

# The Effect on Modelling Performance of Different Activation Functions for Feed Forward and Feedback Network Structures in Modeling of Chen Chaotic System

Murat Alcin (Corresponding author)  
E-mail: murat81alcin@gmail.com

## Abstract

Activation functions is an important parameter that affects the performance of the network in the process of training of Artificial Neural Network (ANN) structures. This paper presents the modelling of Aizawa Chaotic System (ACS) using the structures of Feed Forward Neural Network (NN) and Feedback NN. Runge Kutta 5 Butcher (RK-5-B) algorithm has been used for the numeric solution describing ACS. Nonlinear activation functions like Radial Basis (RadBas), Logarithmic Sigmoid (LogSig) and Tangent Sigmoid (TanSig) have been used in the modelling process and the analysis study has been performed related to the modelling performance of ACS by using these functions in the created network structures. It has been observed that the TanSig activation function which is one of the activation functions used in the modelling with FFNN structure has produced more sensitive results than others and the LogSig activation function which is one of the activation functions used in the modelling with RNN structure. has produced more sensitive results than others.

**Keywords:** Artificial Neural Network, Chaotic System, Modelling, Feed Forward Neural Network, Feedback Neural Network, LogSig, TanSig, RadBas.

## Chen Kaotik Sisteminin Modellenmesinde İleri ve Geri Beslemeli Ağ Yapıları İçin Farklı Aktivasyon Fonksiyonlarının Modelleme Performansına Etkisi

### Özet

Aktivasyon fonksiyonları Yapay Sinir Ağı (YSA) yapılarının eğitimi sürecinde ağın performansına doğrudan etki eden önemli bir parametredir. Bu çalışmada, Aizawa Kaotik Sistemi (AKS), İleri Beslemeli YSA (İBYSA) ve Geri Beslemeli YSA (GBYSA) yapıları kullanılarak modellenmiştir. AKS'yi tanımlayan denklemlerin nümerik çözümü için, Runge Kutta 5 Butcher (RK-5-B) algoritması kullanılmıştır. Modelleme sürecinde Radial Basis (RadBas), Logarithmic Sigmoid (LogSig) ve Tangent Sigmoid (TanSig) gibi doğrusal olmayan aktivasyon fonksiyonları kullanılmış ve bu fonksiyonlar oluşturulan ağ yapılarında kullanılarak AKS'nin modellenme performansı ile ilgili analiz çalışması yapılmıştır. AKS'nin, İBYSA yapısı ile modellenmesinde kullanılan aktivasyon fonksiyonlarından TanSig aktivasyon fonksiyonunun; GBYSA yapısı ile modellenmesinde kullanılan aktivasyon fonksiyonlarından LogSig aktivasyon fonksiyonunun daha hassas sonuçlar ürettiği görülmüştür.

**Anahtar kelimeler:** Yapay Sinir Ağları, Kaotik Sistem, Modelleme, İleri Beslemeli YSA, Geri Beslemeli YSA, LogSig, TanSig, RadBas.

## 1. Giriş

Kaos teorisi, bilim ve mühendislik alanlarında bir çok önemli uygulamaya sahiptir. Kaos teorisinin, bilgisayar bilimi, mühendislik, fizik, biyoloji, meteoroloji, sosyoloji ve ekonomi gibi değişik alanlarda uygulamaları mevcuttur (Bahi, Couchot, Gueux, & Salomon, 2016; Lamamra, Vaidyanathan, Azar, & Salah, 2017; Vaidyanathan & Azar, 2016; Vaidyanathan, Azar, & Ouannas, 2017; Vaidyanathan & Volos, 2016).

Kaotik sistemler, başlangıç koşullarına hassas olan, doğrusal olmayan dinamik sistemler olarak tanımlanırlar. Kaotik sistemlerin başlangıç koşullarına hassasiyeti, bir çok insan tarafından Kelebek Etkisi olarak bilinmektedir. Bir başlangıç durumundaki ufak bir değişim, gelecek durumlarda sistem davranışında çok büyük farklılıklar oluşturacaktır. Kaotik sistemlerin davranışı kaotik matematiksel modeller ile çalışılabilmektedir (Lamamra et al., 2017; Vaidyanathan & Azar, 2016).

Yapay Zeka (YZ), akıllı makinelerin gelişimine katkı veren bilgisayar biliminin bir dalıdır. YZ, medikal teşhis, stok ticareti, robot kontrolü gibi değişik alanlarda yoğun uygulamalara sahip bulunur (Alves, Tavares da Costa Jr, Lopes, da Rocha, & de Sá, 2017; Bahi et al., 2016; Chen & Kuo, 2017; Doucoure, Agbossou, & Cardenas, 2016; ErKaymaz & Ozer, 2016; Gautam & Giri, 2016; Johansson & Nafar, 2017). YZ'nin önemli bir alanı Yapay Sinir Ağları (YSA)'dır. YSA, insan beyninin çalışması ile motive edilmiş birbiri ile bağlantılı bir yapay nöron grubundan oluşan matematiksel bir modeldir. Beyin, çevresine olan uyumu ve tecrübesi ile öğrenir. Ayrıca nöronlar arası bağlantı gücü olan ağırlıklar elde edilen bilginin saklanması amacıyla kullanılmaktadır. YSA, girişler ve çıkışlar arasındaki değişik ilişkiyi modellemek için kullanılan, doğrusal olmayan, paralel, adaptif bir sistemdir. Bir ünitenin çıkışı giriş/çıkış karakteristikleri ile belirlenirken, baştan başa çalışan YSA'nın ise sahip olduğu yapı ve eğitim algoritması ile belirlenir (Khelifa & Boukabou, 2016; Koyuncu, 2016; Mishra & Mishra, 2017; Tlelo-Cuautle, de Jesús Rangel-Magdaleno, & de la Fraga, 2016).

YSA'nın kullanım alanı, farklı ortamlara uyum yeteneği ve bu duruma bağlı olarak davranışını değiştirmesi gibi avantajlarından dolayı oldukça geniştir. Bununla birlikte, YSA hem doğrusal hem de doğrusal olmayan dinamik sistemleri kontrol etmek ve modellemek için kullanılmaktadır (Alves et al., 2017; Doucoure et al., 2016; ErKaymaz & Ozer, 2016; Gautam & Giri, 2016; Lamamra et al., 2017).

YSA ile ilgili araştırmalar, uygun bir ağ yapısına önem vermektedir, yani nöronların nasıl bağlı olacağı, bağlantı ağırlıklarını nasıl ayarlayıp, nasıl hesaplanacağı ve YSA'nın diğer parametrelerinin nasıl bulunacağına yönelik çalışmalar artarak devam etmektedir (Chen & Kuo, 2017; Johansson & Nafar, 2017; Loussifi, Nouri, & Braiek, 2016; Mostafa & El-Masry, 2016; Panapakidis & Dagoumas, 2016).

## 2. Yapay Sinir Ağları (YSA):

YSA, bir giriş katmanı, bir çıkış katmanı ve bir veya birden fazla gizli katmanlar içeren, birbiri ile bağlantılı olan nöronların çoklu katmanlarda düzenlendiği bir ağıdır (Khazaei, Sadat-Hosseini, Marjaninejad, & Daneshvar, 2017; Zhang, 2017b). YSA, doğrusal olmayan sistemlerin kontrolü, durum tahmini ve modellemesi ile ilgili var olan yeteneklerinden dolayı mühendislik alanı için kullanışlı bir araç haline gelmiştir (Bahi et al., 2016; Khelifa & Boukabou, 2016; Kumar & Saini, 2016; Loussifi et al., 2016; Sanchez, Rodriguez-Castellanos, Chen, & Ruiz-Cruz, 2017; Tlelo-Cuautle et al., 2016; Vaidyanathan & Volos, 2016).

Literatürde yüzlerce YSA yapısı bulunmaktadır. Bununla birlikte, en geniş çapta kullanılan YSA Çok Katmanlı Algılayıcılar (ÇKA)'dır. ÇKA, giriş katmanını oluşturan duysal birimlerden, işlem ünitelerini (algılayıcılar) içeren bir veya daha fazla gizli katmanlardan ve çıkış katmanlarından oluşmaktadır (Bahi et al., 2016; Koyuncu, 2016; Mostafa & El-Masry, 2016).

YSA, nöron adı verilen belli sayıda birbiriyle bağlantılı işlem elemanlarını içermektedir. Nöronların birbirleriyle olan bağlantı şekli YSA'nın yapısını belirlemektedir (Sanchez et al., 2017; Tlelo-Cuautle et al., 2016). Genel olarak uygulamada en sık kullanılan YSA yapıları, İleri Beslemeli YSA (İBYSA) ve Geri Beslemeli YSA (GBYSA)'dır. İBYSA, tipik olarak, ağı her katmanındaki nöronlar kendi girişlerini yalnızca kendinden önceki katmanın çıkış sinyallerinden alır. Sinyaller ileri yönde akarlar (Alçın, 2017). GBYSA ise en az bir adet geri besleme döngüsüne sahip olduğu için kendini İBYSA'dan ayırır. Geri besleme döngülerinin varlığının ağı öğrenme yeteneği ve performansı üzerinde yoğun bir etkisi vardır (Alçın, 2017). Geri Beslemeli YSA (GBYSA)'da, bir nöronun çıkışı aynı nöronun veya

kendinden önceki katmanda yer alan bazı nöronların geri beslemesidir. Sinyaller ileri ve geri yönde akarlar (Sanchez et al., 2017).

### 2.1 Bir yapay nöronun iç yapısı:

Bir yapay nöronun iç yapısı üç fonksiyon ve bu fonksiyonların ağırlık davranışını etkileyen özelliklerinden oluşmaktadır. Bunlardan ilki tipik formu Eşitlik 1’de (Moldes, Mejuto, Rial-Otero, & Simal-Gandara, 2017) görüleceği gibi yayılım kuralıdır.

$$P_i(t) = \sum w_{ji} \cdot x_j + b \quad (1)$$


Burada  $w_{ij}$ ,  $i$  ve  $j$  nöronları arasındaki bağlantının ağırlığını temsil etmektedir;  $x_j$ ,  $j$  nöronu öncesindeki giriştir;  $b$  ise eşik değeridir. Bu kural nörona giren giriş sinyallerinin ağırlıklandırılmış toplamını gerçekleştirir ve toplar. Ağırlıklar bu durumda, belirli bir an için her tek girişin yoğunluğunu temsil etmektedir. Sonrasında bunun çıkışı Eşitlik 2’de (Moldes et al., 2017) gösterilen ve ikinci fonksiyon olan transfer veya aktivasyon fonksiyonu ile işlem görür.

$$A_i(t) = f_i(P(t)) \quad (2)$$

Sonucu fonksiyon ise Eşitlik 3’te (Moldes et al., 2017) gösterildiği gib, aktivasyon sinyalini alan ve nöronun son çıkış değerini üreten bundan dolayı genellikle aktivasyon değerinin bir kimliği olan çıkış fonksiyonudur (Bahi et al., 2016; Gautam & Giri, 2016; Moldes et al., 2017; Tlelo-Cuautle et al., 2016).

$$Y_i(t) = A_i(t) = f_i(P(t)) \quad (3)$$

Şekil 1, daha iyi kavranması için bir nöron modelini resmetmektedir (Moldes et al., 2017).



Şekil 1. Bir yapay nöronun şekli [24].

Şekil 1’den de görüleceği gibi diğer nöronlardan veya ağırlıklar dışından gelen  $x$  girişleri, yayılım kuralı olan  $P$ ’ye göre kendine özgü ağırlıkları ile ve birbirleriyle ve  $b$  eşik değeriyle toplanır. Aktivasyon fonksiyonu olan  $A$  kurulur ve toplam değer aktivasyon fonksiyonuna göre hesaplanır. Çıkış sinyali  $Y$ , giriş değerlerinin doğrusal kombinasyonu olan çıkış fonksiyonu ile üretilir (Moldes et al., 2017).

Aktivasyon fonksiyonu, biyolojik nöronun diğer nöronlardan farklı girişleri aldığı gibi biyolojik nörona benzer şekilde çalışır. Bir düğüm bir önceki katmandan çok sayıda düğüme bağlı olduğu gibi aynı şekilde bir sonraki katmandan çok sayıda düğüme bağlıdır. Çalışırken bir önceki katmanda yer alan düğümlerden gelen sinyaller elde edilir ve aktivasyon fonksiyonu ile işlenir. Bu işlem bu sinyallerin ilgili ağırlıkları ile yapılır. Sonrasında eğer yayılım kuralına göre tüm toplam kümesi, nöronu tetikleyecek kadar güçlü ise aktivasyon fonksiyonu, çıkış fonksiyonu tarafından kontrol edilen ağırlık bir sonraki katmanına sinyali iletir. Burada üretilen değer diğer nörona giriş olarak birleştirilmiştir ve bu yolla nöronlar giriş katmanından çıkışa kadar birbirleriyle bağlantılıdır (Bahi et al., 2016; Gautam & Giri, 2016; Koyuncu, 2016; Moldes et al., 2017).

Ağırlıklar, diğer nöronlara göre belirli bir nöronun sinyalin ilgili gücünü kabul ettirdikleri için bağlantıda önemli bir role sahiptir. Ağırlık farklı ağırlıkları ile farklı sonuçlar üretilecektir. Bundan dolayı uygun YSA’nın tasarımı ağırlıklar için uygun değerlerin bulunması anlamına gelir. Öğrenme işlemi bu eğitim süreci ile başarılı olur (Bahi et al., 2016; Gautam & Giri, 2016; Koyuncu, 2016; Moldes et al., 2017).


YSA'da kullanılan birkaç aktivasyon fonksiyonu bulunmaktadır. YSA model tasarımında gizli katmanlar için LogSig, TanSig ve RadBas aktivasyon fonksiyonları kullanılmıştır (Alves et al., 2017; Khazaei et al., 2017; Kumar & Saini, 2016). LogSig, TanSig ve RadBas aktivasyon fonksiyonları sırasıyla Eşitlik 4, 5 ve 6'da verilmektedir (Zhang, 2017a).

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (4)$$

$$f(x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}} = \frac{2}{1 + e^{-\beta x}} - 1 \quad (5)$$

$$f(x) = \frac{1}{e^{n^2}} \quad (6)$$

Burada  $\beta$ , LogSig ve TanSig Aktivasyon fonksiyonlarının eğimini temsil etmektedir. LogSig, TanSig ve RadBas aktivasyon fonksiyonları Şekil 2'de gösterilmektedir.



Şekil 2. LogSig, TanSig ve RadBas aktivasyon fonksiyonları.

LogSig Aktivasyon fonksiyonunun çıkışı, eğim  $+\infty$  yönünde arttırıldığı zaman ( $\beta \rightarrow \infty$ ), LogSig Aktivasyon fonksiyonunun çıkışları eşik aktivasyon fonksiyonuna ulaşır.  $\beta=0$  olduğunda çıkışlar yatay bir doğru olur (x eksenini) (Zhang, 2017a).

LogSig Aktivasyon fonksiyonu,  $(-\infty, +\infty)$  aralığındaki sonsuz bir giriş alanını sınırlı bir çıkış alanına  $((0,1)$  aralığına) eşleyen doğrusal olmayan sürekli bir fonksiyondur. Bu özellik, aktivasyon fonksiyonunun herhangi bir fonksiyonu tahmin etmesi için, YSA modellerinde genellemeyi mümkün kılar. Bu aktivasyon fonksiyonu, biyolojik olarak akla yatkındır ve geri yayımlı eğitim ile YSA tasarımları için sıklıkla kullanılmaktadır. Geri yayılım algoritması, aktivasyon fonksiyonunun diferansiyel çıkışını hesaplamak için gerekli olan gradient descent'e dayanmaktadır. Bu aktivasyon fonksiyonunun kolaylıkla türevi alınabilir, ayrıca türev fonksiyonu sürekli (Alves et al., 2017; Khazaei et al., 2017; Kumar & Saini, 2016; Zhang, 2017a).

TanSig Aktivasyon fonksiyonu,  $(-\infty, +\infty)$  aralığındaki sonsuz bir giriş alanını sınırlı bir çıkış alanına  $(-1,1)$  aralığına) eşleyen doğrusal olmayan sürekli bir fonksiyondur (Zhang, 2017a).

### 3. Chen Kaotik Sistemi (CKS):


Chen Kaotik Sistemi (CKS), Eşitlik 7'de tanımlanmıştır (Liang & Qi, 2017; Yassen, 2003):

$$\dot{x} = a.(y - x)$$

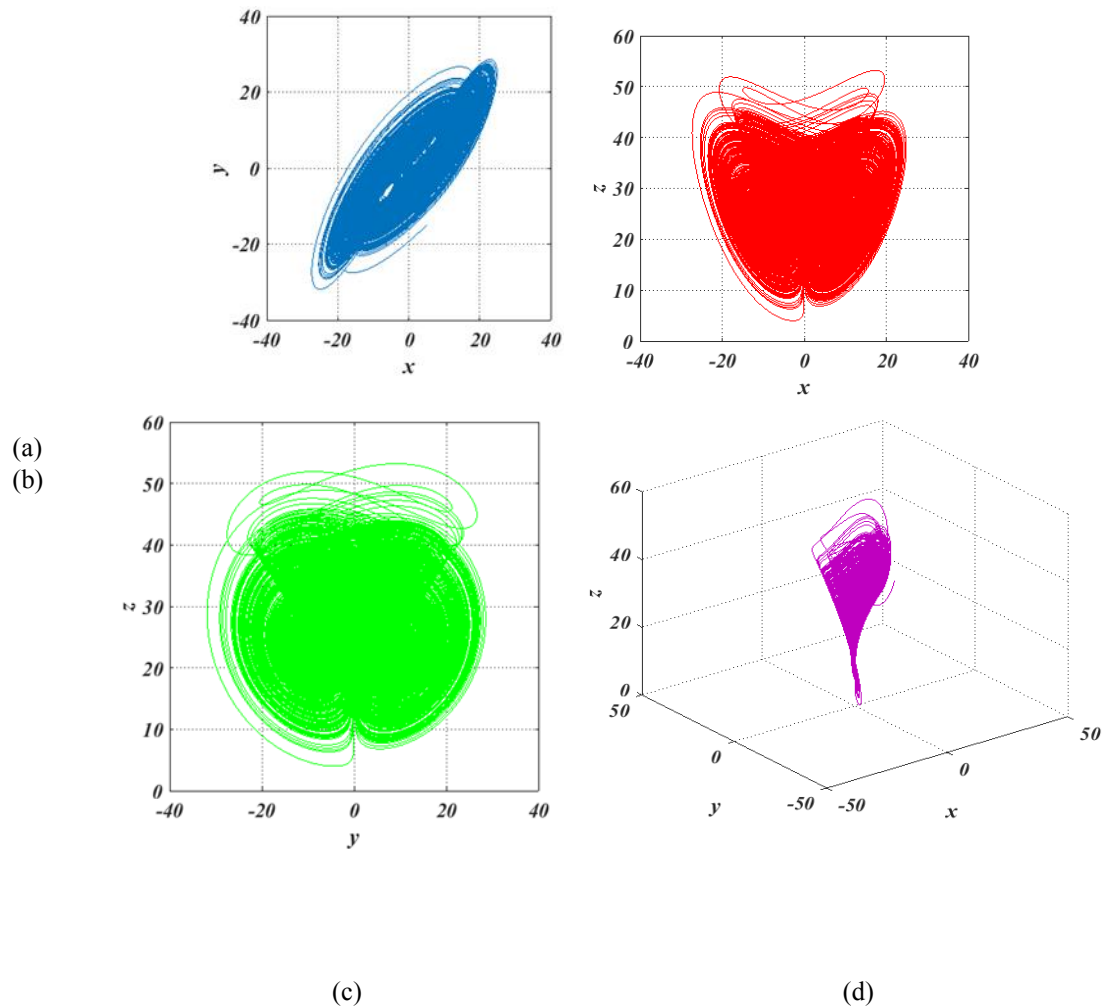
$$\dot{y} = (c - a).x - x.z + c.y \quad (7)$$

$$\dot{z} = x.y - b.z$$

Burada  $x$ ,  $y$  ve  $z$  durum değişkenleridir.  $a$ ,  $b$  ve  $c$ , 3 pozitif gerçek katsayıdır.  $a=35$ ,  $b=3$  ve  $c=28$  değerlerini aldığı zaman sistem eşsiz bir kaotik çekiciye sahip olur. Nümerik çözümler, 5. Dereceden Runge-Kutta metodu (RK5B) kullanılarak gerçekleştirilmiştir. Adım aralığı  $dt = 0.001$  ve başlangıç koşulları  $x_0 = 5$ ;  $y_0 = -15$ ;  $z_0 = 40$  olarak alınmıştır (Liang & Qi, 2017; Yassen, 2003). Şekil 3 ve Şekil 4'te sırasıyla Chen Sistemine ait zaman serileri ve Chen Sistemine ait kaotik çekiciler gösterilmektedir.




Şekil 3. Chen Sisteminin zaman serileri.



Şekil 4. Chen Sisteminin ait kaotik çekiciler (a): x-y düzleminde (b): x-z düzleminde (c): y-z düzleminde (d):x-y-z düzleminde


#### 4. YSA Yapılarının Tasarımı ve Eğitimi:

YSA yapılarının eğitimi için MATLAB Neural Network Toolbox kullanılmıştır. Şekil 5'te kullanılan İBYSA Yapısı gösterilmektedir. Buna göre, giriş katmanında 3, gizli katmanda 6 ve çıkış katmanında 3 nöron bulunmaktadır. 3x6x3 YSA İBYSA yapısı için gizli katmanda kullanılan aktivasyon fonksiyonlarından LogSig örneklenmektedir.



Şekil 5. Kullanılan İBYSA Yapısı.

Şekil 6’da kullanılan GBYSA Yapısı gösterilmektedir. Buna göre, yine giriş katmanında 3, gizli katmanda 6 ve çıkış katmanında 3 nöron bulunmaktadır. 3x6x3 YSA GBYSA yapısı için gizli katmanda kullanılan aktivasyon fonksiyonlarından RadBas örneklenmektedir.



Şekil 6. Kullanılan GBYSA Yapısı.

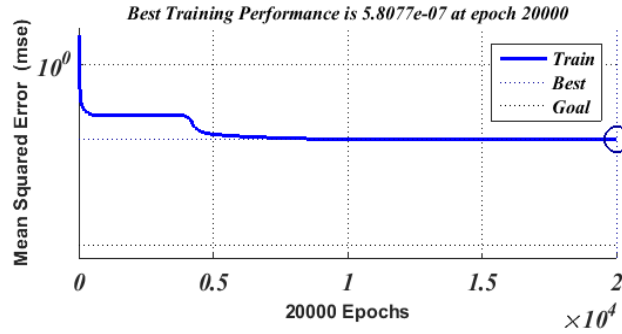
CKS, Tablo 1’de parametreleri gösterilen İBYSA ve GBYSA ağ yapıları ile oluşturulmuştur. Oluşturulan bu modeller için sırasıyla LogSig, TanSig ve RadBas aktivasyon fonksiyonlarını içeren ve Şekil 5’te ve Şekil 6’da yapıları gösterilen ağ modelleri için ayrı ayrı YSA eğitimi gerçekleştirilmiştir.

Tablo 1. Ağ modelleri için eğitim parametreleri

	İBYSA Model Yapısı	GBYSA Model Yapısı
<b>Katman Sayısı</b>	3	3
<b>Katmanlardaki Nöron Sayıları</b>	Giriş: 3 Gizli:6 Çıkış:3	Giriş: 3 Gizli:6 Çıkış:3
<b>Başlangıç ağırlıkları ve eşik değerleri</b>	Rasgele	Rasgele
<b>Aktivasyon fonksiyonları</b>	Gizli: LogSig, TanSig ve RadBas Çıkış:Lineer	Gizli: LogSig, TanSig ve RadBas Çıkış:Lineer
<b>Performans Fonksiyonu</b>	Mean Square Error (mse)	Mean Square Error (mse)
<b>Örnek Veri Sayısı</b>	6000	6000
<b>İterasyon Sayısı</b>	20000	20000
<b>Hata hedefi</b>	1e-15	1e-15


Chen kaotik sistemine ait 6,000 eğitim örneği, MATLAB yazılımı kullanılarak RK5B nümerik çözüm yöntemi ile üretilmiştir. Eğitim süreci boyunca, İBYSA’nın ve GBYSA’nın 3 girişi, Chen kaotik sistemine ait 1.-6000. örnekler tarafından sağlanmakla birlikte; İBYSA’nın ve GBYSA’nın 3 çıkışı, Chen kaotik sistemine ait girişin iteratif versiyonlarını temsil eden 2.-6001. örnekler tarafından

sağlanmaktadır. Eğitim MATLAB Neuron Network Toolbox'ın temin ettiği, LogSig, TanSig ve RadBas olmak üzere 3 farklı aktivasyon fonksiyonu ile ayrı ayrı gerçekleştirilmiştir. Her bir eğitim 20,000 iterasyon sonunda sonlandırılmıştır. Gizli katmanda LogSig aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 7'de gösterilmektedir.



Şekil 7. Gizli katmanda LogSig aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği.

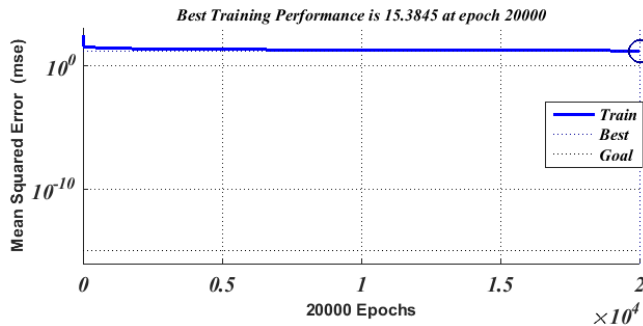
Şekil 7'ye göre, Gizli katmanda LogSig aktivasyon fonksiyonu bulunduğunda, İBYSA için, eğitim sonunda elde edilen MSE'nin  $5.8 \times 10^{-7}$  gibi küçük bir değere düştüğü görülmüştür. Gizli katmanda TanSig aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 8'de gösterilmektedir.



Şekil 8. Gizli katmanda TanSig aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği.

Şekil 8'e göre, Gizli katmanda TanSig aktivasyon fonksiyonu bulunduğunda, İBYSA için, eğitim sonunda elde edilen MSE'nin  $2.35 \times 10^{-7}$  gibi küçük bir değere düştüğü görülmüştür.

Gizli katmanda RadBas aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 9'da gösterilmektedir.




Şekil 9. Gizli katmanda RadBas aktivasyon fonksiyonu bulunan İBYSA için, eğitim sonunda elde edilen performans grafiği.

Şekil 9'a göre, Gizli katmanda RadBas aktivasyon fonksiyonu bulunduğunda, İBYSA için, eğitim



sonunda elde edilen MSE'nin 15.38 gibi istenmeyen büyük bir değer olduğu görülmüştür.


Gizli katmanda LogSig aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 10'da gösterilmektedir.



Şekil 10. Gizli katmanda LogSig aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği.

Şekil 10'a göre, Gizli katmanda LogSig aktivasyon fonksiyonu bulunduğu, GBYSA için, eğitim sonunda elde edilen MSE'nin 4.71e-09 gibi küçük bir değere düştüğü görülmüştür.

Gizli katmanda TanSig aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 11'de gösterilmektedir.

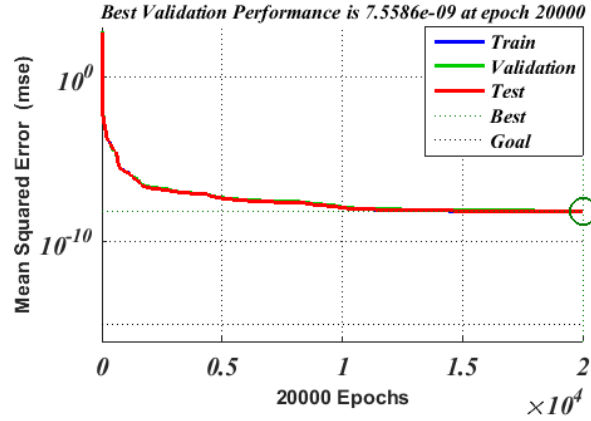


Şekil 11. Gizli katmanda TanSig aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği.

Şekil 11'e göre, Gizli katmanda TanSig aktivasyon fonksiyonu bulunduğu, GBYSA için, eğitim sonunda elde edilen MSE'nin 5.42e-09 gibi küçük bir değere düştüğü görülmüştür.

Gizli katmanda RadBas aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği Şekil 12'de gösterilmektedir.





Şekil 12. Gizli katmanda RadBas aktivasyon fonksiyonu bulunan GBYSA için, eğitim sonunda elde edilen performans grafiği.

Şekil 11'e göre, Gizli katmanda TanSig aktivasyon fonksiyonu bulunduğunda, GBYSA için, eğitim sonunda elde edilen MSE'nin 5.42e-09 gibi küçük bir değere düştüğü görülmüştür.

##### 5. YSA Yapılarının Performans Değerlendirmesi:

YSA eğitim sonucu, hesaplanan YSA çıkışı,  $y$ , ile hedef eğitim çıkışı,  $\hat{y}$ , arasındaki hata ile ölçülür. Eğitim amacı, çıkışın doğru olarak görülebilmesi için yeterince küçük olan bir eşik hata değeridir. YSA eğitim işleminin performansı, hatanın hedef eşik seviyesine ne kadar hızlı ve ne kadar iyi örtüştüğü ile değerlendirilir. Çıkış hatasının ölçümü için en sık kullanılan yöntem Eşitlik 8 ile ifade edilen MSE (Mean Square Error, Ortalama Karesel Hata)'dir (Zhang, 2017b).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (8)$$

Burada N çıkış sayısını ifade etmekle birlikte bu Chen kaotik sistemi için 3'tür. LogSig, TanSig ve RadBas aktivasyon fonksiyonlarını içeren İBYSA ve GBYSA ile oluşturulmuş 6 farklı YSA yapısı için eğitim performansları Tablo 2'de gösterilmektedir.

Tablo 2. İBYSA ve GBYSA'ya göre ve aktivasyon fonksiyonlarına göre eğitim performansı (20000 iterasyon için, MSE cinsinden)

	LOGSIG	TANSIG	RADBAS
FFNN	5.8e-07	2.35 e-07	15.38
RNN	4.71 e-09	5.42 e-09	7.55 e-09

Buna göre, AKS'nin, İBYSA yapısı ile modellenmesinde kullanılan aktivasyon fonksiyonlarından TanSig aktivasyon fonksiyonunun daha hassas sonuçlar ürettiği görülmüştür. Benzer şekilde, AKS'nin, GBYSA yapısı ile modellenmesinde kullanılan aktivasyon fonksiyonlarından LogSig aktivasyon fonksiyonunun daha hassas sonuçlar ürettiği görülmüştür.

##### 6. Sonuç:

Bu çalışmada, Aizawa Kaotik Sistemi (AKS), İleri Beslemeli YSA (İBYSA) ve Geri Beslemeli YSA (GBYSA) yapıları kullanılarak modellenmiştir. Gerçekleştirilen ağ modeli yapılarında, giriş katmanı için 3 giriş ve çıkış katmanı için 3 çıkış bulunmaktadır. Girişler AKS'nin durum değişkenlerini

göstermektedir. Çıkışlar ise AKS'nin çıkışlarını göstermekle birlikte aynı zamanda durum değişkenlerinin bir sonraki durumunu ifade etmektedir. Gizli katmanda 6 nöron bulunmaktadır ve her bir nöron yapısında RadBas, LogSig ve TanSig aktivasyon fonksiyonları yer almaktadır. 3-6-3 ağ yapıları MATLAB yazılımı ile oluşturulmuştur. Sonuç olarak, bu fonksiyonlar ile oluşturulan ağ yapılarında AKS'nin modellenme performansı ile ilgili analiz çalışmaları yapılmıştır. Ortalama Karesel Hata (Mean Square Error, mse), YSA yapılarının modelleme performansını ölçmek için kullanılmıştır. Bu çalışmalar neticesinde LogSig ve TanSig aktivasyon fonksiyonlarının genel olarak daha hassas sonuçlar ürettiği görülmüştür. İleriki çalışmalarda bu veya benzer yapılar kullanılarak mühendislik alanlarına yönelik donanımsal çözümler gerçekleştirilebilir.

### Referanslar

- Alçın, M. (2017). *Yeni Bir Fpga-Ysa Tabanlı Gerçek Rasgele Sayı Üreteci Tasarımı ve Gerçeklenmesi*. (Doktora Tezi), Sakarya Üniversitesi.
- Alves, E. R., Tavares da Costa Jr, C., Lopes, M. N. G., da Rocha, B. R. P., & de Sá, J. A. S. (2017). Lightening prediction using satellite atmospheric sounding data and feed-forward artificial neural network. *Journal of Intelligent & Fuzzy Systems*, 33(1), 79-92.
- Bahi, J. M., Couchot, J.-F., Guyeux, C., & Salomon, M. (2016). Neural Networks and Chaos: Construction, Evaluation of Chaotic Networks, and Prediction of Chaos with Multilayer Feedforward Networks. *arXiv preprint arXiv:1608.05916*.
- Chen, Z. Y., & Kuo, R. (2017). Evolutionary Algorithm - Based Radial Basis Function Neural Network Training for Industrial Personal Computer Sales Forecasting. *Computational Intelligence*, 33(1), 56-76.
- Doucoure, B., Agbossou, K., & Cardenas, A. (2016). Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data. *Renewable Energy*, 92, 202-211.
- Erkaymaz, O., & Ozer, M. (2016). Impact of small-world network topology on the conventional artificial neural network for the diagnosis of diabetes. *Chaos, Solitons & Fractals*, 83, 178-185.
- Gautam, M. K., & Giri, V. K. (2016). An Approach of Neural Network For Electrocardiogram Classification. *APTİKOM Journal on Computer Science and Information Technologies*, 1(3), 115-123.
- Johansson, S., & Nafar, S. (2017). Effective Sampling and Windowing for an Artificial Neural Network Model Used in Currency Exchange Rate Forecasting.
- Khazaei, M., Sadat-Hosseini, H., Marjaninejad, A., & Daneshvar, S. (2017). *A Radial Basis Function Neural Network approximator with fast terminal sliding mode-based learning algorithm and its application in control systems*. Paper presented at the Electrical Engineering (ICEE), 2017 Iranian Conference on.
- Khelifa, M. A., & Boukabou, A. (2016). Design of an intelligent prediction-based neural network controller for multi-scroll chaotic systems. *Applied Intelligence*, 45(3), 793-807.
- Koyuncu, I. (2016). Design and implementation of high speed artificial neural network based Sprott 94 S system on FPGA. *International Journal of Intelligent Systems and Applications in Engineering*, 4(2), 33-39.
- Kumar, H., & Saini, S. (2016). *Chaotic characterization of electric load demand time series & load forecasting by using GA trained artificial neural network*. Paper presented at the Signal Processing, Communication, Power and Embedded System (SCOPEs), 2016 International Conference on.

- Lamamra, K., Vaidyanathan, S., Azar, A. T., & Salah, C. B. (2017). Chaotic System Modelling Using a Neural Network with Optimized Structure *Fractional Order Control and Synchronization of Chaotic Systems* (pp. 833-856): Springer.
- Liang, X., & Qi, G. (2017). Mechanical analysis of Chen chaotic system. *Chaos, Solitons & Fractals*, 98, 173-177.
- Loussifi, H., Nouri, K., & Braiek, N. B. (2016). A new efficient hybrid intelligent method for nonlinear dynamical systems identification: The Wavelet Kernel Fuzzy Neural Network. *Communications in Nonlinear Science and Numerical Simulation*, 32, 10-30.
- Mishra, S., & Mishra, A. (2017). Analysis and Improved Performance of ANN Based Chaotic Generator.
- Moldes, O., Mejuto, J., Rial-Otero, R., & Simal-Gandara, J. (2017). A critical review on the applications of artificial neural networks in winemaking technology. *Critical reviews in food science and nutrition*, 57(13), 2896-2908.
- Mostafa, M. M., & El-Masry, A. A. (2016). Oil price forecasting using gene expression programming and artificial neural networks. *Economic Modelling*, 54, 40-53.
- Panapakidis, I. P., & Dagoumas, A. S. (2016). Day-ahead electricity price forecasting via the application of artificial neural network based models. *Applied Energy*, 172, 132-151.
- Sanchez, E. N., Rodriguez-Castellanos, D. I., Chen, G., & Ruiz-Cruz, R. (2017). Pinning control of complex network synchronization: A recurrent neural network approach. *International Journal of Control, Automation and Systems*, 1-10.
- Tlelo-Cuautle, E., de Jesús Rangel-Magdaleno, J., & de la Fraga, L. G. (2016). *Engineering Applications of FPGAs: Chaotic Systems, Artificial Neural Networks, Random Number Generators, and Secure Communication Systems*: Springer.
- Vaidyanathan, S., & Azar, A. T. (2016). A Novel 4-D Four-Wing Chaotic System with Four Quadratic Nonlinearities and Its Synchronization via Adaptive Control Method. In A. T. Azar & S. Vaidyanathan (Eds.), *Advances in Chaos Theory and Intelligent Control* (pp. 203-224). Cham: Springer International Publishing.
- Vaidyanathan, S., Azar, A. T., & Ouannas, A. (2017). An Eight-Term 3-D Novel Chaotic System with Three Quadratic Nonlinearities, Its Adaptive Feedback Control and Synchronization *Fractional Order Control and Synchronization of Chaotic Systems* (pp. 719-746): Springer.
- Vaidyanathan, S., & Volos, C. (2016). *Advances and applications in chaotic systems* (Vol. 636): Springer.
- Yassen, M. (2003). Chaos control of Chen chaotic dynamical system. *Chaos, Solitons & Fractals*, 15(2), 271-283.
- Zhang, L. (2017a). *Artificial neural network model-based design and fixed-point FPGA implementation of hénon map chaotic system for brain research*. Paper presented at the Electronics, Electrical Engineering and Computing (INTERCON), 2017 IEEE XXIV International Conference on.
- Zhang, L. (2017b). *Artificial Neural Network model design and topology analysis for FPGA implementation of Lorenz chaotic generator*. Paper presented at the Electrical and Computer Engineering (CCECE), 2017 IEEE 30th Canadian Conference on.