

## Modül Yapay Sinir Ağları ile Doğrusal Olmayan Sistemlerin Denetimi

Şerafettin BALOĞLU<sup>1\*</sup>, Muammer GÖKBULUT<sup>2</sup>

<sup>1</sup> Seydişehir İlçe Milli Eğitim Müdürlüğü, Seydişehir/Konya, Türkiye

<sup>2</sup> Elektrik-Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

\*<sup>1</sup> serefbal@gmail.com, <sup>2</sup> mgokbulut@firat.edu.tr

(Geliş/Received: 29/04/2023;

Kabul/Accepted: 06/07/2023)

**Öz:** Yapay sinir ağı (YSA) tarafından gerçekleştirilen hesaplama, birbiriyle iletişim kurmadan girdi uzayı üzerinde çalışan iki veya daha fazla modüle (alt sistemler) ayrıştırılabilirse, sinir ağı modüllerdir (MYSA). Modülerlik, karmaşık bir hesaplama görevini daha basit görevlere bölerek girdi uzayının farklı bölgelerini öğrenip uzmanlaşma eğilimindeki modüllerin bireysel çözümlerini birleştirme yaparak çözüme izin veren böl ve fethet ilkesinin bir tezahürüdür. Bu çalışmada, doğrusal olmayan iki sistemin MYSA ile modellenmesi ve denetim başarıları incelenerek elde edilen sonuçlar YSA ile karşılaştırılmıştır. Sistemlerin modelleme ve denetiminde yapılan karşılaştırma sonuçlarına bakıldığında MYSA performansının YSA' ya göre iyi olduğu tespit edilmiştir.

**Anahtar kelimeler:** Modül yapay sinir ağları, doğrusal olmayan sistemler, modelleme ve denetim.

### Modular Neural Network Control of Nonlinear Systems

**Abstract:** A neural network is modular (MNN) if the computation performed by an artificial neural network (ANN) can be decomposed into two or more modules (subsystems) operating on the input space without communicating with each other. Modularity is a manifestation of the divide-and-conquer principle, which allows a solution by dividing a complex computational task into simpler tasks, combining individual solutions of modules that tend to learn and specialize in different regions of the input space. In this study, the modeling of two nonlinear systems with MCA and the audit successes were examined and the results obtained were compared with ANN. When the comparison results made in the modeling and inspection of the systems are examined, it has been determined that the MYSA performance is better than the ANN.

**Key words:** Module neural networks, nonlinear systems, modeling and control.

### 1. Giriş

YSA, makine öğrenmesinde yaygın kullanıma sahip model olup temeli 1940'lı yıllara dayanmaktadır. YSA hakkında geçmişte birçok çalışma yapılmış ve son yıllarda popüler olan derin öğrenme çalışmalarının da temelini oluşturmuştur [1]. İnsan beyninin çalışma prensibini modellemeyi amaçlayan YSA günümüzde, sistem tanılama ve denetimi, güdümlü önleme, nesne tanıma, sinyal işleme, otomobiller için otomatik pilot tasarımı gibi tıp, mühendislik başta olmak üzere pek çok multidisipliner alanda kullanılmaktadır.

1950'lerin başlarında YSA sorgulanmaya başlanmış ve hayata geçmesi on yıllar sürmüştür. İlk başlarda YSA'nın nasıl eğitileceği büyük bir sorun olmuş, birçok bilim insanının birbirinden bağımsız olarak geri yayılım olarak adlandırılan "gratiant inişi"ni kullanmasıyla birlikte YSA yeniden keşfedilmiştir. 1989 yılında Bell Labs' dan Yan LeCun'un sonradan LeNet adı verilen evrimsel sinir ağları ile geri yayılım algoritmasını birleştirip el ile yazılmış rakamları tanımada kullanılması, YSA' nda ilk başarılı uygulama olmuştur [2].

İnvaziv mekanik ventilasyonun yönetimi ve ventilasyon sırasında sedasyon ve analjezinin düzenlenmesi yoğun bakıma başvuran hastaların bakımının önemli bir bölümünü oluşturur. Hem mekanik ventilasyona uzun süreli bağımlılık hem de erken ekstübasyon, artan komplikasyon riski ve daha yüksek hastane maliyetleri ile ilişkilidir, ancak hastaları ventilatörden ayırmanın en iyi protokölüne ilişkin klinik görüş değişikliği gösterir. YSA, ekstübasyon hazır olma süresini tahmin etmek ve kişiselleştirilmiş bir sedasyon dozu ve ventilatör desteği rejimi önermek için mevcut hasta bilgilerinden (geçmiş yoğun bakım ünitesi verileri) hareketle bir karar destek aracı olarak kullanılabilir [3]. Akut akciğer hasarının ventilasyon tedavisi, akciğer çökmesini önlemek için ekspirasyon sonunda pozitif hava yolu basıncının (PEEP) uygulanmasını gerektirmektedir. Ancak alveol duvarlarına uygulanan toplam basınç, pozitif hava yolu basıncı ile gizli bileşen olan intrinsik PEEP'in (PEEPi) toplamıdır. Alveol duvarlarına uygulanan toplam basıncı ölçmek için ventilasyon, ekspirasyon sonu tutma

\* Sorumlu yazar: [serefbal@gmail.com](mailto:serefbal@gmail.com). Yazarların ORCID Numarası: <sup>1</sup> 0000-0002-6541-4023, <sup>2</sup> 0000-0003-1870-1772

manevrası ile kesilmelidir. YSA'nın devam eden mekanik ventilasyon sırasında akış ve basınç izlerinden toplam basınç tahmini araştırılmış ve YSA'nın toplam basıncı dinamik koşullar altında farklı seviyelerinde tahmin ederek ventilatör tedavisi gerektiren kritik hastalarda PEEPi'nin izlenmesinde yeni yaklaşımlar ortaya koymuştur [4]. Beyin tümörü sınıflandırması, tümör bölgesi alanlarında iyi huylu (belign) ve kötü huylu (malign) tümör sınıflandırması yapmayı amaçlar ve görüntü işlemede oldukça zorlu bir süreçtir. MRI görüntüleri Neutrosophy ve Convolutional Neural Network (NS-CNN) kullanan hibrit bir yöntemle sınıflandırılmıştır. Bulgular, CNN özneliklerinin farklı sınıflandırıcılarla yüksek bir sınıflandırma performansı sergilediğini göstermiştir [5].

Doğrusal olmayan sistemleri kontrol etmek amacıyla doğrusal olmayan kontrol problemleriyle başa çıkmak için YSA ve bulanık mantık sistemleri (FLS) son zamanlarda yaygın olarak incelenmektedir. Doğrusal olmayan kontrol problemlerinin çözümünde uyarlanabilir ve buluşsal bir yol olan YSA derin bir etkiye sahiptir. Özellikle, sistem parametreleri bozulduğunda veya matematiksel model tanımlanamadığında, sistem performansının sağlamak için parametrelerin ayarlanması, optimize edilmesi gerekir [6]. YSA, öğrenme üzerine odaklanmış ve doğrusal olmayan sistemlerde, sisteme ait bilginin eksik veya hatalı olduğu sistemler için uygundur. YSA'ların en önemli dezavantajı ise var olan uzman bilgisinin problem çözümüne aktarılmasındaki zorluktur [7].

Sistem dinamiklerine göre en iyi kararların alınması, otomatik olarak kontrol edilen sistemlerde yüksek düzeyde özerklik sağlar [8-11]. Günlük yaşamda karşılaşılan çoğu fiziksel sistemlerde çeşitli biçimlerde model parametre hataları ve belirsizlikler vardır [12-15]. Bilinmeyen bu dinamikler ciddi performans düşüşüne ve diğer sorunlara neden olabilmektedir [16].

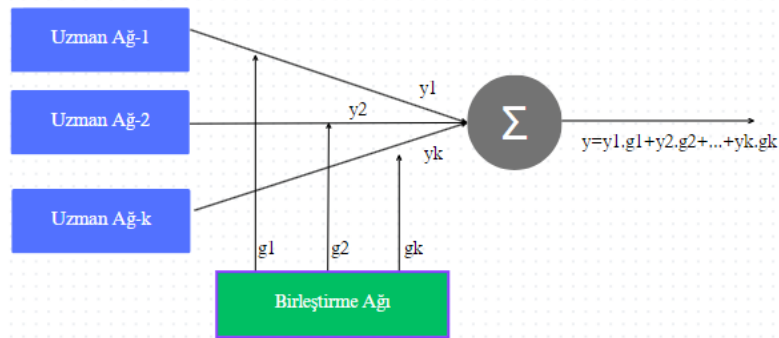
Gelişen modüler yapay sinir ağı (MYSA), doğrusal olmayan sistemlerin karmaşıklığını etkili bir şekilde azaltabilir. MYSA tasarımı, nörobiyolojiden esinlenmiştir. Omurgalı canlıya ait beyin organizasyonunu ve işlevini simüle eder. MYSA, "böl ve fetet" taktiğini kullanır. MYSA'nın büyük ölçekli bir sorunu daha küçük ve daha basit alt probleme böldüğü ve öğrenmek için bağımsız ve basit "uzman sistem" ile bir veya daha fazla alt ağ modülü atadığı anlamına gelir [17].

İnsan beyni incelendiğinde, gerçekleştirilecek işlevin beyin farklı alanlarında meydana gelen birtakım değerlendirmeler bütünü olduğu anlaşılmıştır. İnsan beyinin occipital lobunda hayal ve düş, periate lobunda duygusal, temporal lobunda işitsel ve görsel, frontal lobunda hareket planlaması gibi fonksiyonların gerçekleştiği saptanmıştır. Beynin her lobunda meydana gelen bu olaylar birleştirilerek insan tepkisi oluşturulmaktadır [18, 19]. Beynin bu çalışmasından hareketle MYSA geliştirilmiştir.

Günümüzde MYSA, çok sınıflı sınıflandırma problemleri için basit ama etkili çözümler sunarken, AlexNet ve ResNet gibi daha karmaşık derin sinir ağlarına göre parametre sayısını önemli ölçüde azaltmaktadır [20].

## 2. Materyal ve Yöntem

Genel olarak MYSA, birbirinden bağımsız olarak çalışan iki ya da daha fazla YSA yapısının birleşmesinden oluşur [17]. Modüllerin veya uzman ağların çıkışları, geri besleme olmaksızın birleştirici (geçit) ağ ile birleştirilir. Şekil 1' de gösterildiği gibi, MYSA blok şeması verilmiştir.



Şekil 1. MYSA yapısı

Birleşirme ağının iki görevi vardır;

- Modül çıkışlarının nasıl birleştirileceğine karar vererek, MYSA çıkışını belirler,
- Her bir modül için en uygun eğitim şeklini belirler.

## 2.1. Birleşmeli gauss karışımı modeli

Şekil 1’ de verilen MYSA’da, uzman ağ adı verilen K adet denetlenmiş modülden ve birleştirme ağı adı verilen ve uzman ağlar arasında birleştirme görevi yapan bir üniteden oluşur. Eğitim örnekleri p boyutlu x giriş vektörü ile, arzu edilen davranış q boyutlu d vektörü ile gösterilmek üzere, giriş vektörü x, uzman ağa ve birleştirme ağına eş zamanlı olarak uygulanır [21, 22].  $y_i$ ,  $i$ . uzman ağın çıkış vektörünü,  $g_i$  birleştirme ağın aktivasyon fonksiyonunu ve y tüm modüler ağın çıkış vektörünü göstermek üzere Denklem 1’ deki ifade bulunur.

$$y = \sum_{j=1}^K g_j y_j \quad (1)$$

MYSA’ nın eğitiminde, uzman ağlar ve birleştirme ağı eşzamanlı olarak eğitilir [21, 22]. Eş zamanlı eğitimde aşağıdaki öğrenme algoritması kullanılır.

- Rasgele belirlenmiş bir x giriş vektörü seçilir,
- x giriş vektörünün  $i$ . uzman ağ olasılığı  $P(i|x)$  kullanılarak, bir uzman ağ seçilir,
- Arzu edilen d davranış vektörü, geri yayılım sonunda  $i$ . kural olarak oluşturulur.

Arzu edilen davranışı bildiren d vektörünün çoklu rastlantısal değişkenli Gauss dağılımı, x giriş vektörü ve  $i$ . uzman ağın seçilmesi halinde Denklem 2’deki gibi bulunur.

$$\begin{aligned} f(d|x, i) &= \frac{1}{(2\pi \det \Lambda_i)^{q/2}} e^{\left(-\frac{1}{2}(d-y_i)^T \Lambda_i^{-1}(d-y_i)\right)} \\ &= \frac{1}{(2\pi)^{q/2}} e^{\left(-\frac{1}{2}(d-y_i)^T (d-y_i)\right)} \\ &= \frac{1}{(2\pi)^{q/2}} e^{\left(-\frac{1}{2}\|d-y_i\|^2\right)}, i = 1, 2, \dots, K \end{aligned} \quad (2)$$

Burada  $\|-\|$ , kapalı vektörün Öklit normunu ifade eder. Denklem 2’deki çoklu rastlantısal değişkenli dağılım, şarta bağlı olasılık yoğunluk fonksiyonu olarak yazılır. Bunun nedeni ise belli bir x giriş vektörü için,  $i$ . uzman ağın arzu edilen d vektörüne en uygun olanı ürettiği kabul edilir. Bu nedenle, arzu edilen d vektörünün olasılık dağılımı bir karışım modeli olarak Denklem 3’de K adet çoklu rastlantısal değişkenli Gauss dağılımının lineer kombinasyonu şeklinde ele alınır. Denklem 3’deki olasılık dağılımına birleşmeli Gauss karışım modeli denir.

$$\begin{aligned} f(d|x) &= \sum_{i=1}^K g_i f(d|x, i) \\ &= \frac{1}{(2\pi)^{q/2}} \sum_{i=1}^K g_i e^{\left(-\frac{1}{2}\|d-y_i\|^2\right)} \end{aligned} \quad (3)$$

MYSA’da uzman ağların ve birleştirme ağın ağırlıklarını uyarlamak için Denklem 3’de bulunan çoklu rastlantısal değişkenli Gauss dağılımının logaritması alınarak elde edilen log-olasılık fonksiyonu kullanılır. w uzman ağların, g birleştirme ağın ağırlık vektörü olmak üzere  $l(w, g)$  log-olasılık fonksiyonu Denklem 4’deki gibi bulunur.

$$l(w, g) = \ln \sum_{i=1}^K g_i e^{\left(-\frac{1}{2}\|d-y_i\|^2\right)} \quad (4)$$

MYSA’da, uzman ağların değişik şekillerde bağlanmaları mümkünken, birleştirme ağındaki aktivasyon fonksiyonu iki şartı yerine getirmek üzere sınırlandırılmıştır [21, 22];

- Her modülün aktivasyon fonksiyonu 0 ile 1 değeri arasındadır. Bu şart Denklem 5’deki gibi bulunur.

$$0 \leq g_i \leq 1, \quad \forall i \quad (5)$$

- Bütün modüllerin aktivasyon fonksiyonları toplamı 1’ e eşittir.

$$\sum_{i=1}^K g_i = 1 \quad (6)$$

Birleştirme ağındaki  $i$ . çıkış hücresine uygulanan girişlerin ağırlıklı toplamı olan  $u_i$ ' nin verilmesi halinde, Denklem 5 ve 6'daki şartlar dikkate alınarak, birleştirme ağının  $i$ . çıkış hücresine ait  $g_i$  aktivasyon fonksiyonu softmax olarak adlandırılır [21-23] ve Denklem 7'deki gibi bulunur.

$$g_i = \frac{e^{(u_i)}}{\sum_{i=1}^K g_i e^{(u_i)}} \quad \{u_i | i = 1, 2, \dots, K\} \quad (7)$$

## 2.2. Stokastik – eğitim öğrenme algoritması

Stokastik – eğitim öğrenme algoritması, MYSA'daki  $i$ . uzman ağı çıkışı ile ilişkili bir sonraki olasılığı tahmin eder. Bu olasılık Denklem 8'deki gibi bulunur.

$$h_i = \frac{g_i e^{\left(-\frac{1}{2}\|d-y_i\|^2\right)}}{\sum_{j=1}^K g_j e^{\left(-\frac{1}{2}\|d-y_j\|^2\right)}}, \quad i = 1, 2, \dots, K \quad (8)$$

$h_i$ , hem  $x$  giriş vektörü hem de arzu edilen davranışı bildiren  $d$  vektörü şartına bağlıdır.  $g_i$  aktivasyon fonksiyonu gibi,  $h_i$  sonraki olasılık ile temsil edilen öncül olasılıklar da iki şartla sınırlandırılmıştır.

- Her modülün  $h_i$  sonraki olasılığı 0 ile 1 değeri arasındadır. Bu şart Denklem 9'daki gibi bulunur.

$$0 \leq h_i \leq 1, \quad \forall i \quad (9)$$

- Bütün modüllerin  $h_i$  sonraki olasılık toplamları 1'e eşittir.

$$\sum_{i=1}^K h_i = 1 \quad (10)$$

MYSA' da yapılan iki farklı parametre ayarlama işlemi vardır;

- Uzman ağlardaki ağırlıkların yenilenmesi işlemi,
- Birleştirme ağındaki ağırlıkların yenilenmesi işlemidir.


Tüm bu parametre değişiklikleri eş zamanlı olarak Denklem 3'de ifade edilen Gauss karışım modeline dayanan *stokastik- eğitim algoritması* kullanılarak yapılmıştır.

## 2.3. Uzman ağların uyarlanması

Şekil 1' de gösterildiği gibi MYSA' nın logaritmik-olasılık fonksiyonu Denklem 4 ile tanımlanmıştır. Uzman ağı uyarlanması,  $l$  log-olasılık fonksiyonunun  $w$  ağırlık vektörüne göre kısmi eğimi bulunarak yapılmaktadır. Dolayısıyla  $i$ . uzman ağı  $y$  çıkış vektörü ile ilgili olarak bu denklemin diferansiyeli, Denklem 11'deki kısmi türev ile bulunur [1].

$$\frac{\partial l}{\partial y_i} = h_i(d - y_i), \quad i = 1, 2, \dots, K \quad (11)$$

Denklem 11'de,  $y$  çıkış vektörü ile arzu edilen davranışı bildiren  $d$  vektörü arasındaki hatayı minimize etmek için uzman ağı  $i$ . ağırlıkları eğitim süresince uyarlanır. Uyarlama esnasında kullanılan eğitim modeli,  $h_i$  sonraki olasılık ile orantılı olarak,  $i$ . uzman ağı tarafından belirlenir. Uyarlama işlemi basite indirgemek için her bir uzman ağı Şekil 2.a' da gösterildiği gibi lineer olduğu kabul edilmiştir. Şekil 2.b' de gösterildiği gibi sinyal akış şeması,  $i$ . uzman ağı  $m$ . hücresinin  $y_i$  çıkış vektörü,  $w_i^{(m)}$  ağırlık vektörü ile  $x$  giriş vektörünün transpozisinin çarpımıdır ve Denklem 12'deki gibi bulunur. Burada  $T$  kuvveti  $x$  vektörünün tersini gösterir ve ağırlık vektörü  $w_i^{(m)}$   $i$ . uzman ağındaki  $m$ . hücrenin  $w_{i1}^{(m)}, w_{i2}^{(m)}, \dots, w_{ip}^{(m)}$  ağırlıklarından oluşur. Eğitim düşme esasına dayanan geri yayılım algoritması aşağıdaki gibi çıkarılmıştır.



Şekil 2. a) Uzman Ağı Oluşturan Tek Bir Lineer YSA Tabakası, b) Lineer Bir Hücrenin Sinyal- Akış Şeması

$$y_i^{(m)} = x^T w_i^{(m)}, \quad \begin{cases} i = 1, 2, \dots, K \\ m = 1, 2, \dots, q \end{cases} \quad (12)$$

$$\frac{\partial l}{\partial w_i^{(m)}} = \frac{\partial l}{\partial y_i^{(m)}} \frac{\partial y_i^{(m)}}{\partial w_i^{(m)}} \quad (13)$$

$$\frac{\partial y_i^{(m)}}{\partial w_i^{(m)}} = x \quad (14)$$

$$\begin{aligned} \frac{\partial l}{\partial y_i^{(m)}} &= h_i (d^{(m)} - y_i^{(m)}) \\ &= h_i e_i^{(m)} \end{aligned} \quad (15)$$

$$e_i^{(m)} = d^{(m)} - y_i^{(m)} \quad (16)$$

$$\frac{\partial l}{\partial w_i^{(m)}} = h_i e_i^{(m)} x, \quad \begin{cases} i = 1, 2, \dots, K \\ m = 1, 2, \dots, q \end{cases} \quad (17)$$

$w_i^{(m)}$  ağırlık vektörünü yenilemek için  $\Delta w_i^{(m)}$  düzeltme miktarı Denklem 18'deki gibi bulunur.

$$\Delta w_i^{(m)} = \eta h_i e_i^{(m)} x, \quad \begin{cases} i = 1, 2, \dots, K \\ m = 1, 2, \dots, q \end{cases} \quad (18)$$


Burada  $\eta$ , öğrenme oranıdır. n iterasyon sayısını göstermek üzere öğrenme algoritmasının bir sonraki iterasyonunda kullanacağı yenilenmiş  $w_i^{(m)}$  ağırlık vektörü Denklem 19'daki gibi bulunur.

$$\begin{aligned} w_i^{(m)}(n+1) &= w_i^{(m)}(n) + \Delta w_i^{(m)}(n) \\ &= w_i^{(m)}(n) + \eta h_i e_i^{(m)}(n) x, \quad \begin{cases} i = 1, 2, \dots, K \\ m = 1, 2, \dots, q \end{cases} \end{aligned} \quad (19)$$

Modelleme ve denetimi yapılacak sistemlere uygun uzman ağ yapıları seçilmelidir. Bölüm 2.3. de seçilen uzman ağ yapısı, uyarlama işlemini anlaşılır kılmak için lineer bir yapıya sahiptir.

#### 2.4. Birleştirme ağı uyarlanması

Uzman ağların çıkışlarını değerlendirerek MYSA çıkışını belirleyen birleştirme ağ yapısı Şekil 3.a' da gösterilmiştir. Konunun anlaşılır olması için softmax hücreli yapı olarak bilinen birleştirme ağının tek katmanlı çıkış hücrelerinden oluştuğu kabul edilmiştir [20].



Şekil 3. a) Birleştirme Ağında Kullanılan Softmax Hücreleri, b) Bir Softmax Hücresinin Sinyal-Akış Şeması

Şekil 3.a' da gösterildiği gibi birleştirme ağ yapısı, uzman ağ yapısından iki bakımdan farklıdır.

- Birleştirme ağı K adet çıkış hücresine sahipken, her bir uzman ağda q tane çıkış hücresi vardır.
- Birleştirme ağı, Şekil 3.b' de gösterildiği gibi çıkış hücrelerinde aktivasyon fonksiyonu olarak softmax fonksiyonunu kullanır.

Birleştirme ağın uyarlanması, Denklem 20'de düzenlemiş olan  $l$  log-olasılık fonksiyonunun  $a$  ağırlık vektörüne göre doğru eğiminin hesaplanmasına dayanan geri yayılım algoritmasına göre yapılmaktadır.

$$l = \ln \sum_{i=1}^K e^{(u_i)} \cdot e^{\left(-\frac{1}{2}\|d-y_i\|^2\right)} - \ln \sum_{j=1}^K e^{(u_j)} \quad (20)$$

Buna göre birleştirme ağının giriş katmanındaki ağırlıklara uygulanacak düzeltme miktarı  $\Delta a_i$  ve yeni ağırlıklar Denklem 21 ile bulunur.

$$\Delta a_i = \eta(h_i - g_i)x, \quad a_i(n+1) = a_i(n) + \eta(h_i(n) - g_i(n))x \quad (21)$$

### 3. Benzetim Bulguları

Denklem 22 ve 23'te verilen giriş çıkış ilişkisine göre doğrusal olmayan iki sistem için sırasıyla MYSA ile YSA'nın düz ve ters modelleri ile başarıları, doğrudan uyarlamalı ve dolaylı uyarlamalı denetim sonuçları MATLAB programı kullanılarak kıyaslanmış ve paylaşılmıştır. Sistemin düz yön dinamiklerini ( $y(k) = f(y(k-i), u(k-j))$ ) ortaya çıkaracak şekilde sinir ağının modellenmesi ve eğitimi için düz model, sistemin ters yön dinamiklerini ( $u_m(k) = f(y(k-i), u(k-j))$ ) ortaya çıkaracak şekilde sinir ağının modellenmesi ve eğitimi için ters model kullanılmıştır. Hem doğrudan hem de dolaylı uyarlamalı denetimde denetleyici YSA'da ters model kullanılmıştır. Doğrusal olmayan sistemin doğru bir ters modeli elde edilemeyebilir. Bu sorunu ortadan kaldırmak için ise sistemin düz modeli kullanılarak, sistem çıkış hatası düz model üzerinden geriye yayılarak denetleyici sinir ağı eğitilmiştir.

$$y(k) = 0.9y(k-1) + \varphi[u(k)] \quad (22)$$

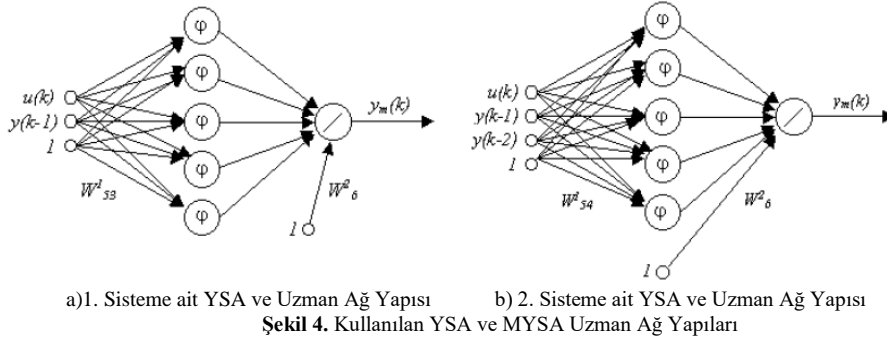
$$y(k) = \frac{1.5y(k-2)y(k-1)}{1+y(k-2)^2+y(k-1)^2} + 0.35 \sin[y(k-2) + y(k-1)] + \varphi[u(k)] \quad (23)$$

Denklemlerde yer alan  $\varphi[u(k)]$  ifadesi Denklem 24'deki gibi tanımlanır.

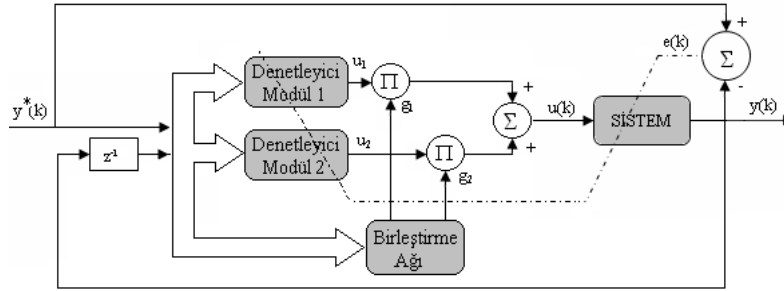
$$\varphi[x] = \begin{cases} 2x & x < 0 \\ \frac{1}{2}x & x \geq 0 \end{cases} \quad (24)$$

Sistemlerin modelleme ve denetiminde, iki uzman ağ ve bir birleştirme ağından oluşan MYSA yapısı seçilmiştir. Her uzman ağ yapısı; sigmoid aktivasyonlu 5 hücreden oluşan tek gizli katman ile tek hücreli doğrusal çıkış katmanından, birleştirme ağı ise softmax aktivasyonlu 2 hücreli çıkış katmanından oluşturulmuştur. Karşılaştırmanın sağlıklı yapılabilmesi için MYSA uzman ağ yapısı ile aynı yapıya sahip YSA yapısı seçilmiştir.

(katmanlardaki hücre sayıları, katman sayıları vb.) ve geri yayılım algoritması kullanılmıştır. Sistemlerde kullanılan YSA yapısı ile MYSA uzman ağ yapısı Şekil 4’te verilmiştir.




Sistemlerin düz ve ters model yapıları oluşturulup sistemlerin denetim yapılarında kullanılmıştır. Şekil 5’ te 1. sistemin denetiminde kullanılan doğrudan uyarlamalı model verilmiştir. Şekil 5’ te görülen denetleyici modüller aslında sistemin ters yön dinamiklerini verecek şekilde eğitilmiş ters MYSA model yapılarıdır.



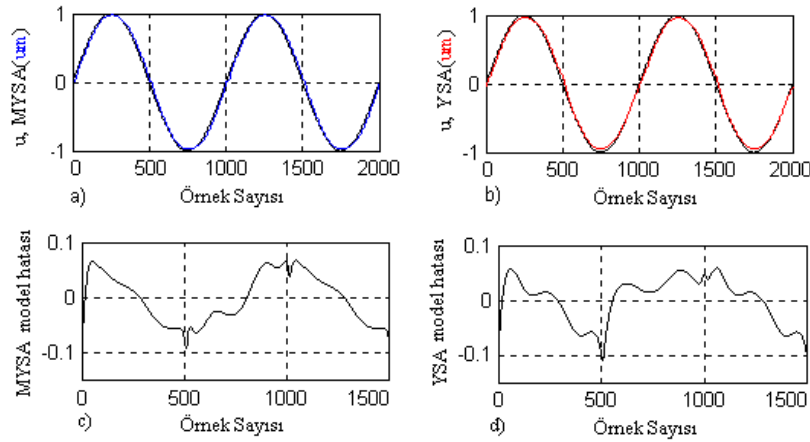
Sistemlerin düz ve ters modelleri, toplu öğrenme algoritması kullanılarak ileri beslemeli MYSA ile, doğrudan ve dolaylı uyarlamalı denetimleri ise örneksel öğrenme algoritması kullanılarak ileri beslemeli MYSA ile yapılmıştır. Bu bölümde, MYSA ile YSA’ nın modelleme ve denetim yapılarından elde edilen eğitim ve genelleme başarıları verilmiştir. Şekil 6’da görülen y sistem çıkışını, MYSA(y\_m) düz model MYSA çıkışını, YSA(y\_m) düz model YSA çıkışını, u referans girişi, MYSA(u\_m) ters model MYSA çıkışını, YSA(u\_m) ters model YSA çıkışını, Modül1- Modül2 düz ve ters model MYSA’ nın uzman ağ çıkışlarını göstermektedir.

Sistemlerin modelleme ve denetiminde kullanılan MYSA ile YSA yapılarında aynı parametre değerleri kullanılarak başarıları karşılaştırılmıştır.



**Şekil 6.** 1. Sistemin Toplu Öğrenme ile Elde Edilen Düz Modelleme Başarısı.

Şekil 6'da, 1. sisteme ait düz MYSA ile düz YSA modellerinin eğitim ve genelleme başarıları verilmiştir. Sistem girişine  $u = \sin(k * 2 * \pi / 1000)$  referans giriş işareti uygulanarak toplu öğrenme yöntemiyle eğitilen MYSA ve YSA ile elde edilen düz model davranışları belirlenmiştir. Sistemin düz yön dinamiklerini ortaya çıkarmak ve eğitim örneklerini sistemin geniş çalışma bölgesinden almak için referans giriş olarak uyarlamalı bir sinüs sinyali seçilmiştir. Sinüs sinyalinin açısal değerini belirleyen k parametresi 0-2000 değerleri arasında değiştirilerek veriler (veri seti) elde edilmiştir. Şekil 6.a ve b' de eğitim sonunda elde edilen düz MYSA model davranışı ile düz YSA model davranışı verilmiştir. MYSA'daki uzman ağların eğitimine toplam modelleme hatasının 0.8 altına düşülünceye kadar devam edilmiştir. Düz MYSA modeli eğitiminde, birleştirme ağına kullanılan alfa öğrenme oranı uzman ağlarda kullanılan alfa öğrenme oranından farklı seçilmesi durumunda düz MYSA model çıkışının sistem çıkışına daha çabuk yakınsadığı ve eğitim sürecinin hızlandığı görülmüştür. Giriş vektörünün farklı bölümlerini öğrenerek uzmanlaşan uzman ağ çıkışları Şekil 6.c'de verilmiştir. Bu çıkışlara birleştirme ağına aktivasyon çıkışları dahil edilerek Şekil 6.a'da gösterilen düz MYSA model davranışı elde edilmiştir. MYSA ile YSA'nın modelleme hataları Şekil 6.d' de verilmiştir. MYSA model hatası, YSA model hatasına göre daha düşük hesaplanmıştır.



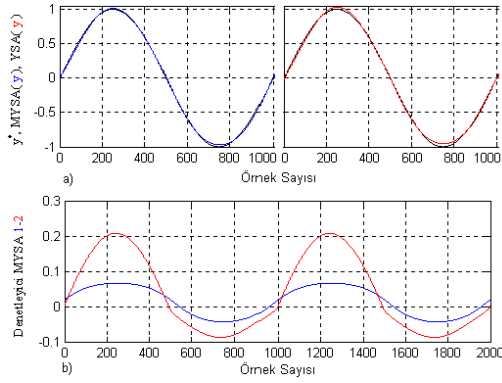
a) Ters MYSA Modeli. b) Ters YSA Modeli. c) Ters MYSA Modelleme Hatası. d) Ters YSA Modelleme Hatası.

Şekil 7. 1. Sistemin Toplu Öğrenme ile Elde Edilen Ters Modelleme Başarısı.


Şekil 7'de 1. sisteme ait toplu öğrenme algoritmasıyla eğitilen MYSA ve YSA ile elde edilen ters modellerin davranışları verilmiştir. Şekil 7.a. ve b'de eğitim sonunda elde edilen ters MYSA, YSA modellerinin davranışları paylaşılmıştır. MYSA'nın modelleme başarıları yaklaşık 5000 iterasyonda sonunda, YSA'nın modelleme başarıları ise yaklaşık 7000 iterasyon sonunda gerçekleşmiştir. İterasyon sayısından da anlaşılacağı üzere MYSA öğrenme süresi YSA'ya göre daha kısa sürmüştür. Ters MYSA'nın modelleme hatası Şekil 7.c' de, ters YSA'nın modelleme hatası ise Şekil 7.d'de verilmiştir. MYSA ters model hatasının YSA'nın hatasına göre daha az olduğu görülmüştür.

Şekil 8'de 1. sistemin MYSA ve YSA ile doğrudan uyarlamalı denetim ile bir referans hızı izleme başarıları verilmiştir. Simülasyon sonuçlarının karışmaması için Şekil 8.a'da gösterildiği gibi MYSA'lı doğrudan uyarlamalı denetim davranışı ile YSA'lı doğrudan uyarlamalı denetim davranışı ayrı ayrı çizdirilmiştir. MYSA ile doğrudan uyarlamalı denetimde uzman ağların sistemin farklı bölümlerini öğrenerek uzmanlaşmış ve denetleyici olarak kullanılan uzman ağlar sistemin ters yön dinamiklerini en iyi şekilde öğrenmişlerdir. Örneksel öğrenme yöntemine göre eğitilen uzman ağların davranışları her eğitim örneğinde iyileşmiş ve sistem çıkışı referans girişine doğru yakınsamıştır. Denetleyici olarak kullanılan uzman ağların denetim sürecindeki davranışları Şekil 8.b'de verilmiştir. Uzman ağ çıkışları birleştirici ağ çıkışlarıyla işleme tabi tutularak sistemin denetim girişi belirlenmiştir.






a) Ref. Giriş, MYSA' lı ve YSA' lı Denetim Çıktıları.  
b) Denetleyici Uzman Ağ Çıktıları.  
**Şekil 8.** 1. Sistemin Doğrudan Uyarlamalı Denetim Başarısı.




a) Ref. Giriş, MYSA' lı ve YSA' lı Denetim Çıktıları.  
b) Denetleyici Uzman Ağ Çıktıları.  
**Şekil 9.** 1. Sistemin Dolaylı Uyarlamalı Denetim Başarısı.

Şekil 9'da 1. sistemin dolaylı uyarlamalı denetim başarısı verilmiştir. Şekil 9.a'da MYSA' lı dolaylı uyarlamalı denetim başarısı ile YSA' lı dolaylı uyarlamalı denetim başarısı paylaşılmıştır. MYSA' lı denetim başarısı YSA' ya göre oldukça iyidir. Bunun nedeni, dolaylı uyarlamalı denetim yapısındaki düz MYSA modelinin sistemin düz yön dinamiklerini en iyi şekilde öğrenmesidir. Denetleyici uzman ağların eğitimi, referans giriş ile sistem çıkışı arasındaki hatanın sistemin düz modeli üzerinden geri yayılım algoritması kullanılarak her ağırlığa göre eğiminin doğru bir şekilde belirlenmesi ve ağırlıkların yenilenmesidir. Düz modelin, sistemin düz yön dinamiklerini doğru olarak tanınması ve denetleyici uzman ağların ağırlıklarının yenilenmesi sonucu sistemin MYSA ile dolaylı uyarlamalı denetim ve genelleme başarısı YSA' ya göre son derece iyidir. MYSA' nın karmaşık bir fonksiyonu daha küçük parçalara ayırarak, her parçayı ayrı ayrı yaklaştırma yeteneği burada YSA yapısına göre bir üstünlüğüdür. Şekil 9.b'de sistemin denetim girişini oluşturan MYSA' daki denetleyici uzman ağların eğitim başarıları çizdirilmiştir. Her uzman ağın davranışı diğerinden bağımsızdır.



a) Referans Giriş, MYSA' lı ve YSA' lı Denetim Çıktıları. b) Denetleyici Uzman Ağ Çıktıları.  
**Şekil 10.** 2. Sistemin Doğrudan Uyarlamalı Denetim Başarısı.

Şekil 10'da 2. sistemin MYSA ve YSA yapıları kullanılarak elde edilmiş doğrudan uyarlamalı denetimin sinüsoydal referans girişi izleme başarısı verilmiştir. Şekil 10.a'da MYSA ve YSA ile elde edilen denetim başarıları ayrı ayrı çizdirilmiştir. Şekil 10.b'de MYSA' da denetleyici uzman ağların davranışları verilmiştir. Her uzman ağ, sistemin denetim girişini belirlemede rol oynamaktadır. Uzman ağların sistem girişine hangi oranda etki edeceğine ise birleştirme ağı karar vermektedir. Denetim sisteminde kullanılan birleştirme ağında softmax aktivasyon fonksiyonu kullanılmıştır. Birleştirme ağına çıkışı uzman ağ sayısına bağlıdır ve bu sayı ikidir.



a) Referans Giriş, MYSA' lı ve YSA' lı Denetim Çıktıları. b) Denetleyici Uzman Ağ Çıktıları.  
Şekil 11. 2. Sistemin Dolaylı Uyarlamalı Denetim Başarısı.

Şekil 11'de aynı sistemin dolaylı uyarlamalı denetim başarısı, Şekil 11.a'da gösterildiği gibi MYSA ile YSA yapıları kullanılarak elde edilen dolaylı uyarlamalı denetimin sinüsoydal referans girişi izleme başarısı verilmiştir. Şekil 11.b'de gösterildiği gibi sinüsoydal referans girişine göre eğitilen MYSA uzman ağlarının davranışları elde edilmiştir. Burada da her uzman ağ, birleştirme ağı belirlediği oranda sistemin denetim girişine etki etmiştir.

#### 4. Tartışma

Günümüzde, doğrusal olmayan sistemler için modelleme çalışmaları halen sürmektedir. Kendi kendini organize edebilen, çözülecek problemin özelliğine göre alt ağ modellerini otomatik ekleyebilen/birleştirebilen MYSA yapıları geliştirilmektedir [17, 20, 23]. Tiny ImageNet, CIFAR-10, MNIST, CIFAR-100, AlexNET, On-Road-Risk gibi veri setleri üzerinde böl ve fethet esasına göre çalışan modüler sinir ağlarının başarılı sonuçlar verdiği kanıtlanmıştır [20, 23]. Bu çalışmada, doğrusal olmayan sistemler için bir adet birleştirme ağı ile iki uzman ağdan oluşan MYSA yapısı önerilmiştir. MYSA'da, birleştirme ağındaki softmax puanına göre seçilen her uzman ağ, problemin bir parçasını öğrendiğinden doğrusal olmayan sistemlerde MYSA'nın öğrenme hızı, modelleme ve denetiminin YSA'ya göre daha başarılı olduğu görülmüştür.

#### 5. Sonuç

Bu çalışmada, giriş çıkış ilişkisine göre lineer olmayan iki sistemin YSA ve MYSA kullanılarak modelleme ve denetim başarıları karşılaştırılmıştır. MYSA sistemin farklı bölümlerini çok daha iyi öğrendiği görülmüştür. Sistemlerin YSA' lı modelleme ve denetim başarıları da ayrıca incelenerek MYSA modelleme ve denetim başarıları ile birlikte verilmiştir. Karşılaştırmanın sağlıklı yapılabilmesi için YSA ve MYSA yapıları, katmanlardaki hücre sayıları, katman sayıları, öğrenme oranları vb. aynı seçilmiştir. Lineer olmayan sistemlerin kontrolünde, böl ve fethet esasına göre çalışan MYSA'nın YSA'na göre başarılı olduğu görülmüştür.

#### Kaynaklar

- [1] Uğuz, S., Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zeka Ekolü. 2 ed. 2021: Nobel Akademik Yayıncılık. 300.
- [2] Chollet, F., Python ile Derin Öğrenme. 1. Baskı ed. Buzdağı Yayınevi, Ankara. 2019.
- [3] Prasad, N., et al., A reinforcement learning approach to weaning of mechanical ventilation in intensive care units. arXiv preprint arXiv:1704.06300, 2017.
- [4] Perchiuzzi, G., et al., Monitoring of total positive end-expiratory pressure during mechanical ventilation by artificial neural networks. Journal of clinical monitoring and computing, 2017. 31: p. 551-559.
- [5] Özyurt, F., et al., Brain tumor detection based on Convolutional Neural Network with neutrosophic expert maximum fuzzy sure entropy. Measurement, 2019. 147: p. 106830.
- [6] Liu, Y.-J., et al., Adaptive neural network control for a class of nonlinear systems with function constraints on states. IEEE Transactions on Neural Networks and Learning Systems, 2021.
- [7] Kubat, P.D.C., Matlab Yapay Zeka ve Mühendislik Uygulamaları. 2019: Abaküs.

- [8] Izzo, D., M. Märten, and B. Pan, A survey on artificial intelligence trends in spacecraft guidance dynamics and control. *Astrodynamics*, 2019. 3: p. 287-299.
- [9] Kamalapurkar, R., et al., Reinforcement learning for optimal feedback control. 2018: Springer.
- [10] Wen, T., et al., Hop reachable domain on irregularly shaped asteroids. *Journal of Guidance, Control, and Dynamics*, 2020. 43(7): p. 1269-1283.
- [11] Yin, S., J. Li, and L. Cheng, Low-thrust spacecraft trajectory optimization via a DNN-based method. *Advances in Space Research*, 2020. 66(7): p. 1635-1646.
- [12] Cheng, L., et al., Fast solution continuation of time-optimal asteroid landing trajectories using deep neural networks. *Acta Astronautica*, 2020. 167: p. 63-72.
- [13] Huang, Y., S. Li, and J. Sun, Mars entry fault-tolerant control via neural network and structure adaptive model inversion. *Advances in Space Research*, 2019. 63(1): p. 557-571.
- [14] Yang, T., et al., Neural network-based adaptive anti-swing control of an underactuated ship-mounted crane with roll motions and input dead zones. *IEEE Transactions on Neural Networks and Learning Systems*, 2019. 31(3): p. 901-914.
- [15] Zhou, N., Y. Kawano, and M. Cao, Neural network-based adaptive control for spacecraft under actuator failures and input saturations. *IEEE transactions on neural networks and learning systems*, 2019. 31(9): p. 3696-3710.
- [16] He, D., Z. Liu, and Y. Jiang, An intuitive model for on-axis pulse evolution of ultrashort pulsed Gaussian beams diffracted from a circular aperture. *Journal of Modern Optics*, 2015. 62(8): p. 620-625.
- [17] Qiao, J., X. Guo, and W. Li, An online self-organizing modular neural network for nonlinear system modeling. *Applied Soft Computing*, 2020. 97: p. 106777.
- [18] Aytaş, G., Sözlü çeviri eğitiminde bilişsel incelemeler: SAÜ çeviribilim bölümü hazırlık, 2. ve 4. sınıflar örneği, in *Sosyal Bilimler Enstitüsü, Ph.D. 2019, Sakarya Üniversitesi*.
- [19] Baloğlu, Ş., Modül yapay sinir ağları ile doğrusal olmayan sistemlerin denetimi, *Fen Bilimleri Enstitüsü. 2003, Fırat Üniversitesi*.
- [20] Intisar, C.M. and Q. Zhao. A selective modular neural network framework. 2019 IEEE 10th International Conference on Awareness Science and Technology (iCAST). 2019. IEEE.
- [21] Ma, J., et al., Feature guided Gaussian mixture model with semi-supervised EM and local geometric constraint for retinal image registration. *Information Sciences*, 2017. 417: p. 128-142.
- [22] Khanmohammadi, S. and C.-A. Chou, A Gaussian mixture model based discretization algorithm for associative classification of medical data. *Expert Systems with Applications*, 2016. 58: p. 119-129.
- [23] Chowdhury, M.I., et al., CMNN: Coupled modular neural network. *IEEE Access*, 2021. 9: p. 93871-93891.