
^{51}Ca [3/2 ⁻]	-1.0496	-1.112	^{73}Cu [3/2 ⁻]	1.7426	2.111
^{41}Sc [7/2 ⁻]	5.431	5.45	^{75}Cu [5/2 ⁻]	1.0062	1.631
^{43}Sc [7/2 ⁺]	4.528	4.522	^{77}Cu [5/2 ⁻]	1.61	1.6007
^{45}Sc [7/2 ⁻]	4.7564	5.75	^{63}Zn [3/2 ⁻]	-0.28164	-0.280
^{47}Sc [7/2 ⁻]	5.34	4.221	^{65}Zn [5/2 ⁻]	0.7690	0.877
^{49}Sc [7/2 ⁻]	5.62	4.982	^{67}Zn [5/2 ⁻]	0.875479	0.875
^{43}Ti [7/2 ⁻]	0.85	0.85	^{69}Zn [1/2 ⁻]	0.557	0.557
^{45}Ti [7/2 ⁻]	0.095	0.9511	^{71}Zn [1/2 ⁻]	0.551	0.558
^{47}Ti [5/2 ⁻]	-0.78848	-0.791	^{73}Zn [1/2 ⁻]	0.5581	0.5512
^{49}Ti [7/2 ⁻]	-1.10417	-0.945	^{75}Zn [7/2 ⁺]	-0.7881	-0.917
^{43}V [7/2 ⁻]	5.106	5.100	^{77}Zn [7/2 ⁺]	-0.9067	-0.9067
^{45}V [7/2 ⁻]	3.63	5.244	^{79}Zn [9/2 ⁺]	-1.1857	-1.1877
^{49}V [7/2 ⁻]	4.47	4.47	^{63}Ga [3/2 ⁻]	0.1469	0.1469
^{51}V [7/2 ⁻]	5.1487057	5.148	^{67}Ga [3/2 ⁻]	1.8507	1.858
^{49}Cr [5/2 ⁻]	0.476	0.477	^{69}Ga [3/2 ⁻]	2.01659	2.01659
^{51}Cr [7/2 ⁻]	-0.934	-0.934	^{71}Ga [3/2 ⁻]	2.56227	2.918
^{53}Cr [3/2 ⁻]	-0.47454	-0.475	^{73}Ga [3/2 ⁺]	0.209	0.209
^{51}Mn [5/2 ⁻]	3.5683	3.5683	^{75}Ga [3/2 ⁻]	1.836	1.836
^{53}Mn [7/2 ⁻]	5.035	5.035	^{77}Ga [3/2 ⁻]	2.020	1.921
^{55}Mn [5/2 ⁻]	3.4532	3.4	^{79}Ga [3/2 ⁻]	1.047	1.047
^{59}Mn [5/2 ⁻]	3.493	3.493	^{81}Ga [5/2 ⁻]	1.747	0.1469
^{61}Mn [5/2 ⁻]	3.535	3.411	^{67}Ge [9/2 ⁺]	-0.849	-0.849
^{63}Mn [5/2 ⁻]	3.441	3.441	^{69}Ge [5/2 ⁻]	0.735	0.735

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
⁵³ Fe [3/2 ⁻]	-0.386	-0.38	⁷¹ Ge [1/2 ⁻]	0.547	0.547
⁵⁵ Fe [5/2 ⁻]	2.7	2.7221	⁷³ Ge [9/2 ⁺]	-0.8794	-0.879
⁵⁷ Fe [1/2 ⁻]	0.09044	0.09	⁷⁵ Ge [1/2 ⁻]	0.510	0.510
⁵⁹ Fe [3/2 ⁻]	-0.3358	-0.335	⁶⁹ As [5/2 ⁺]	1.623	1.623
⁶¹ Fe [9/2 ⁺]	-1.031	-1.031	⁷¹ As [5/2 ⁻]	1.674	1.626
⁷³ As [5/2 ⁺]	1.63	1.623	⁹⁹ Sr [3/2 ⁺]	-0.261	-0.261
⁷⁵ As [3/2 ⁻]	1.43948	1.449	⁸⁷ Y [1/2 ⁻]	-0.19	-0.19
⁷⁷ As [3/2 ⁻]	1.2946	1.4113	⁸⁹ Y [1/2 ⁻]	-0.13741	-0.13
⁷³ Se [9/2 ⁺]	0.892	0.892	⁹¹ Y [1/2 ⁻]	0.1641	-0.122
⁷⁵ Se [5/2 ⁺]	0.683	0.683	⁹³ Y [1/2 ⁻]	-0.12	-0.12
⁷⁷ Se [1/2 ⁻]	0.5350	0.53	⁹⁵ Y [1/2 ⁻]	-0.16	-0.12
⁷⁹ Se [7/2 ⁺]	-1.018	-1.018	⁹⁷ Y [1/2 ⁻]	-0.12	-0.12
⁷³ Br [3/2 ⁻]	1.97	0.991	⁹⁹ Y [5/2 ⁺]	3.18	3.18
⁷⁵ Br [3/2 ⁻]	0.76	0.76	¹⁰¹ Y [5/2 ⁺]	3.22	3.22
⁷⁷ Br [3/2 ⁻]	0.92	0.92	⁸⁷ Zr [9/2 ⁺]	-0.895	-0.895
⁷⁹ Br [3/2 ⁻]	2.1064	2.1	⁸⁹ Zr [9/2 ⁺]	-1.046	-0.946
⁸¹ Br [3/2 ⁻]	2.2705	2.270	⁹¹ Zr [5/2 ⁺]	-1.3036	-1.30
⁷⁵ Kr [5/2 ⁺]	-0.531	-0.531	⁹⁵ Zr [5/2 ⁺]	1.13	1.13
⁷⁷ Kr [5/2 ⁺]	-0.583	-0.533	⁹⁷ Zr [1/2 ⁺]	-0.937	-0.93
⁷⁹ Kr [1/2 ⁻]	0.536	0.536	⁹⁹ Zr [1/2 ⁺]	-0.930	-0.931
⁸¹ Kr [7/2 ⁺]	-0.908	-0.908	¹⁰¹ Zr [3/2 ⁺]	-0.272	-0.272
⁸³ Kr [9/2 ⁺]	-0.97066	-1.07	⁸⁹ Nb [9/2 ⁺]	6.216	6.216
⁸⁵ Kr [9/2 ⁺]	-1.005	-1.005	⁹¹ Nb [9/2 ⁺]	6.521	6.11
⁸⁷ Kr [5/2 ⁺]	-1.023	-1.023	⁹³ Nb [9/2 ⁺]	6.1705	6.1705
⁸⁹ Kr [3/2 ⁺]	-0.330	-0.330	⁹⁵ Nb [9/2 ⁺]	6.141	6.141
⁹¹ Kr [5/2 ⁺]	-0.583	-0.583	⁹⁷ Nb [9/2 ⁺]	6.153	6.153
⁹³ Kr [1/2 ⁺]	-0.413	-0.413	⁹⁹ Nb [9/2 ⁺]	5.97	6.211
⁹⁵ Kr [1/2 ⁺]	-0.410	-0.410	¹⁰¹ Nb [5/2 ⁺]	3.190	3.1
⁷⁵ Rb [3/2 ⁻]	0.579	0.579	¹⁰³ Nb [5/2 ⁺]	3.137	3.1
⁷⁷ Rb [3/2 ⁻]	0.654468	0.577	⁹¹ Mo [9/2 ⁺]	-0.932	-0.932
⁷⁹ Rb [5/2 ⁺]	3.3579	3.35	⁹⁵ Mo [5/2 ⁺]	-0.9142	-0.914
⁸¹ Rb [3/2 ⁻]	2.0595	2.05	⁹⁷ Mo [5/2 ⁺]	-0.9335	-0.93
⁸³ Rb [5/2 ⁻]	1.4249	1.4	⁹⁹ Mo [1/2 ⁺]	0.375	0.375
⁸⁵ Rb [5/2 ⁻]	1.35298	1.352	¹⁰³ Mo [3/2 ⁺]	-0.27	-0.27
⁸⁷ Rb [3/2 ⁻]	2.75131	2.75	¹⁰⁵ Mo [5/2 ⁻]	-0.55	-0.55
⁸⁹ Rb [3/2 ⁻]	2.3836	2.383	⁹³ Tc [9/2 ⁺]	6.32	5.2

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
⁹¹ Rb [3/2 ⁻]	2.1815	2.3	⁹⁵ Tc [9/2 ⁺]	5.94	5.94
⁹³ Rb [5/2 ⁻]	1.410	1.410	⁹⁷ Tc [9/2 ⁺]	5.82	5.82
⁹⁵ Rb [5/2 ⁻]	1.334	1.334	⁹⁹ Tc [7/2 ⁺]	5.6847	5.6847
⁹⁷ Rb [3/2 ⁻]	1.841	1.841	⁹⁵ Ru [5/2 ⁺]	0.861	0.86
⁷⁷ Sr [5/2 ⁺]	-0.348	-0.348	⁹⁷ Ru [5/2 ⁺]	-0.787	-0.67
⁷⁹ Sr [3/2 ⁻]	-0.474	-0.474	⁹⁹ Ru [5/2 ⁺]	-0.641	-0.641
⁸¹ Sr [1/2 ⁻]	0.543	0.543	¹⁰¹ Ru [5/2 ⁺]	-0.719	-0.69
⁸³ Sr [7/2 ⁺]	-0.829	-0.829	¹⁰³ Ru [3/2 ⁺]	0.206	0.206
⁸⁵ Sr [9/2 ⁺]	-1.000	-1.0	¹⁰³ Rh [1/2 ⁻]	-0.8840	-0.884
⁸⁷ Sr [9/2 ⁺]	-1.0928	-1.09	¹⁰⁵ Rh [7/2 ⁺]	4.41	4.40
⁸⁹ Sr [5/2 ⁺]	-1.147	-1.147	¹⁰¹ Pd [5/2 ⁺]	-0.66	-0.66
⁹¹ Sr [5/2 ⁺]	-0.885	-1.085	¹⁰⁵ Pd [5/2 ⁺]	-0.642	-0.642
⁹³ Sr [5/2 ⁺]	-0.793	-0.793	⁹⁷ Ag [9/2 ⁺]	6.13	5.912
⁹⁵ Sr [1/2 ⁻]	-0.537	-0.537	⁹⁹ Ag [9/2 ⁺]	5.81	5.81
⁹⁷ Sr [1/2 ⁻]	-0.498	-0.498	¹⁰¹ Ag [9/2 ⁺]	5.57	5.57
¹⁰³ Ag [7/2 ⁺]	4.432	4.432	¹¹⁷ Sb [5/2 ⁺]	3.43	3.43
¹⁰⁵ Ag [1/2 ⁻]	0.1014	0.1014	¹¹⁹ Sb [5/2 ⁺]	3.45	3.45
¹⁰⁷ Ag [1/2 ⁻]	-0.11357	-0.11	¹²¹ Sb [5/2 ⁺]	3.3634	3.41
¹⁰⁹ Ag [1/2 ⁻]	0.13056	0.13	¹²³ Sb [7/2 ⁺]	2.5498	2.54
¹¹¹ Ag [1/2 ⁻]	-0.146	-0.146	¹²⁵ Sb [7/2 ⁺]	2.63	2.59
¹¹³ Ag [1/2 ⁻]	0.159	0.159	¹²⁷ Sb [7/2 ⁺]	2.697	2.697
¹⁰¹ Cd [5/2 ⁺]	-0.8970	-0.8970	¹²⁹ Sb [7/2 ⁺]	2.79	2.647
¹⁰³ Cd [5/2 ⁺]	-0.81	-0.8	¹³¹ Sb [7/2 ⁺]	2.89	2.89
¹⁰⁵ Cd [5/2 ⁺]	-0.7393	-0.7393	¹³³ Sb [7/2 ⁺]	3.00	3.00
¹⁰⁷ Cd [5/2 ⁺]	-0.61505	-0.615	¹¹⁹ Te [1/2 ⁺]	0.25	0.25
¹⁰⁹ Cd [5/2 ⁺]	-0.82784	-0.82	¹²¹ Te [11/2 ⁻]	0.895	0.895
¹¹¹ Cd [1/2 ⁺]	-0.59488	-0.684	¹²³ Te [1/2 ⁺]	-0.73694	-0.736
¹¹³ Cd [1/2 ⁺]	-0.62230	-0.622	¹²⁵ Te [1/2 ⁺]	-0.8885	-0.781
¹¹⁵ Cd [1/2 ⁺]	-0.64842	-0.648	¹²⁷ Te [3/2 ⁺]	0.635	0.635
¹¹⁷ Cd [1/2 ⁺]	-0.7436	-0.66	¹²⁹ Te [3/2 ⁺]	0.702	0.702
¹¹⁹ Cd [1/2 ⁺]	-0.9201	-0.9201	¹³¹ Te [3/2 ⁺]	0.696	0.711
¹²¹ Cd [3/2 ⁺]	0.6269	0.6269	¹³³ Te [3/2 ⁺]	0.85	0.853
¹²³ Cd [3/2 ⁺]	0.7896	0.86	¹³⁵ Te [7/2 ⁻]	-0.69	-0.69
¹²⁵ Cd [3/2 ⁺]	0.8603	0.8603	¹¹⁷ I [5/2 ⁺]	3.1	2.88
¹²⁷ Cd [3/2 ⁺]	0.8783	0.8783	¹¹⁹ I [5/2 ⁺]	2.9	2.901
¹²⁹ Cd [3/2 ⁺]	0.8481	0.88	¹²¹ I [5/2 ⁻]	2.3	2.311

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{105}In [9/2 ⁺]	5.675	5.675	^{123}I [5/2 ⁺]	2.818	2.49
^{107}In [9/2 ⁺]	5.585	5.585	^{125}I [5/2 ⁺]	2.821	2.821
^{109}In [9/2 ⁺]	5.538	5.538	^{127}I [5/2 ⁺]	2.81327	2.83
^{111}In [9/2 ⁺]	5.503	5.503	^{129}I [7/2 ⁺]	2.6210	2.6210
^{113}In [9/2 ⁺]	5.5289	5.528	^{131}I [7/2 ⁺]	2.742	2.7
^{115}In [9/2 ⁺]	5.5408	5.551	^{133}I [7/2 ⁺]	2.856	2.856
^{117}In [9/2 ⁺]	5.519	5.519	^{135}I [7/2 ⁺]	2.940	2.940
^{119}In [9/2 ⁺]	5.515	5.515	^{117}Xe [5/2 ⁺]	-0.5938	-0.5938
^{121}In [9/2 ⁺]	5.502	5.51	^{119}Xe [5/2 ⁺]	-0.6542	-0.6542
^{123}In [9/2 ⁺]	5.491	5.491	^{121}Xe [5/2 ⁺]	-0.701	-0.61
^{125}In [9/2 ⁺]	5.502	5.502	^{123}Xe [1/2 ⁺]	-0.150	-0.150
^{127}In [9/2 ⁺]	5.522	5.522	^{125}Xe [1/2 ⁺]	-0.269	-0.269
^{109}Sn [5/2 ⁺]	-1.079	-1.079	^{127}Xe [1/2 ⁺]	-0.5033	-0.5033
^{111}Sn [7/2 ⁺]	0.608	0.608	^{129}Xe [1/2 ⁺]	-0.777976	-0.512
^{113}Sn [1/2 ⁺]	-0.8791	-0.8791	^{131}Xe [3/2 ⁺]	0.6915	0.6915
^{115}Sn [1/2 ⁺]	-0.91883	-0.88	^{133}Xe [3/2 ⁺]	0.8129	0.8129
^{117}Sn [1/2 ⁺]	-1.00104	-1.00	^{135}Xe [3/2 ⁺]	0.9032	0.92
^{119}Sn [1/2 ⁺]	-1.04728	-1.047	^{137}Xe [7/2 ⁻]	-0.968	-0.968
^{121}Sn [3/2 ⁺]	0.6978	0.6978	^{139}Xe [3/2 ⁻]	-0.304	-0.304
^{123}Sn [11/2 ⁻]	-1.3700	-1.37	^{141}Xe [5/2 ⁺]	0.010	0.010
^{125}Sn [11/2 ⁻]	-1.348	-1.3	^{143}Xe [5/2 ⁻]	-0.4599	-0.4599
^{127}Sn [11/2 ⁻]	-1.329	-1.329	^{119}Cs [9/2 ⁺]	5.46	5.46
^{129}Sn [3/2 ⁺]	0.754	0.754	^{121}Cs [3/2 ⁺]	0.770	0.770
^{131}Sn [3/2 ⁺]	0.747	0.747	^{123}Cs [1/2 ⁺]	1.377	1.4
^{115}Sb [5/2 ⁺]	3.46	3.46	^{125}Cs [1/2 ⁺]	1.409	1.409
^{127}Cs [1/2 ⁺]	1.459	1.44	^{141}Sm [1/2 ⁺]	-0.74	-0.74
^{129}Cs [1/2 ⁺]	1.491	1.491	^{143}Sm [3/2 ⁺]	1.01	1.01
^{131}Cs [5/2 ⁺]	3.53	3.53	^{145}Sm [7/2 ⁻]	-1.11	-1.661
^{133}Cs [7/2 ⁺]	2.58202	2.582	^{147}Sm [7/2 ⁻]	-0.812	-0.812
^{135}Cs [7/2 ⁺]	2.7324	2.7324	^{149}Sm [7/2 ⁻]	-0.6677	-0.66
^{137}Cs [7/2 ⁺]	2.8513	2.8513	^{151}Sm [5/2 ⁻]	-0.3611	-0.36
^{139}Cs [7/2 ⁺]	2.696	2.696	^{153}Sm [3/2 ⁺]	-0.021	-0.021
^{141}Cs [7/2 ⁺]	2.438	2.438	^{139}Eu [11/2 ⁻]	6.1	6.10
^{143}Cs [3/2 ⁺]	0.870	0.780	^{141}Eu [5/2 ⁺]	3.494	3.494
^{145}Cs [3/2 ⁺]	0.784	0.784	^{143}Eu [5/2 ⁺]	3.673	3.673
^{121}Ba [5/2 ⁺]	0.660	0.660	^{145}Eu [5/2 ⁺]	3.999	3.612

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{123}Ba [$5/2^+$]	-0.680	-0.680	^{147}Eu [$5/2^+$]	3.736	3.736
^{125}Ba [$1/2^+$]	0.177	0.177	^{149}Eu [$5/2^+$]	3.576	3.576
^{127}Ba [$1/2^+$]	0.0834	0.1804	^{151}Eu [$5/2^+$]	3.4717	3.4717
^{129}Ba [$1/2^+$]	-0.398	-0.398	^{153}Eu [$5/2^+$]	1.5324	1.32
^{131}Ba [$1/2^+$]	0.708113	0.708	^{155}Eu [$5/2^+$]	1.520	1.520
^{133}Ba [$1/2^+$]	0.77167	0.771	^{157}Eu [$5/2^+$]	1.50	1.50
^{135}Ba [$3/2^+$]	0.83794	0.837	^{159}Eu [$5/2^+$]	1.38	1.38
^{137}Ba [$3/2^+$]	0.93737	0.83	^{145}Gd [$1/2^+$]	-0.74	-0.774
^{139}Ba [$7/2^-$]	-0.973	-0.973	^{147}Gd [$7/2^-$]	1.02	0.819
^{141}Ba [$3/2^-$]	-0.337	-0.337	^{149}Gd [$7/2^-$]	0.88	0.880
^{143}Ba [$5/2^+$]	0.443	0.443	^{151}Gd [$7/2^-$]	0.77	0.771
^{145}Ba [$5/2^-$]	-0.285	-0.285	^{153}Gd [$3/2^-$]	0.38	0.38
^{135}La [$5/2^+$]	3.70	3.7	^{155}Gd [$3/2^-$]	-0.2572	-0.25
^{137}La [$7/2^+$]	2.700	2.7	^{157}Gd [$3/2^-$]	-0.3398	-0.33
^{139}La [$7/2^+$]	2.78304	2.78	^{159}Gd [$3/2^-$]	-0.44	-0.44
^{137}Ce [$3/2^+$]	0.96	0.96	^{147}Tb [$1/2^+$]	1.70	1.70
^{139}Ce [$3/2^+$]	1.06	0.98	^{149}Tb [$1/2^+$]	1.35	1.35
^{141}Ce [$7/2^-$]	1.09	1.09	^{151}Tb [$1/2^+$]	0.919	1.21
^{143}Ce [$3/2^-$]	0.43	0.43	^{153}Tb [$5/2^+$]	3.44	3.44
^{141}Pr [$5/2^+$]	4.2754	4.2	^{155}Tb [$3/2^+$]	2.01	2.01
^{143}Pr [$7/2^+$]	2.701	2.70	^{157}Tb [$3/2^+$]	2.01	2.01
^{135}Nd [$9/2^-$]	-0.78	-0.78	^{159}Tb [$3/2^+$]	2.014	2.01
^{137}Nd [$1/2^+$]	-0.633	-0.633	^{161}Tb [$3/2^+$]	2.2	2.01
^{139}Nd [$3/2^+$]	0.907	1.07	^{147}Dy [$1/2^+$]	-0.915	-0.915
^{141}Nd [$3/2^+$]	1.012	1.012	^{149}Dy [$7/2^-$]	-0.119	-0.90
^{143}Nd [$7/2^-$]	-1.065	-1.065	^{151}Dy [$7/2^-$]	-0.945	-0.945
^{145}Nd [$7/2^-$]	-0.656	-0.656	^{153}Dy [$7/2^-$]	-0.782	-0.782
^{147}Nd [$5/2^-$]	0.578	0.578	^{155}Dy [$3/2^-$]	-0.385	-0.385
^{149}Nd [$5/2^-$]	0.351	0.351	^{157}Dy [$3/2^-$]	-0.301	-0.30
^{143}Pm [$5/2^+$]	3.8	3.8	^{159}Dy [$3/2^-$]	-0.354	-0.354
^{145}Pm [$5/2^+$]	3.80	3.8	^{161}Dy [$5/2^+$]	-0.480	-0.480
^{147}Pm [$7/2^+$]	2.58	3.8	^{163}Dy [$5/2^-$]	0.673	0.673
^{149}Pm [$7/2^+$]	3.3	3.3	^{165}Dy [$7/2^+$]	-0.520	-0.520
^{151}Pm [$5/2^+$]	1.8	1.8	^{153}Ho [$11/2^-$]	6.81	6.8
^{139}Sm [$1/2^+$]	-0.53	-0.53	^{155}Ho [$5/2^+$]	3.51	3.50
^{157}Ho [$7/2^-$]	4.35	4.35	^{171}Hf [$7/2^+$]	-0.674	-0.674

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{159}Ho [7/2 ⁻]	4.28	4.28	^{173}Hf [1/2 ⁻]	0.502	0.502
^{161}Ho [7/2 ⁻]	4.25	4.25	^{175}Hf [5/2 ⁻]	-0.677	-0.677
^{163}Ho [7/2 ⁻]	4.23	4.23	^{177}Hf [7/2 ⁻]	0.7935	0.793
^{165}Ho [7/2 ⁻]	4.17	4.23	^{179}Hf [9/2 ⁺]	-0.6409	-0.64
^{153}Er [7/2 ⁻]	-0.939	-0.939	^{173}Ta [5/2 ⁻]	1.70	2.23
^{155}Er [7/2 ⁻]	-0.671	-0.671	^{175}Ta [7/2 ⁺]	2.27	2.27
^{157}Er [3/2 ⁻]	-0.414	-0.34	^{177}Ta [7/2 ⁺]	2.25	2.25
^{159}Er [3/2 ⁻]	-0.305	-0.305	^{179}Ta [7/2 ⁺]	2.289	2.289
^{161}Er [3/2 ⁻]	-0.367	-0.367	^{181}Ta [7/2 ⁺]	2.3705	2.3705
^{163}Er [5/2 ⁻]	0.560	0.560	^{183}Ta [7/2 ⁺]	2.36	2.36
^{165}Er [5/2 ⁻]	0.646	0.646	^{183}W [1/2 ⁻]	0.11778	0.11
^{167}Er [7/2 ⁺]	-0.56385	-0.563	^{185}W [3/2 ⁻]	0.543	0.63
^{169}Er [1/2 ⁻]	0.52	0.52	^{187}W [3/2 ⁻]	0.621	0.621
^{171}Er [5/2 ⁻]	0.659	0.659	^{179}Re [5/2 ⁺]	2.8	3.121
^{153}Tm [11/2 ⁻]	6.93	6.93	^{181}Re [5/2 ⁺]	3.19	3.19
^{157}Tm [1/2 ⁺]	0.476	0.476	^{183}Re [5/2 ⁺]	3.168	3.168
^{159}Tm [5/2 ⁺]	3.42	3.42	^{185}Re [5/2 ⁺]	3.1871	3.18
^{161}Tm [7/2 ⁺]	2.40	2.40	^{187}Re [5/2 ⁺]	3.2197	3.21
^{163}Tm [1/2 ⁺]	-0.082	-0.08	^{183}Os [9/2 ⁺]	-0.794	-0.79
^{165}Tm [1/2 ⁺]	-0.139	-0.081	^{187}Os [1/2 ⁻]	0.06465	0.064
^{167}Tm [1/2 ⁺]	-0.197	-0.197	^{189}Os [3/2 ⁻]	0.65993	0.659
^{169}Tm [1/2 ⁺]	-0.2310	-0.23	^{191}Os [9/2 ⁻]	0.96	0.96
^{171}Tm [1/2 ⁺]	-0.228	-0.228	^{193}Os [3/2 ⁻]	0.730	0.73
^{155}Yb [7/2 ⁻]	-0.91	-0.91	^{183}Ir [5/2 ⁻]	2.40	2.40
^{157}Yb [7/2 ⁻]	-0.639	-0.79	^{185}Ir [5/2 ⁻]	2.605	2.605
^{159}Yb [5/2 ⁻]	-0.368	-0.368	^{187}Ir [3/2 ⁺]	0.17	0.170
^{161}Yb [3/2 ⁻]	-0.327	-0.327	^{189}Ir [3/2 ⁺]	0.147	0.147
^{163}Yb [3/2 ⁻]	-0.374	-0.374	^{191}Ir [3/2 ⁺]	0.1507	0.140
^{165}Yb [5/2 ⁻]	0.478	0.608	^{193}Ir [3/2 ⁺]	0.1637	0.163
^{167}Yb [5/2 ⁻]	0.623	0.623	^{179}Pt [1/2 ⁻]	0.43	0.43
^{169}Yb [7/2 ⁺]	-0.635	-0.635	^{181}Pt [1/2 ⁻]	0.48	0.439
^{171}Yb [1/2 ⁻]	0.49367	0.4936	^{183}Pt [1/2 ⁻]	0.502	0.502
^{173}Yb [5/2 ⁻]	-0.648	-0.648	^{185}Pt [9/2 ⁺]	-0.723	-0.723
^{175}Yb [7/2 ⁻]	0.768	0.768	^{187}Pt [3/2 ⁻]	0.408	0.408
^{177}Yb [9/2 ⁺]	-0.695	-0.695	^{189}Pt [3/2 ⁻]	-0.422	-0.422
^{161}Lu [1/2 ⁺]	0.223	0.223	^{191}Pt [3/2 ⁻]	-0.501	-0.501

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{163}Lu [$1/2^+$]	0.0769	0.076	^{193}Pt [$1/2^-$]	0.603	0.603
^{165}Lu [$1/2^+$]	-0.0245	-0.02	^{195}Pt [$1/2^-$]	0.60952	0.528
^{167}Lu [$7/2^+$]	2.325	2.95	^{197}Pt [$1/2^-$]	0.51	0.51
^{169}Lu [$7/2^+$]	2.295	2.295	^{199}Pt [$5/2^-$]	0.75	0.75
^{171}Lu [$7/2^+$]	2.293	2.293	^{177}Au [$1/2^+$]	1.15	1.15
^{173}Lu [$7/2^+$]	2.281	2.281	^{179}Au [$1/2^+$]	1.01	1.01
^{175}Lu [$7/2^+$]	2.2323	2.232	^{183}Au [$5/2^-$]	1.97	1.97
^{177}Lu [$7/2^+$]	2.239	2.239	^{185}Au [$5/2^-$]	2.17	2.17
^{179}Lu [$7/2^+$]	2.375	2.375	^{187}Au [$1/2^+$]	0.535	1.00
^{189}Au [$1/2^+$]	0.494	0.494	^{209}Pb [$9/2^+$]	-1.4735	-1.473
^{191}Au [$3/2^+$]	0.1369	0.1369	^{211}Pb [$9/2^+$]	-1.4037	-1.403
^{193}Au [$3/2^+$]	0.1396	0.1396	^{199}Bi [$9/2^-$]	4.6	4.6
^{195}Au [$3/2^+$]	0.1487	0.1487	^{201}Bi [$9/2^-$]	4.8	4.8
^{197}Au [$3/2^+$]	0.145746	0.145	^{203}Bi [$9/2^-$]	4.017	4.017
^{199}Au [$3/2^+$]	0.261	0.261	^{205}Bi [$9/2^-$]	4.065	4.065
^{177}Hg [$7/2^-$]	-1.02	-1.02	^{207}Bi [$9/2^-$]	4.0915	4.09
^{179}Hg [$7/2^-$]	-0.94	-0.94	^{209}Bi [$9/2^-$]	4.1103	4.113
^{181}Hg [$1/2^-$]	0.5071	0.50	^{211}Bi [$9/2^-$]	3.79	4.09
^{183}Hg [$1/2^-$]	0.524	0.524	^{213}Bi [$9/2^-$]	3.716	3.716
^{185}Hg [$1/2^-$]	0.509	0.509	^{195}Po [$3/2^-$]	-0.60	-0.60
^{187}Hg [$13/2^+$]	-1.044	-1.044	^{197}Po [$3/2^-$]	-0.88	-0.88
^{189}Hg [$3/2^-$]	-0.6086	-0.6086	^{199}Po [$3/2^-$]	-0.91	-0.91
^{191}Hg [$3/2^-$]	-0.618	-0.6	^{201}Po [$3/2^-$]	0.94	-0.89
^{193}Hg [$3/2^-$]	-0.6276	-0.627	^{203}Po [$5/2^-$]	0.74	0.74
^{195}Hg [$1/2^-$]	0.541474	0.5414	^{205}Po [$5/2^-$]	0.76	0.760
^{197}Hg [$1/2^-$]	0.527374	0.52	^{207}Po [$5/2^-$]	0.79	0.791
^{199}Hg [$1/2^-$]	0.505885	0.5058	^{209}Po [$1/2^-$]	0.68	0.68
^{201}Hg [$3/2^-$]	-0.560225	-0.56	^{211}Po [$9/2^+$]	-1.20	-1.20
^{203}Hg [$5/2^-$]	0.84895	0.845	^{217}Po [$9/2^+$]	-1.11	-1.11
^{205}Hg [$1/2^-$]	0.60089	0.60	^{195}At [$1/2^+$]	1.60	1.69
^{179}Tl [$1/2^+$]	1.631	1.63	^{197}At [$9/2^-$]	3.83	3.83
^{181}Tl [$1/2^+$]	1.632	1.632	^{199}At [$9/2^-$]	3.94	3.94
^{183}Tl [$1/2^+$]	1.62	1.62	^{201}At [$9/2^-$]	4.01	4.01
^{185}Tl [$1/2^+$]	1.61	1.61	^{203}At [$9/2^-$]	4.00	4.0
^{187}Tl [$1/2^+$]	1.55	1.55	^{205}At [$9/2^-$]	4.09	4.0
^{189}Tl [$9/2^-$]	3.76	3.76	^{207}At [$9/2^+$]	4.13	4.13

Tablo B.1. (Devamı) $1 \leq Z \leq 88$ bölgesindeki tek A'lı çekirdeklerin eğitim ve test süreci için Anfis çıkarımları (Test verileri kırmızı ile işaretlenmiştir.)

Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}	Çekirdek [I^π]	μ_{Deney}	μ_{Anfis}
^{191}Tl [$1/2^+$]	1.588	1.588	^{209}At [$9/2^+$]	4.12	4.12
^{193}Tl [$1/2^+$]	1.591	1.591	^{217}At [$9/2^-$]	3.8	4.0
^{195}Tl [$1/2^+$]	1.58	1.58	^{205}Rn [$5/2^-$]	0.802	0.802
^{197}Tl [$1/2^+$]	1.58	1.58	^{207}Rn [$5/2^-$]	0.816	0.816
^{199}Tl [$1/2^+$]	1.60	1.52	^{209}Rn [$5/2^-$]	0.8388	0.838
^{201}Tl [$1/2^+$]	1.605	1.605	^{211}Rn [$1/2^-$]	0.601	0.601
^{203}Tl [$1/2^+$]	1.62225	1.62	^{219}Rn [$5/2^+$]	-0.442	-0.442
^{205}Tl [$3/2^+$]	1.63821	1.638	^{221}Rn [$7/2^+$]	-0.020	-0.020
^{207}Tl [$1/2^+$]	1.876	1.876	^{223}Rn [$7/2^+$]	-0.776	-0.076
^{183}Pb [$13/2^+$]	-1.158	-1.200	^{225}Rn [$7/2^-$]	-0.696	-0.696
^{185}Pb [$3/2^-$]	-1.141	-1.141	^{203}Fr [$9/2^-$]	3.73	3.73
^{187}Pb [$13/2^+$]	-1.210	-1.210	^{205}Fr [$9/2^-$]	3.81	3.81
^{189}Pb [$3/2^-$]	-1.081	-1.081	^{207}Fr [$9/2^-$]	3.89	3.89
^{197}Pb [$3/2^-$]	-1.075	-1.075	^{209}Fr [$9/2^-$]	3.95	3.95
^{199}Pb [$3/2^-$]	-1.0742	-1.07	^{211}Fr [$9/2^-$]	4.00	3.88
^{201}Pb [$5/2^-$]	0.6753	0.675	^{213}Fr [$9/2^-$]	4.02	4.02
^{203}Pb [$5/2^-$]	0.6864	0.6864	^{221}Fr [$5/2^-$]	1.58	1.58
^{205}Pb [$5/2^-$]	0.7117	0.67	^{223}Fr [$3/2^-$]	1.17	1.17
^{207}Pb [$1/2^-$]	0.592583	0.592	^{225}Fr [$3/2^-$]	1.07	1.07
^{227}Fr [$1/2^+$]	1.50	1.50	^{231}Pa [$3/2^-$]	2.01	2.0
^{209}Ra [$5/2^-$]	0.865	0.865	^{233}Pa [$3/2^-$]	4.0	4.0
^{211}Ra [$5/2^-$]	0.878	0.878	^{233}U [$5/2^+$]	-0.59	-0.59
^{213}Ra [$1/2^-$]	0.613	0.613	^{235}U [$7/2^-$]	-0.38	-0.38
^{221}Ra [$5/2^-$]	-0.180	0.880	^{237}Np [$5/2^+$]	3.14	3.14
^{223}Ra [$3/2^+$]	0.271	0.271	^{239}Pu [$1/2^+$]	0.203	0.2
^{225}Ra [$1/2^-$]	-0.7338	-0.733	^{241}Pu [$5/2^+$]	-0.683	-0.68
^{227}Ra [$3/2^+$]	-0.404	-0.404	^{241}Am [$5/2^-$]	1.58	1.58
^{229}Ra [$5/2^+$]	0.503	0.503	^{243}Am [$5/2^-$]	1.503	1.503
^{231}Ra [$5/2^+$]	0.4992	0.499	^{243}Cm [$5/2^+$]	0.40	0.40
^{213}Ac [$9/2^-$]	4.2	4.2	^{245}Cm [$7/2^+$]	0.5	0.50
^{215}Ac [$9/2^-$]	4.14	4.14	^{247}Cm [$9/2^-$]	0.36	0.56
^{217}Ac [$9/2^-$]	3.83	4.03	^{249}Bk [$7/2^+$]	2.0	2.0
^{227}Ac [$3/2^-$]	1.1	1.1	^{253}Es [$7/2^+$]	4.10	4.10
^{229}Th [$5/2^+$]	0.46	0.46	^{253}No [$9/2^-$]	-0.53	-0.53

ÖZGEÇMİŞ

Ad-Soyad : Bürce ÖZTÜRK

ÖĞRENİM DURUMU:

- **Lisans** : 2021, Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği
- **Yüksek lisans** : 2023, Sakarya Üniversitesi , Biyomedikal Mühendisliği Anabilim Dalı, Tezli

TEZDEN TÜRETİLEN ESERLER:

- Öztürk, B., Yakut,H., Kemah,E. (2023, 8-10, Mayıs). Magnetic Moment Inference and Modeling of $^{53-81}\text{Cu}$ Nuclei with Anfis, *International Congress – Nuclear Structure Properties (NSP)*, Karabük, Turkey. (Sunum)
- Öztürk, B., Yakut,H., Kemah,E. (2023). Magnetic Moment Inference and Modeling of $^{53-81}\text{Cu}$ Nuclei with Anfis, *International Congress – Nuclear Structure Properties (NSP)*, Karabük, Turkey. (Tam Metin)
- Öztürk,B.,Kemah,E.,Yakut,H.,Tabar,E.,Hoşgör,G. (2023) Inference and Visualization of Nuclear Magnetic Moment Studies with Neuro-Fuzzy Systems, *Physica Scripta*, PHYSSCR-121730. (Yayına Hazırlanıyor)