



T. C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



YÜKSEK LİSANS TEZİ

NÖTRAL TİPTEKİ ZAMAN GECİKMELİ DİNAMİK
YAPAY SİNİR AĞLARININ KARARLILIK
ÖZELLİKLERİNİN İNCELENMESİ

Zeliha DOĞAN

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

DANIŞMAN

Doç. Dr. Rüya ŞAMLI

II. DANIŞMAN

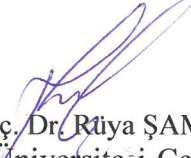
Doç. Dr. Eylem Yücel DEMİREL

Mayıs, 2019

İSTANBUL


Bu çalışma 23.05.2019 Tarihinde ařağıdaki jüri tarafından Bilgisayar Mühendisliğı Anabilim Dalı, Bilgisayar Mühendisliğı Tezli Yüksek Lisans Programı Yüksek Lisans Tezi olarak kabul edilmiştir.

TEZ JÜRİSİ


Doç. Dr. Rtiya ŞAMLI
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi


Prof. Dr. Sabri ARIK
İstanbul Üniversitesi-Cerrahpařa
Mühendislik Fakültesi

Dr.Öğr.Üyesi Cahit KARAKUŞ
İstanbul Esenyurt Üniversitesi
Mühendislik ve Mimarlık Fakültesi





20.04.2016 tarihli Resmi Gazete' de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın aboneli olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, 118E682 numaralı TÜBİTAK projesi ile desteklenmiştir.

ÖNSÖZ

Yüksek lisans öğrenimim ve tez çalışmam boyunca hiçbir zaman destek ve yardımlarını esirgemeyen çok değerli hocam Doç. Dr. Rüya ŞAMLI' ya en içten dileklerle teşekkür ederim.

Bilgi ve görüşlerini esirgemeyen değerli hocam Prof. Dr. Sabri ARIK'a ve ikinci tez danışmanım Doç. Dr. Eylem YÜCEL DEMİREL'e sonsuz teşekkürler...

Tez çalışmam boyunca desteklerinden dolayı değerli çalışma arkadaşlarıma teşekkür ederim. Ve manevi desteklerinden dolayı aileme teşekkürü borç bilirim.

Mayıs, 2019

Zeliha DOĞAN

İÇİNDEKİLER

| | Sayfa No |
|---|-----------|
| ÖNSÖZ | İV |
| ŞEKİL LİSTESİ | VI |
| TABLO LİSTESİ..... | VII |
| SİMGE VE KISALTMA LİSTESİ | VIII |
| ÖZET | İX |
| SUMMARY | X |
| 1.GİRİŞ..... | 1 |
| 2. GENEL KISIMLAR | 3 |
| 2.1. YAPAY SİNİR AĞLARI (YSA) | 3 |
| 2.1.1. Yapay Sinir Ağlarının Özellikleri | 4 |
| 2.1.2. Biyolojik Sinir Ağları | 5 |
| 2.1.3. Yapay Sinir Ağı – Biyolojik Sinir Ağı Karşılaştırması..... | 6 |
| 2.1.4. Yapay Sinir Ağları' nın Yapısı | 10 |
| 2.1.5. Yapay Sinir Ağları'nın Sınıflandırılması..... | 12 |
| 2.1.5.1.Yapılarına Göre Yapay Sinir Ağları..... | 12 |
| 2.1.5.2. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları..... | 13 |
| 2.1.5.3. Öğrenme Zamanına Göre Yapay Sinir Ağları | 14 |
| 2.1.6. Yapay Sinir Ağı Modelleri..... | 15 |
| 3. MALZEME VE YÖNTEM | 22 |
| 3.1. VEKTÖR VE MATRİS NÖRMLERİ | 22 |
| 3.2. MATRİS SINIFLARI | 23 |
| 3.3. KARARLILIK TEOREMLERİ | 26 |
| 4. BULGULAR | 32 |
| 4.1. NÖTRAL TİPTEKİ YAPAY SİNİR AĞLARI'NIN TANIMI | 32 |
| 4.2. LİTERATÜRDEKİ NÖTRAL TİPTEKİ YAPAY SİNİR AĞI MODELLERİ | 34 |
| 4.2.1. MODELLER VE AÇIKLAMALARI | 34 |
| 4.2.2. MODELLER ARASI İLİŞKİLER | 62 |
| 4.3. NÖTRAL TİPTEKİ YAPAY SİNİR AĞI MODELLERİNİN SINIFLANDIRILMASI..... | 68 |
| 4.3.1. Gecikmeye Göre Sınıflandırma | 70 |
| 4.3.2. Kararlılık Tipine Göre Sınıflandırma | 73 |
| 4.3.3. Aktivasyon Fonksiyonlarına Göre Sınıflandırma..... | 76 |
| 5. TARTIŞMA VE SONUÇ | 80 |
| KAYNAKLAR..... | 81 |
| ÖZGEÇMİŞ | 89 |

ŞEKİL LİSTESİ

| | Sayfa No |
|---|-----------------|
| Şekil 2.1: Biyolojik Sinir Ağı Yapısı | 6 |
| Şekil 2.2: Biyolojik Sinir Ağı ve Yapay Sinir Ağı | 7 |
| Şekil 2.3: Yapay Sinir Hücresinin Yapısı | 8 |
| Şekil 2.4: Yapay Sinir Ağının Yapısı..... | 11 |
| Şekil 2.5: İleri Beslemeli Yapay Sinir Ağları | 12 |
| Şekil 2.6: Geri Beslemeli Yapay Sinir Ağları..... | 13 |
| Şekil 2.7: 3x3 boyutunda Hücresel Sinir Ağı Mimarisi..... | 20 |



TABLO LİSTESİ

| | Sayfa No |
|---|-----------------|
| Tablo 2.1: Biyolojik Sinir Sistemi/Yapay Sinir Sistemi..... | 7 |
| Tablo 2.2: En Sık Kullanılan Aktivasyon Fonksiyonları..... | 9 |
| Tablo 4.1: Literatürdeki Nötral Tipteki Yapay Sinir Ağı Çalışmaları..... | 68 |
| Tablo 4.2: Gecikmelerine Göre Sınıflandırma | 70 |
| Tablo 4.3: Kararlılık Tipine Göre Sınıflandırma | 74 |



SİMGE VE KISALTMA LİSTESİ

Simgeler

| | |
|--------|--|
| A | : Pozitif diyagonal matrisi |
| $g(u)$ | : Nöron aktivasyon fonksiyonu |
| u | : Yapay Sinir Ağları'nın nöron durum vektörü |
| w | : Yapay Sinir Ağları'nın ağırlıkları |
| x | : Yapay Sinir Ağları'nın girişleri |
| y | : Yapay Sinir Ağları'nın çıkışları |

Kisaltmalar

Açıklama

| | |
|-------|---|
| BAM | : Bidirectional Associative Memory |
| CNN | : Cellular Neural Networks |
| ÇBA | : Çift Yönlü Çağrışimli Bellek Yapay Sinir Ağları |
| GBYSA | : Geri Beslemeli Yapay Sinir Ağları |
| HSA | : Hücresel Yapay Sinir Ağları |
| İBYSA | : İleri Beslemeli Yapay Sinir Ağları |
| TSP | : Traveling Salesman Problem - Gezgin Satıcı Problemi |
| YSA | : Yapay Sinir Ağları |

ÖZET

YÜKSEK LİSANS TEZİ

NÖTRAL TİPTEKİ ZAMAN GECİKMELİ DİNAMİK YAPAY SINIR AĞLARININ KARARLILIK ÖZELLİKLERİNİN İNCELENMESİ

Zeliha DOĞAN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Rüya ŞAMLI

II. Danışman: Doç. Dr. Eylem YÜCEL DEMİREL

Bu tez çalışmasında, literatürdeki Nötral Tipteki Yapay Sinir Ağı modelleri incelenmiş ve çeşitli özelliklerine göre sınıflandırılmıştır. Bu çerçevede Nötral Tipteki Yapay Sinir Ağı modelleri tanımları verilmiş, kararlılık özellikleri ele alınmış ve gecikme türleri incelenmiştir. Modeller; sahip oldukları gecikmeye, kararlılık özelliklerine ve kullandıkları aktivasyon fonksiyonlarına göre sınıflandırılmıştır. Son olarak modellerin genel bir değerlendirmesi yapılmıştır. Bu tez çalışması Nötral Tipteki Yapay Sinir Ağı modellerini derleyen bu kapsamdaki en geniş çalışma olma niteliği taşımaktadır.

Mayıs 2019, 96 sayfa.

Anahtar kelimeler: Kararlılık Analizi, Nötral Tipteki Yapay Sinir Ağları

SUMMARY

M.Sc. THESIS

THE INVESTIGATION OF STABILITY PROPERTIES OF NEUTRAL TYPE TIME DELAYED DYNAMIC NEURAL NETWORKS

Zeliha DOĞAN

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Computer Engineering

Supervisor: Assoc. Prof. Dr. Rüya ŞAMLI

Co-Supervisor: Assoc. Prof. Dr. Eylem YÜCEL DEMİREL

In this thesis, Neural Type Neural Network models in the literature are examined and classified according to their various characteristics. In this context, Neutral Type Artificial Neural Network models are given definitions, stability properties are discussed and delay types are examined. Models; they are classified according to their delay, stability characteristics and activation functions. Finally, a general evaluation of the models was made. This thesis is the most extensive study of Neural Type Neural Network models.

May 2019, 96 pages.

Keywords: Stability Analysis, Neutral Type Artificial Neural Networks

1.GİRİŞ

Genel tanımıyla, Yapay Sinir Ağları (YSA) insan beyninin biyolojik yapısını ve çalışma prensibini taklit ederek geliştirilmiş, önceden öğrenilmiş bilgileri kullanarak yeni bilgiler türetebilen yapılardır. Genellikle örüntü tanıma, sinyal işleme, robotik gibi çalışma konuları ile birlikte kullanılan Yapay Sinir Ağları, finans, otomotiv, sağlık gibi pek çok alandaki problemlere çözüm üretmektedir.

Yapay Sinir Ağları'nın ilk modeli Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir. Bu model, elektrik devrelerini kullanarak ve insan beyninden esinlenerek oluşturulmuştur. Zamanla yapay zekâ alanında yaşanan gelişmelere bağlı olarak Yapay Sinir Ağları rağbet görmeye başlamış, konu üzerinde yapılan çalışmalar artmıştır. 1980 yılı sonrasında, Hopfield tarafından bilgisayar yazılımı ile çözülemeyen bazı problemlerin Yapay Sinir Ağları aracılığı ile çözülebileceği gösterilmiştir. Gelişen teknoloji ve artan ihtiyaçlar, Yapay Sinir Ağları modellerinin gelişmesine ve çeşitlenmesine yol açmıştır. Hopfield Yapay Sinir Ağları, Hüresel Yapay Sinir Ağları ve Cohen-Grossberg Yapay Sinir Ağları modelleri bunlardan bazılarıdır. Bunun dışında pek çok Yapay Sinir Ağları modelleri de bulunmaktadır. Bu tezin asıl konusu Nötral Tipteki Zaman Gecikmeli Dinamik Yapay Sinir Ağları (kısaca Nötral Tipteki Yapay Sinir Ağları) olduğundan diğer modeller ayrıntılı olarak incelenmemiştir.

Kullanılacak alan ve uygulamaya göre Yapay Sinir Ağı modelinde, denge noktasının varlık-teklik durumu ve kararlılık analizleri farklılık göstermektedir. Örneğin, Yapay Sinir Ağı, optimizasyon problemlerinin çözümü için kullanılacaksa; tek bir denge noktasına sahip olmalıdır ve bu denge noktası global asimptotik kararlı olmalıdır. Böyle bir problem çözümü için fazla sayıda denge noktası belirlenmesi, sistemin yanlış sonuçlar üretmesine sebep olacaktır. Buna karşın, eğer bir çağrışımlı bellek tasarımı yapılacaksa Yapay Sinir Ağı'nın birden fazla denge noktasına sahip olması ve tam kararlılığının sağlanması gerekmektedir. Böylece bir örüntü için daha fazla bilgi depolama olanağı oluşmuş olacaktır.

Yapay Sinir Ağları'nın denge noktasının varlık-teklik durumunu ve kararlılık analizini etkileyen en önemli etken, sistemin sahip olduğu gecikmedir. Gerçek dünya uygulamalarındaki

durumun aksine, teoride Yapay Sinir Ağını oluşturan nöronlar arasındaki sinyal iletiminin kusursuz olduğu varsayılmaktadır. Yapay Sinir Ağları'nın uygulanmasında, nöronlar arasındaki sinyal iletimi arasında çeşitli gecikmeler olduğu görülmektedir. Yapay Sinir Ağları'nın kararlılıkları incelenirken, gecikme durumları da ele alınarak analiz yapılması, gerçeğe daha yakın sonuçlar elde edilmesini sağlamaktadır. Yapay Sinir Ağları üzerine çalışan araştırmacılar tarafından, farklı gecikmelere sahip olan farklı tipteki Yapay Sinir Ağı modellerinin denge noktası kararlılık analizi için çeşitli koşullar elde edilmiştir.

En genel tanımıyla "hem durum denkleminde hem de türev denkleminde gecikme bulunan Yapay Sinir Ağı tipi" olarak tanımlanabilecek olan Nötral Tipteki Yapay Sinir Ağları, bu tez çalışmasının asıl konusunu oluşturmaktadır. Yapay Sinir Ağları'nın kararlılığı ile ilgili birçok çalışma yapılmış olup, kimileri zamandan bağımsız, kimileri zamana bağlı olacak şekilde yeni kararlılık koşulları türetilmiştir.

Bu tez çalışmasında, Nötral Tipteki Yapay Sinir Ağları modelleri incelenmiş ve bu modeller gecikmelerine göre, kararlılık tiplerine göre ve aktivasyon fonksiyonlarına göre sınıflandırılarak bir derleme çalışması yapılmıştır.

Bu tez çalışmasının içeriği şu şekildedir: İkinci bölümde, (Genel Kısımlar), Yapay Sinir Ağları'nın tanımı, özellikleri, biyolojik sinir ağları ile karşılaştırılması, öğrenme algoritmaları gibi temel konular üzerinde durulmuştur. Üçüncü bölümde (Malzeme ve Yöntem), Yapay Sinir Ağları'nda "kararlılık kavramı" açıklanmış ve kararlılık analizlerinde sıkça kullanılan vektör ve matris normları ifade edilmiştir. Ayrıca kararlılık analizi için önem arz eden, Lyapunov Teoremi, Hurwitz Teoremi gibi teoremlerden bahsedilmiştir. Dördüncü bölümde (Bulgular), literatürdeki çalışmalar incelenmiş, inceledikleri Yapay Sinir Ağları modelleri, çeşitli kriterlere göre (gecikme, kararlılık tipi, aktivasyon fonksiyonları) sınıflandırılmıştır. Bu tez çalışmasının temelini bu bölüm oluşturmaktadır. Tez çalışması bir derleme niteliği taşıdığından modellerin sınıflandırılması büyük önem taşımaktadır. Beşinci bölüm (Tartışma ve Sonuç) incelenen ve sınıflandırılan Nötral Tipteki Yapay Sinir Ağları modelleri yorumlanmıştır.

2. GENEL KISIMLAR

Bu bölümde, Yapay Sinir Ağları hakkında genel bilgiler verilmiş, Yapay Sinir Ağları'nın biyolojik sinir ağları ile karşılaştırması yapılmış ve Yapay Sinir Ağları çeşitleri (özel olarak Nötral Tipteki Yapay Sinir Ağları) konuları üzerinde durulmuştur.

2.1. YAPAY SİNİR AĞLARI (YSA)

Yapay Sinir Ağları, insan beyninin çalışma yapısından esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirlerine bağlanan ve modellemeler sunan yapılardır. Diğer bir tanımla, kendi aralarında paralel ve çok sayıda bağlantı oluşturmaları sonucu oluşan bir ağ kümesidir [1]. Bazı durumlarda, problemlere, bilgisayarla ya da karmaşık hesaplama yöntemleriyle çözüm bulmak bazı durumlarda oldukça güç olmaktadır. Yapay Sinir Ağları, bu tür durumlarda devreye girerek çözüm sunmaktadır.

Yapay Sinir Ağları'nın kısa bir tarihçesi aşağıdaki gibidir: 1940 yılı öncesine dayanan süreçlerde mühendislik hesabına dayanmayan çalışmalar yapılmıştır. 1943 yılında Warren McCulloch ve Walter Pitts tarafından ilk kez bir sinir ağı modeli geliştirilmiştir. Bu dönemde, sinir ağlarının temeli; elektrik devrelerinin belli bir görevi yerine getirebilecek hesaplama elemanları olarak düşünülmesiyle atılmıştır. Daha sonra paralel çalışma ilkesi kullanılarak öğrenme kuralları oluşturulmaya başlanmıştır. 1949 yılında, Donald Hebb, kendi adı ile anılan öğrenme kuramını Yapay Sinir Ağları'nı uygulamaya başlamıştır. Bu kuram "A hücrelerinin bir aksonu, B hücrelerini uyaracak ve tekrarlı veya sürekli olarak tetikleyecek kadar yakında ise, hücrelerde B'yi tetikleyen A'nın etkinliğini artıracak bir büyüme işlemi veya metabolik değişiklik olur" şeklindedir. Buradan "Yapay Sinir Ağları modelindeki bağlantı sayısı ile öğrenme ve uyum sağlayabilme durumları birbirleri ile ilişkilidir" sonucu çıkarılabilir. Yapay Sinir Ağları'nda yaşanan gelişmeler bir dönem yapay zeka gelişmeleriyle çakışmış olup, beraber çalışılmadığı için Yapay Sinir Ağları arka planda kalmıştır. Bu durum 1960'lı yılların ortasından, 1980'li yılların başına kadar sinir ağlarının gelişiminde duraklama dönemine girilmesine sebep olmuştur. Yapay Sinir Ağları'na ait önemli gelişmeler 1980 yılı sonrasında gerçekleşmiştir. 1982 yılında, Hopfield doğrusal olmayan dinamik Hopfield ağını geliştirmiştir. Böylece, yaygın olan ve bilgisayar yazılımları ile çözülmesi zor olan problemlere çözüm üretebildiğini gözlemlenmiştir. Gezgin Satıcı Problemi (Traveling Salesman Problem - TSP) probleminin çözülmesi buna en iyi örnek olmuştur. Kohonen, 1984 yılında danışmansız

öğrenebilen ağı geliştirmiştir. 1986 yılında Rumelhart, Yapay Sinir Ağları için devrim niteliğinde olan ve günümüzde çok yaygın bir şekilde kullanılan çok katmanlı algılayıcı geri yayımlı bir algoritma geliştirmiştir. Bu tarihlerden günümüze kadar Yapay Sinir Ağları'nın gelişmesi devam etmiştir ve halen devam etmektedir.

2.1.1. Yapay Sinir Ağlarının Özellikleri

Günümüz problemlerinin çoğu karışık ve sıradan algoritmalarla çözülemeyecek hale gelmiştir. Bu sebeple, Yapay Sinir Ağları kavramı karşımıza daha çok çıkmaya başlamış ve kullanımı giderek artmıştır. Hem karmaşık problemlere çözüm üretebilen hem de multidisipliner birçok alanda kullanılan Yapay Sinir Ağları'na rağbet giderek artmaktadır. Yapay Sinir Ağları'nı klasik problem çözme yöntemlerinden ayıran özellikleri şu şekilde sıralanabilir:

Paralellik: Yapay Sinir Ağları'nda bir işlem yapılırken çok sayıda nöron paralel (eş zamanlı) çalışır. Sistemdeki her nöron bir işleme elemanıdır ve her nöron kendi üzerine düşen görevi yerine getirir. Fakat zaman içerisinde herhangi bir nöron zarar görüp devre dışı kaldığında; sistem dikkate alınacak kadar zarar görmez. Nöronlar bu şekilde çalışabildiği için ağ hızı dolayısıyla performansı artmaktadır ve bu da nöronun devre dışı kaldığındaki zararı tolere edebilir.

Doğrusal Olmama: Yapay Sinir Ağları üzerinde dağılmış olan belli tipteki doğrusal olmayan birimler, bu özellikteki problemlerin de çözümünü mümkün kılmaktadır. Bu sayede daha fazla sayıda, karmaşık problemlerin çözümü kolaylaşmaktadır.

Genelleme: Yapay Sinir Ağları, kendisine öğretilmiş olan bilgilerden çıkarım yaparak, benzer olaylar karşısında anlamlı yanıtlar üretebilir.

Hata Toleransı: Geleneksel bilgisayar yapılarında bir veya birden fazla elamanın bozulması sonucu meydana gelen hasar, sistemde büyük bir kayba yol açarken; Yapay Sinir Ağları'nda böyle bir durum oluşmaz; bu tip bir hasar, ağın genel işleyişinde büyük bir soruna yol açmaz.

Öğrenme: Geleneksel bilgisayarlarda kullanılan hesaplama ya da programlama yöntemlerinden farklı olarak Yapay Sinir Ağları'nda örneklerle eğitime (öğrenme) mekanizması vardır. Yapay

Sinir Ağları'nın, öğrenebilmesi için örneklerin ağa gösterilerek ulaşılmak istenen sonuca göre ağın eğitilmesi gerekmektedir.

Bilgilerin Ağın Tamamında Saklanması: Geleneksel bilgisayarlarda veriler genellikle veri tabanında, tek bir merkezde saklanmaktadır. Yapay Sinir Ağları'nda ise, ağın tamamında saklanır. Bir ya da birkaç bilginin kaybolması, ağda herhangi bir soruna yol açmaz.

Yapay Sinir Ağları'nın bütün bu avantajlarının yanı sıra bazı dezavantajları da bulunmaktadır:

Ağ Yapısının Belirlenmesi Konusundaki Belirsizlik: Yapay Sinir Ağları'nda, ağ yapısının belirlenmesi belli bir kurala bağlı değildir. Uygun ağ yapısı deneme - yanılma ve deneyimlere bağlı olarak bulunur. Bu durum da ağ yapısının bulunmasını zorlaştırabilir.

Problemin Ağa Tanıtılması Konusundaki Sıkıntılar: Bir problemdeki verilerin, Yapay Sinir Ağları ile çözülebilmesi için nümerik değere sahip olması ya da nümerik değerlere dönüştürülmesi gerekmektedir. Bu dönüşüm esnasında kullanıcı tarafından yapılacak hata tüm sistemi etkileyebilir.


Yapay Sinir Ağları'ndaki gelişmeler son hızla devam etmektedir. Yukarıda açıklanmış olan avantajlar ve dezavantajlar göz önünde bulundurulduğunda, problem çözümlerinde ana kriter olan performans ve hata tolere edebilme özellikleri ağır basmaktadır. Ayrıca Yapay Sinir Ağları'nın sahip olduğu dezavantajların giderilmesi için sürekli çalışmalar yapılmaktadır.

2.1.2. Biyolojik Sinir Ağları

Yapay Sinir Ağları, biyolojik sinir ağlarının modellenmiş hali olduğu için, Yapay Sinir Ağları'nın yapısının anlaşılabilmesi için biyolojik sinir ağlarının yapısının bilinmesinde fayda olduğu düşünülmektedir.

Sinir sistemi çevreden gelen uyarıları alma, iletme ve bu uyarılara tepki vermeyi sağlar. Biyolojik sinir hücreleri (nöronlar), biyolojik sinir ağlarının temel elemanıdır. İnsan beyni yaklaşık olarak 10^{11} nörondan meydana gelmiştir. Her sinir hücresi diğer hücrelerle karşılıklı ilişki içerisindedir.

Biyolojik sinir ağlarının temel yapı taşı olan nöronların yapısı, Şekil 2.1’de görüldüğü gibidir ve dört ana bölümden oluşmaktadır. Bunlar; dentrit, akson, çekirdek ve bağlantılardır. Dentritlerin görevi, bağlı olduğu diğer nöronlardan gelen sinyalleri çekirdeğe iletmektir. Çekirdek, dentritten aldığı bu sinyalleri toplayarak, çok sayıda dentritin bağlı olduğu, aksona bağlıdır. Toplanan bu sinyaller akson tarafından işlenerek bağlantı noktalarına iletilir. Bu bağlantı noktaları ise, üretilmiş olan sinyalleri diğer nöronlara iletir.



Şekil 2.1: Biyolojik Sinir Ağı Yapısı

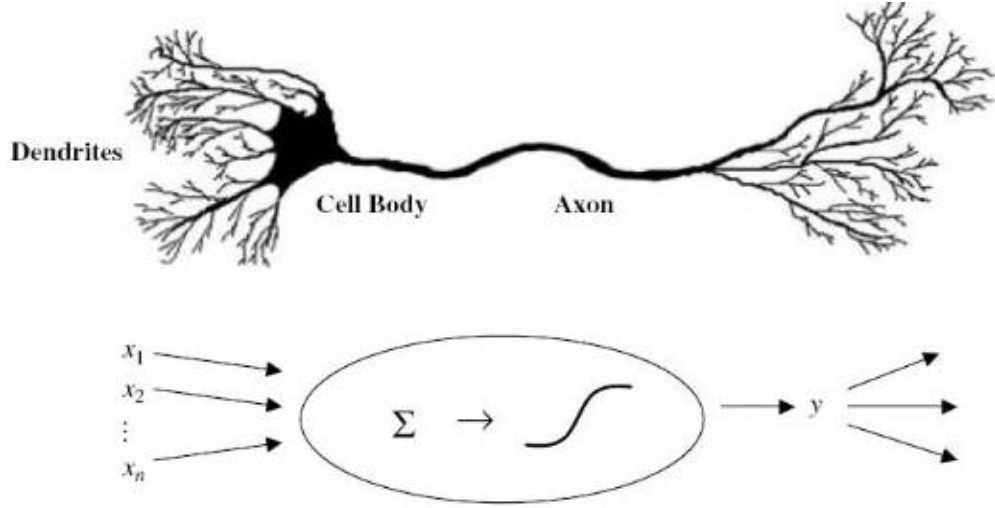
2.1.3. Yapay Sinir Ağı – Biyolojik Sinir Ağı Karşılaştırması

Biyolojik Sinir Ağları; dentrit, akson ve çekirdek ve sinaptan bağlantılarından oluşan yapılardır. Sinaptik bağlantılar, iki sinir hücresi arasında iletişimi sağlayan dentrit ve akson arasında bulunan boşluklardır. Sinapslar, biyolojik nöronlar arasındaki sinyal iletimini sağlar.

Biyolojik ağların çalışma şekli şu şekildedir:

1. Sinyaller, sinaplar aracılığı ile dentrite gelir.
2. Dentrite gelen sinyaller, nöronun akson kısmında toplanır.
3. Eğer toplamda oluşan sinyaller belli bir eşik değerinden büyükse akson aracılığı ile diğer nöronlara uyarı sinyali gönderir.

Yapay Sinir Ağları'nın modellenmesi, biyolojik sinir ağlarından esinlendiği için iki sinir ağının da çalışma mekanizması ve yapısı Şekil 2.2’de görüldüğü gibi benzerdir.



Şekil 2.2: Biyolojik Sinir Ağı ve Yapay Sinir Ağı

Biyolojik sinir ağları ve Yapay Sinir Ağları için kullanılan kavramlar şu şekildedir (Tablo 2.1):


Tablo 2.1: Biyolojik Sinir Sistemi/Yapay Sinir Sistemi

| BİYOLOJİK SİNİR SİSTEMİ | YAPAY SİNİR SİSTEMİ |
|-------------------------|---------------------|
| Nöron | İşlemci Eleman |
| Dentrit | Toplama Fonksiyonu |
| Hücre Gövdesi | Transfer Fonksiyonu |
| Aksonlar | Yapay Nöron Çıkışı |
| Sinapslar | Ağırlıklar |

Yapay Sinir Ağları; ağırlıklandırılmış girdiler, aktivasyon fonksiyonu ve bir çıktıdan oluşur. Yapay nöron olarak nitelendirdiğimiz eleman, çevreden gelen uyarıları girdi olarak alır. Gelen tüm girdileri, net bir girdi haline getirmek için ağırlıklandırılmış biçimde birleştirir ve bir eşik değerinden geçirek sinyali diğer nörona iletir. Biyolojik Sinir Ağları ile Yapay Sinir Ağları arasında benzer çalışma prensipleri vardır. Yapay nöronların oluşturdukları ağlar sayesinde, bu nöronların da giriş sinyallerini aldıkları, bu sinyalleri toplayıp işledikleri ve oluşturdukları çıktıları ilettikleri bölümleri vardır. Yapay sinir hücresi şu bölümlerden oluşmaktadır:

1. Girdiler
2. Ağırlıklar
3. Toplama Fonksiyonu
4. Aktivasyon Fonksiyonu
5. Çıktılar

Bir yapay sinir hücresinin yapısı Şekil 2.3'te gösterilmiştir.



Şekil 2.3: Yapay Sinir Hücresinin Yapısı

Yapay sinir hücresi modellemesinde giriş(x), çıkış(y) değişkenleri arasındaki ilişki $y = f(x) + \varepsilon$ şeklindedir. Oluşan hatayı azaltmak için ağırlık (W) değerleri atanır. Bu şekilde yer alan elemanlar aşağıdaki gibi açıklanabilir:

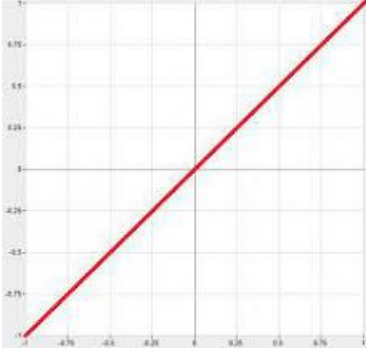
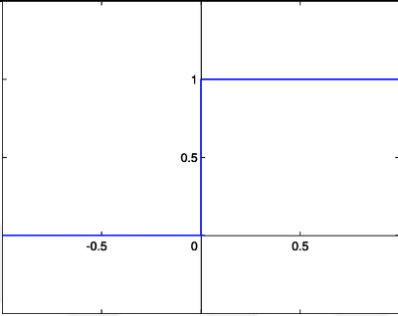
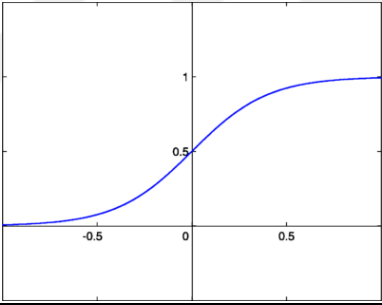
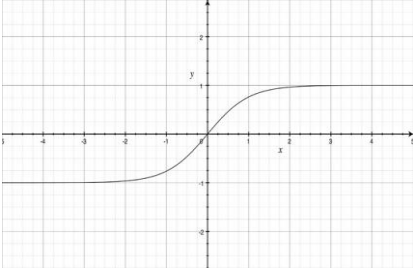
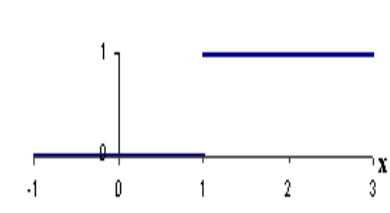
Girdiler: Girdi değerleri nörona gelen verilerdir. Girdi değerleri, diğer nöronlardan gelebileceği gibi dış çevreden de gelebilir. Bu girdilerden gelen veriler toplanmak üzere nöron çekirdeğine gönderilir.

Ağırlıklar: Yapay sinir hücresine gelen bilgiler çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlıklarıyla çarpılarak çekirdeğe iletilir. Ağırlıkla çarpılan her girdinin, çıktı üzerinde belli bir etkisi vardır. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Ağırlığı sıfır olan girdilerin çıkış değeri üzerinde bir etkisi yoktur. Buna bağlı olarak, her girdinin, çıkış değerini nasıl etkileyeceği tasarımcının değer atamasına bağlıdır.

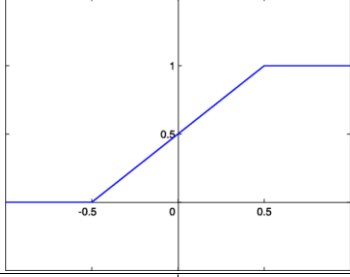
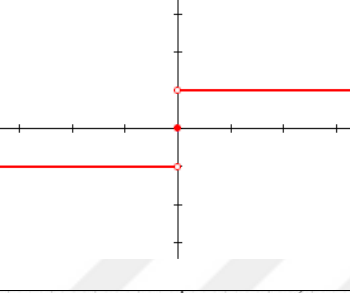
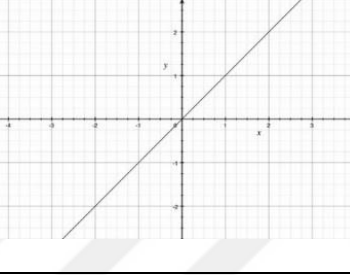
Toplama Fonksiyonu: Toplama fonksiyonu, bir yapay sinir hücresine ağırlıklarla çarpılarak gelen tüm girdileri toplayarak, o hücreye ait net girdiyi hesaplayan bir fonksiyondur. Toplama fonksiyonunu genelleme yaparak bulmak için bir yöntem bulunmamaktadır. Toplama fonksiyonu genellikle deneme yanılma yoluyla belirlenmektedir.

Aktivasyon Fonksiyonu: Bu fonksiyon, hücredeki net girdiyi işleyerek bu girdiye karşılık üretilecek çıktıyı belirler. Aktivasyon fonksiyonu deneme yanılma yolu ile seçilir, genellikle doğrusal olmayan bir fonksiyon tercih edilir. Bazı Yapay Sinir Ağları yapılarında aktivasyon fonksiyonunun türevi de kullanıldığı için, seçilecek fonksiyonun türevinin kolay hesaplanabilir olması gerekir. Bazı aktivasyon fonksiyonları Tablo 2.2'de verilmiştir:

Tablo 2.2: En Sık Kullanılan Aktivasyon Fonksiyonları

| Adı | Grafığı | Açıklaması |
|--|---|--|
| <p>Doğrusal (Linear) Fonksiyon:</p> <p>$f(x) = A * x$ (A sabit bir sayı) şeklinde ifade edilir.</p> |  | <p>Doğrusal problemlerin çözülmesi amacıyla doğrusal aktivasyon fonksiyonları kullanılmaktadır. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.</p> |
| <p>Adım (step) Fonksiyonu:</p> <p>$f_A(x) = \begin{cases} 1 & x \in A \\ 0 & x \notin A \end{cases}$ şeklinde tanımlanır.</p> |  | <p>Gelen net girdinin, belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.</p> |
| <p>Sigmoid Fonksiyon :</p> <p>$f(x) = \frac{1}{1+e^{-x}}$ şeklinde ifade edilir.</p> |  | <p>Sigmoid aktivasyon fonksiyonu sürekli türevi alınabilir bir fonksiyondur. Doğrusal olmaması sebebiyle, Yapay Sinir Ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerleri için 0 veya 1 arasında değerler üretir.</p> |
| <p>Tanh Fonksiyonu:</p> <p>$f(x) = \frac{e^{2x}-1}{e^{2x}+1}$ şeklinde ifade edilir.</p> |  | <p>Bu fonksiyon, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken, bu fonksiyonun çıkış değerleri -1 ile 1 arasında değişmektedir.</p> |
| <p>İkili Adım Fonksiyonu (Eşik Fonksiyonu):</p> <p>$f(x) = \begin{cases} 1 & (x \geq \theta) \\ 0 & (x < \theta) \end{cases}$ şeklinde tanımlanır.</p> |  | <p>x değerinin 0'a eşit ve büyük olduğu durumlarda, $f(x)=1$ ve x'in 0'dan küçük olduğu durumlarda $f(x)=0$ olur.</p> |

Tablo 2.2 (devamı): En Sık Kullanılan Aktivasyon Fonksiyonları


| | | |
|--|--|--|
| <p>Parçalı Doğrusal Fonksiyon :</p> $f(x) = \begin{cases} 1 & v \geq \frac{1}{2} \\ v & -\frac{1}{2} > v > \frac{1}{2} \\ 0 & v \leq -\frac{1}{2} \end{cases}$ <p>şeklinde tanımlanır.</p> |  | <p>Aktivasyon fonksiyonunun küçük değerleri için Yapay Sinir Ağı kazançlı birleştirici doğrusal bağlayıcı gibi çalışır. Fonksiyonun büyük değerleri için, doyum bölgesindedir ve 0 veya 1 üretir. Çok büyük kazançlar için, parçalı fonksiyon bir step fonksiyona dönüşür.</p> |
| <p>Signum (İşaret) Fonksiyonu :</p> $\text{sgn } x = \begin{cases} -1 & x < 0 \\ 0 & x = 0 \\ 1 & x > 0 \end{cases}$ <p>şeklinde tanımlanır.</p> |  | <p>Signum fonksiyonu, 0'dan küçük değerler için -1, 0'dan büyük değerler için 1 değerini alır. 0 değeri için ise, değer 0'dır.</p> |
| <p>Özdeşlik Fonksiyonu:</p> <p>$f(x) = x$ şeklinde ifade edilen fonksiyondur.</p> |  | <p>$f(x) = x$ şeklinde ifade edilebilen fonksiyondur.</p> |

Günümüzde, aktivasyon fonksiyonu türlerinden sigmoid fonksiyonu sıklıkla kullanılmaktadır.

Çıktı: Aktivasyon fonksiyonundan sonra oluşan değer sinir ağı hücresinin çıktı değeri olmaktadır. Bu oluşan değer, istenirse tekrar bir hücreye bağlanabilir ya da çıktı değeri olarak kullanılabilir. Yapay Sinir Ağları hücrelerinin birden fazla girdi değeri olmasına rağmen, yalnızca bir çıktı değeri olmaktadır.

2.1.4. Yapay Sinir Ağları'nın Yapısı

Yapay sinir hücrelerinin birbirine bağlanması sonucu yapay sinir ağları oluşur. Pek çok Yapay Sinir Ağı modeli üç ana katmanda incelenebilir: Giriş Katmanı, Ara (Gizli) Katman(lar) ve Çıkış Katmanı (Şekil 2.4).



Şekil 2.4: Yapay Sinir Ağının Yapısı

Katmanların açıklaması aşağıdaki gibidir:

Giriş Katmanı: Giriş katmanı, sinir ağına girdilerin geldiği katmandır. Her girdinin eşleşebileceği kadar hücre sayısı vardır. Girdiler bu katmanda herhangi bir işleme uğramadan alt katmanlara iletilir.

Ara (Gizli) Katman(lar): Giriş katmanından iletilen girdiler bu katmana gelir. Ara katman sayısı ağı tasarımına göre değişebilir. Bazı sinir ağlarında hiç ara katman bulunmazken, bazılarında birden çok katman olabilir. Her katmandaki hücre sayısı birbirinden farklı olabilir. Ara katman(lar)daki katman sayısındaki artış hesaplama karmaşıklığının ve problem çözüm süresinin artmasına neden olmasına rağmen, Yapay Sinir Ağları hala karmaşık problemlerin çözümünde kullanılmaktadır.

Çıkış Katmanı: Ara katman(lar)dan gelen bilgileri işleyerek ağa çıktı değeri üreten katmandır. Elde edilen bu değer, net çıkış değeri olarak kullanılır. Geri beslemeli ağlarda, üretilen çıkış değeri, başka bir ağın girdisi olarak sisteme geri döner. Eğitim için hazırlanan veri seti giriş katmanına gönderilir. Ağ, varsa, ara katman(lar)a öğrendiği bilgilerin ağırlıklarını atar. Ağ yapısına göre, bağlantı noktalarının değerleri olmayabilir ya da bu değer sıfır olabilir. Bağlantı noktalarına sıfır olarak atanan değerlerin çıkış değerini direkt olarak sıfırlaması için

katmanlar arasına bir eşik değeri eklenmektedir. Ağın test aşamasında ise, farklı bir test seti ağa gösterilerek, ağın bu test setinin her durumu için bir çıktı değeri vermesi sağlanır. Bu çıktı değerleri yorumlanarak net sonuçlar elde edilir.

2.1.5. Yapay Sinir Ağları'nın Sınıflandırılması


Yapay Sinir Ağları; yapılarına, öğrenme algoritmalarına göre ve öğrenme zamanına göre olmak üzere üç sınıfta incelenebilir.

2.1.5.1. Yapılarına Göre Yapay Sinir Ağları

Yapay Sinir Ağları içerdiği nöronların bağlantı şekillerine göre ileri ve geri beslemeli olmak üzere ikiye ayrılır:

İleri Beslemeli Yapay Sinir Ağları:

İleri beslemeli ağlarda, nöronlar giriş katmanından çıkış katmanına doğru sıralı olarak dizilmişlerdir. Bir katmandan yalnızca kendinden sonraki katmana geçiş yapılabilir. Giriş katmanından gelen veriler sırayla, varsa, ara katmanlardan geçerek çıkış katmanında işlenir ve daha sonra dış dünyaya çıkmış olur (Şekil 2.5).




Şekil 2.5: İleri Beslemeli Yapay Sinir Ağları

Görüldüğü gibi, İleri Beslemeli Yapay Sinir Ağı modelinde, her hücrenin çıkış değeri, ancak kendinden sonraki katmanın giriş değeri olabilir.

Geri Beslemeli Yapay Sinir Ağları:

Geri beslemeli yapay sinir ağlarında, çıktı değeri direkt olarak dış dünyaya verilmez ya aynı katmanda ya da kendinden önceki katmanlara girdi olarak tekrar gönderilir. Bağlanış şekillerine göre farklı yapıda ve davranışta oluşabilir (Şekil 2.6).



Şekil 2.6: Geri Beslemeli Yapay Sinir Ağları

Görüldüğü gibi, Geri Beslemeli Yapay Sinir Ağı modelinde, hücrelerin çıkış değeri, kimi zaman kendinden sonraki katmanın giriş değeri olabilirken bazen kendinden önceki hücrelerin giriş değeri de olabilir.

2.1.5.2. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

Yapay Sinir Ağları'nda, sisteme verilen girdilerden sonra çıktı alınabilmesi için ağın öğrenebilmesi gerekir. Birden fazla öğrenme yöntemi vardır. Bu yöntemler, algoritmalarına göre danışmalı, danışmansız ve destekleyici öğrenme olmak üzere üçe ayrılır.

Danışmanlı Öğrenen Yapay Sinir Ağları:

Danışmanlı öğrenme, ağa giriş değerlerinin yanı sıra çıkış değerleri de verilir. Ağ verilen girdilere göre istenen çıktıyı oluşturabilmek için ağırlık değerlerini atar. Ağın oluşturduğu çıktı ile istenen çıktı değeri arasındaki hata hesaplanarak, yeni ağırlıklar bu hata payına göre tekrar düzenlenir. Hata payını hesaplamak için, ağın oluşturduğu bütün çıkış değerleri ile istenen çıkış değerleri arasındaki fark hesaplanır ve bu farka göre her hücreye düşen hata payı bulunur. Her hücreye ait ağırlık değerleri tekrar güncellenerek işlem devam eder. Bir öğretmenin öğrencilere ders anlatması bunun bir örneğidir. Öğretmen, öğrencilere ders anlatır ve onların anlamalarını sağlar. Öğrenciler anlamadıkları kısımları sorar ve öğretmen tekrar anlatır. Böylece öğrenciler, bir öğretmen yardımıyla konuyu anlamış olurlar.

Danışmansız Öğrenen Yapay Sinir Ağları:

Danışmansız öğrenmede, ağa öğrenme sürecinde sadece örnek girdiler verilir. Ağa, beklenen çıktı değeri verilmez. Girdi olarak verilen değerlere göre ağ, her örneği kendi arasında sınıflandırarak kendi kurallarını oluşturur. Ağ ağırlık değerlerini aynı özellikteki hücreleri ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlar.

Örneğin, 50 kişilik bir sınıf kız öğrenciler ve erkek öğrenciler olacak şekilde ayrılmak istendiğini varsayalım. Girdi olarak verilen değerler; boy, kilo, saç rengi ve göz rengi olsun. Sisteme ilk gelen kişiyi bir sınıf olarak kabul edecek ve ardından girilen tüm girdileri buna benzeyip benzememe açısından ayırt edecektir. Yapay Sinir Ağı, en son durumda öğrenmesini tamamlayacak ve 1.girdiye benzeyenler ve benzemeyenler şeklinde iki sınıfa ayırmış olacaktır. Böylece, sisteme sadece girdiler öğretilerek bir çıkış elde edilmiş olur.

Destekleyici Öğrenen Yapay Sinir Ağları:

Destekleyici öğrenmede, ağın her döngüsü için elde edilen sonucun iyi ya da kötü olduğuna dair bilgi verilir. Gelen bilgi sonucu ağ kendini yeniden düzenler. Bu öğrenme şeklinde ağ hem öğrenerek hem de sonuç çıkararak devam eder.

Örnek olarak, satranç oynayan bir Yapay Sinir Ağı, yaptığı hamlelerin iyi ya da kötü olduğunu fark edememesine rağmen oynamaya devam eder. Eğer, oyunun sonunda, program oyunu kazanırsa, yaptığı hamlelerin iyi olduğunu anlar ve bunları öğrenir. Tekrar oynadığında, iyi hamleleri üzerinden hareket edecektir.

2.1.5.3. Öğrenme Zamanına Göre Yapay Sinir Ağları

Yapay Sinir Ağları'nın öğrenmesi, öğrenme zamanına göre statik öğrenen ve dinamik öğrenen olmak üzere ikiye ayrılır.

Statik Öğrenen Yapay Sinir Ağları:

Statik öğrenme kuralında, Yapay Sinir Ağları kullanılmadan önce eğitilmektedir. Eğitim bittikten sonra, ağ istenilen şekilde kullanılabilir. Fakat ağ değerleri sabitlenmiş olduğu için, ağın ağırlık değerlerinde herhangi bir değişiklik olmamaktadır.

Dinamik Öğrenen Yapay Sinir Ağları:

Dinamik öğrenme kuralında ise, Yapay Sinir Ağları'nın çalıştığı süre boyunca öğrenmesi devam eder. Öğrenme aşaması bittikten sonra da, gerek duyulduğunda ağırlık değerlerini değiştirerek çalışmaya devam edebilir.

2.1.6. Yapay Sinir Ağı Modelleri

Bu bölümde, uygulamalarda sıkça kullanılan ve literatürde yaygın bir şekilde yer alan Hopfield Yapay Sinir Ağı, Çağrışımlı Bellek Ağları, Cohen – Grossberg Yapay Sinir Ağı ve Hüresel Yapay Sinir Ağları hakkında kısaca bilgi verilmiştir.

Hopfield Yapay Sinir Ağı Modeli

1980'li yılların başında geliştirilen Hopfield Yapay Sinir Ağı Modeli, Yapay Sinir Ağları'nın temeli olarak kabul edilmektedir. Hopfield, dinamik bir model olan bu yapay sinir ağı için pozitif değerler alan bir Lyapunov fonksiyonu önermiştir [2]. Bu fonksiyon Yapay Sinir Ağları'nda simetrik bağlantı matrislerinin varlığı koşuluna dayanmaktadır. Hopfield, bu fonksiyonun zamana bağlı türevinin negatif olduğunu göstermiştir. Bu durum, sistemin global kararlı olduğunu göstermektedir. Simetrik bağlantı matrisinin kullanılması, sistemin global kararlılığını garantilemesine rağmen, denge noktasının tek ya da birden fazla olması konusunda yorum yapılamadığı görülmektedir. Bu yorumun yapılabilmesi için aktivasyon fonksiyonlarının karakteristiği ve nöronlar arasındaki bağlantı katsayılarının değerleri hakkında fikir sahibi olunmalıdır. Modelde gecikme olması, bu modelin dinamik davranışında önemli değişikliklere neden olmaktadır. Bu gecikmeli model; nöronlar, bir işlemsel kuvvetlendirici ve ona bağlı direnç ve kapasite elemanları ile oluşturulan bir devre ile modellenmektedir. Dinamik Yapay Sinir Ağı modelleri örneklerin sınıflandırılması, optimizasyon ya da çağrışımlı bellekler gibi uygulamalarda başarılı bir şekilde uygulanmaktadır.

Yukarıda genel tanımı ve kullanım alanları verilen Hopfield Yapay Sinir Ağı modelinin dinamik denklemi (2.1)' de tanımlandığı gibidir:

$$\frac{du_i(t)}{dt} = -a_i u_i(t) + \sum_{j=1}^n w_{ij} g_j(u_j(t)) + I_i, \quad i = 1, 2, \dots, n \quad (2.1)$$

$$\frac{du_i(t)}{dt} = -Au(t) + W_0 g(u(t)) + I \quad (2.2)$$

Verilen denklemlerde,

- $u = (u_1, u_2, \dots, u_n)^T$ nöron durum vektörünü,
- $A = \text{diag}(a_i)$ pozitif diyagonal matrisini,
- $W_0 = (\omega_{ij})_{n \times n}$ nöronların ağırlık katsayılarını teşkil eden bağlantı matrisini,
- $I = (I_1, I_2, \dots, I_n)^T$ dış giriş vektörünü,
- $g(u) = (g_1(u_1), g_2(u_2), \dots, g_n(u_n))^T$ nöron aktivasyon fonksiyonlarını göstermektedir.

Yapay Sinir Ağları'nın pek çok kullanımında, nöronlar arasında gecikmeler olduğu tespit edilmiştir. Bu açıdan, Yapay Sinir Ağı modelleri çeşitli gecikmeler ile temsil edilmektedir. Bu gecikmelerin bulunduğu modeller aşağıda ifade edilmeye çalışılmıştır.

(2.1) modelinde tüm nöronların arasındaki gecikmenin sabit olduğu varsayıldığında ve bu sabit gecikme τ olarak ifade edildiğinde, model (2.3)'e dönüşür [3].

$$\frac{du_i(t)}{dt} = -a_i u_i(t) + \sum_{j=1}^n \omega_{ij} g_j(u_j(t - \tau)) + I_i, \quad \forall i \quad (2.3)$$

(2.1) modelinde tüm nöronların arasındaki gecikmenin farklı olduğu varsayıldığında ve bu gecikmeler τ_{ij} olarak ifade edildiğinde, model (2.4)'e dönüşür [4-5].

$$\frac{du_i(t)}{dt} = -a_i u_i(t) + \sum_{j=1}^n \omega_{ij} g_j(u_j(t - \tau_{ij})) + I_i, \quad \forall i \quad (2.4)$$

[6]'da, (2.5)'te verilen durum denklemiyle tanımlanan gecikmeli hücresel sinir ağları denilen, yeni bir gecikmeli yapay sinir ağı modeli ortaya atılmıştır:

$$\frac{du_i(t)}{dt} = -a_i u_i(t) + \sum_{j=1}^n \omega_{ij} g_j(u_j(t - \tau_{ij})) + I_i, \quad \forall i \quad (2.5)$$

[7]'de, bir hücresel sinir ağı çeşidi olan hibrit sinir ağı modeli ve Hopfield yapay sinir ağı modelini genelleştiren, geciktirilmiş fonksiyonel denklemlerin sinir sistemine çalışılmıştır. Ortaya konulan model (2.6)'daki gibidir:

$$\frac{du_i(t)}{dt} = -a_i u_i(t) + \sum_{j=1}^n \omega_{ij}^0 g_j(u_j(t)) + \sum_{j=1}^n \omega_{ij}^1 g_j(u_j(t - \tau_{ij})) + I_i, \quad \forall i \quad (2.6)$$

[2-6]'da verilen Yapay Sinir Ağı modelleri bazı optimizasyon problemlerinin çözümü, çağrışımlı bellek tasarımı ve paralel hesaplama konularında ilgi çekmiştir. Bu tip mühendislik uygulamaları, tasarlanacak sinir ağının dinamik davranışının analizine bağlıdır. [8]'deki

çalışmada, (2.6) genişletilerek, gecikme parametrelerinin zamana bağlı durumu ele alınmıştır. [8]'de ele alınan Yapay Sinir Ağı modeli (2.7)'deki gibidir:

$$\frac{du(t)}{dt} = -Au(t) + W_0g(u(t)) + W_1g(u(t - \tau(t))) + I \quad (2.7)$$

Burada,

- $\tau(t)$ iletim gecikmesini,
- $W_0 = (\omega_{ij}^0)_{n \times n}$ ve $W_1 = (\omega_{ij}^1)_{n \times n}$ nöronların ağırlık katsayılarını temsil eden bağlantı matrislerini göstermektedir.

Cohen – Grossberg Yapay Sinir Ağı Modeli

Cohen – Grossberg Yapay Sinir Ağı modelleri, ilk olarak 1983 yılında öne sürülmüş, optimizasyon problemlerinin çözümünde, bilimsel alanlarda ve hesaplama teknolojisinde, analog – dijital dönüştürücü tasarımı gibi çeşitli mühendislik alanlarında yaygın bir biçimde kullanılmıştır. Bu tür uygulamalarda, tasarlanan Yapay Sinir Ağları'nın kararlılığının belirlenmesi oldukça önemlidir. Bu Yapay Sinir Ağı türünde de, sisteme dışarıdan verilen her giriş vektörü için, oluşturulan Yapay Sinir Ağı'nın global asimptotik kararlı tek bir denge noktasına sahip olması gerekmektedir. Cohen – Grossberg Yapay Sinir Ağı modelinin en genel hali şu şekilde tanımlanabilir:

$$\frac{dx_i(t)}{dt} = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij}f_j(x_j(t)) + u_i \right], \quad i = 1, 2, \dots, n \quad (2.8)$$

(2.8)' da verilen modelde,

- $x = (x_1, x_2, \dots, x_n)^T$ nöron durum vektörünü,
- $d_i(x_i(t))$ kuvvetlendirici fonksiyonunu,
- $c_i(x_i(t))$ davranış fonksiyonunu,
- a_{ij} nöronların katsayılarını temsil eden bağlantı matrisini,
- $f(x) = (f_1(x_1), f_2(x_2), \dots, f_n(x_n))^T$ nöron aktivasyonlarını,
- $u = (u_1, u_2, \dots, u_n)^T$ de giriş vektörünü göstermektedir.

Cohen – Grossberg Yapay Sinir Ağı modelinde, $d_i(x_i(t))$ ifadesi yakınsama hızı için kullanılan bir kontrol parametresidir. Modelin denge noktası üzerinde bir etkisi yoktur. Davranış

fonksiyonu olan $c_i(x_i(t))$ ise, sistemin kararlı çözümlerinin durum uzayında uygun yerlere konulmasını sağlar. Bu şekilde denge noktalarını optimize ederek sistemin davranışını etkiler. (2.8) ile verilen diferansiyel eşitlik, vektör – matris formunda aşağıdaki şekilde yazılabilir.

$$\frac{dx(t)}{dt} = D(x(t))[-C(x(t)) + Af(x(t)) + u] \quad (2.9)$$

Hopfield modeli ve Hücresel Yapay Sinir Ağları modelleri, Cohen – Grossberg Yapay Sinir Ağları'nın özelleşmiş birer formudur. Bu sebeple, Cohen – Grossberg Yapay Sinir Ağı modelinde, kuvvetlendirici fonksiyon $D(x(t)) \equiv 1$ ve D pozitif bir sabit olmak üzere, davranış fonksiyonu da $C(x(t)) = Dx(t)$ alındığında, bu modelden Hopfield ve Hücresel Yapay Sinir Ağları gibi diğer yapay sinir ağı modelleri de elde edilebilir. (2.9)' da verilen modelde, sistemde gecikme olması durumunda model, en genel haliyle aşağıdaki gibi ifade edilebilir:

$$\frac{dx_i(t)}{dt} = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau_{ij})) + u_i \right], \forall i \quad (2.10)$$

Bu modelde, $\tau = \max(\tau_{ij})$, $1 \leq j \leq n$ olmak üzere,

- $\tau_{ij} \geq 0$, gecikme parametresini,
- b_{ij} ise, sistemde τ_{ij} olması durumunda ağ içerisindeki nöronların ağırlık katsayılarını gösteren bağlantı matrisini göstermektedir.

$\tau_{ij} = \tau_j$ olması durumunda (2.10)'de verilen Yapay Sinir Ağı modeli aşağıdaki şekilde yazılabilir:

$$\frac{dx_i(t)}{dt} = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau_j)) + u_i \right], \forall i \quad (2.11)$$

Cohen – Grossberg Yapay Sinir Ağı modelinde, birçok durumda gecikmeler zamanla değişmektedir. Gecikmesi zamanla değişen Cohen – Grossberg Yapay Sinir Ağları aşağıdaki şekilde ifade edilebilir:

$$\frac{dx_i(t)}{dt} = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau_j(t))) + u_i \right], \forall i \quad (2.12)$$

(2.12) eşitliğinde, $\tau = \max(\tau_j(t))$, $1 \leq j \leq n$ olmak üzere, $\tau_j(t) \geq 0$, zamanla değişen gecikme parametresini göstermektedir.

Çift Yönlü Çağrışımlı Bellek Yapay Sinir Ağı Modeli (ÇBA)

Çağrışımlı sistemler, belirli giriş vektörleri ile belirli çıkış vektörleri arasında ilişki kurabilen sistemlerdir. Çağrışımlı bellek ağlarının, eğitim süresince kendilerine verilen örnekleri daha sonra hatırlaması gerektiği için, bu örnekleri ezberler ya da saklar. Çağrışımlı bellek ağları, genellikle örüntü tanıma ve eksik verilerden doğru verileri tahmin edip tamamlama gibi uygulamalarda sıklıkla kullanılmaktadır.

Yapay Sinir Ağı'nın en önemli sınıflarından biri olan Çağrışımlı Bellek Ağları (Bidirectional Associative Memory – BAM) [9]'da anlatılmakta ve en genel dinamik denklemi aşağıdaki şekilde ifade edilmektedir:


$$\begin{aligned} \dot{u}_i(t) &= -a_i u_i(t) + \sum_{j=1}^m \omega_{ij}^T g_j(z_j(t - \tau_{ij})) + I_i, & \forall i \\ \dot{z}_j(t) &= -b_j z_j(t) + \sum_{i=1}^n v_{ji}^T g_i(u_i(t - \sigma_{ji})) + J_j, & \forall j \end{aligned} \quad (2.13)$$

(2.13)'teki kavramlara bakılacak olursa;

- $u_i(t)$ ve $z_j(t)$: nöron durumları,
- a_i ve b_j : nöron yüklenme zamanı sabitleri ve pasif bozulma hızları,
- ω_{ij}^T ve v_{ji}^T : sinaptik bağlantıların dayanıklılığı,
- $\tau_{ij} > 0$ ve $\sigma_{ji} > 0$: işaretlerin nöral olarak işlenmesi ve aksonal geçişi için gerekli olan ortalama zaman gecikmesi,
- $g_i(\cdot)$ ve $g_j(\cdot)$: bazı lineer olmayan aktivasyon fonksiyonları,
- I_i ve J_j : dış girişler'dir.

Hücresel Yapay Sinir Ağı Modeli (HSA)

Hücresel Yapay Sinir Ağları (Cellular Neural Networks – CNN) ilk olarak 1988 yılında Leon O. Chua ve Lin Yang tarafından ortaya atılmıştır. Hücresel Yapay Sinir Ağları, birbirine bağlı ve çoğunlukla iki boyutlu hücrelerden meydana gelmişlerdir. Bu yapıyı diğer modellerden ayıran en önemli özelliği, bağlantı ağırlık katsayılarının çalışılan düzlem üzerinde değişmez bir bağlantı ağı oluşturmasıdır. Hücresel Yapay Sinir Ağları, Yapay Sinir Ağları'nın bilinen özelliklerini taşırlar ve buna ek olarak, iki boyutlu yapıları sebebiyle, görüntü işleme ve örüntü tanıma gibi konularda sıklıkla kullanılmaktadır. Hücresel Yapay Sinir Ağları'na ait diğer bir önemli özellik ise, sadece bağlı oldukları komşuları ile iletişim halinde bulunan hücre yapısına sahip olmalarıdır. Tüm hücreler birbiriyle bağlantılı olmayıp, sadece bağlantılı komşuları ile doğrudan, diğer hücreler ile dolaylı olarak bağlantılı olması, Hücresel Yapay Sinir Ağları'nın yapısının karmaşıklığını azaltmakta ve enerji tüketimini düşürmektedir. Şekil 2.7'de, 3x3'lük örnek bir Hücresel Yapay Sinir Ağı mimarisi verilmiştir.



Şekil 2.7: 3x3 boyutunda Hücresel Sinir Ağı Mimarisi

Bu şekilde verilen HSA 3x3 matris boyutunda satır ve sütunlardan meydana gelmiştir. Her hücrenin doğrudan bağlı olan komşuları olmakla birlikte, dolaylı olarak diğer komşularıyla da iletişim halindedir.

Aşağıda, Hücresel Yapay Sinir Ağı modeline ait genel bir diferansiyel denklem verilmiştir:

$$C \frac{dx_{ij}(t)}{dt} = -\frac{1}{R_x} x_{ij}(t) + \sum_{C(k,l) \in S_r(i,j)} A(i,j) y_{kl}(t) y_{kl}(t) + \sum_{C(k,l) \in S_r(i,j)} B(i,j; k,l) u_{kl} + I_{ij} \quad (2.14)$$

$$y_{ij} = f(x_{ij}) = \frac{1}{2} (|x_{ij} + 1| - |x_{ij} - 1|)$$

Burada,

- $x_{ij} \in \mathbb{R}$; $C(i,j)$ hücrenin durumu,
- $y_{kl} \in \mathbb{R}$; etki küresi içerisindeki hücrelerin çıkışı,
- $u_{kl} \in \mathbb{R}$; etki küresi içerisindeki hücrelerin girişleri,
- $I_{ij} \in \mathbb{R}$; eşik değeri veya hücre akımı,
- $A(i,j; k,l)$; geri besleme operatörü,
- $B(i,j; k,l)$; giriş (kontrol) operatörü,
- Çıkış fonksiyonu y_{ij} , lineer olmayan ve hücrenin çıkışını tanımlayan karakteristik parçalı (piece – wise) bir fonksiyondur.

Bu tezin asıl konusunu oluşturan Nötral Tipteki Yapay Sinir Ağları 4. bölümde açıklanmıştır.

3. MALZEME VE YÖNTEM

Bu bölümde, Yapay Sinir Ağları'nın kararlılık analizinde genel olarak kullanılan matris sınıfları ve özellikleri, normlar ve literatürde sıklıkla kullanılan bazı teoremler ele alınacaktır.

3.1. VEKTÖR VE MATRİS NORMLARI

Öklid Uzayı

Öklid Uzayı, Yapay Sinir Ağları'nın kararlılık analizlerinde, matematiksel işlemlerde kullanılmaktadır. n -boyutlu vektörlerin kümesi $v = [v_1, v_2, \dots, v_n]^T$ şeklinde ifade edilmektedir. v_1, v_2, \dots, v_n olarak gösterilen sayılar reel sayılardır ve n -boyutlu Öklid Uzayı olarak tanımlanmaktadır. R^n şeklinde gösterilirler. Tüm reel sayıları kapsayan tek-boyutlu Öklid Uzayı R ile gösterilir. R^n 'deki vektörler toplanabilir ya da bir skaler değerle çarpılabilir.

Vektör Normları

Vektör normları, Yapay Sinir Ağları'nın kararlılık analizlerinde, matematiksel işlemlerde kullanılmaktadır. Bir $y = [y_1, y_2, \dots, y_n]^T$ vektörünün normu $\|y\|$ şeklinde gösterilir ve değeri reel bir sayı olan norm, aşağıdaki özellikleri sağlayan bir fonksiyondur.

- $\|y\| \geq 0 \quad \forall y \in R^n$, ve $\|y\| = 0$ sadece $y = 0$ için
- $\|y+z\| \leq \|y\| + \|z\|, \quad \forall y, z \in R^n$
- $\|\alpha y\| = |\alpha| \|y\|, \quad \forall \alpha \in R$ ve $y \in R^n$

p -normların sınıfı şu şekildedir:

$$\|y\|_p = (|y_1|^p + \dots + |y_n|^p)^{1/p}, \quad 1 \leq p < \infty$$

Sıklıkla kullanılan 3 Öklid normu; $\|y\|_1, \|y\|_2, \|y\|_\infty$ dir.

$$\|y\|_1 = (|y_1| + \dots + |y_n|) = \sum_{i=1}^n |y_i|$$

$$\|y\|_2 = (|y_1|^2 + \dots + |y_n|^2)^{1/2} = (y^T y)^{1/2}$$

$$\|y\|_\infty = \max_i |y_i|$$

Eğer $\|\cdot\|_\alpha$ ve $\|\cdot\|_\beta$ iki farklı p-normu olmak üzere, $\forall y \in \mathbb{R}^n$ için aşağıdaki şartı sağlayan c_1 ve c_2 sabit sayıları vardır.

$$c_1 \|y\|_\alpha \leq \|y\|_\beta \leq c_2 \|y\|_\alpha$$

Bu sebeple, tüm p-normları eşittir.

Hölder Eşitsizliği:

p-normları için kullanılan diğer bir eşitsizlik ‘‘Hölder Eşitsizliği’’dir ve aşağıdaki gibi ifade edilir.

$$|y^T z| \leq \|y\|_p \|z\|_q, \quad \frac{1}{p} + \frac{1}{q} = 1, \quad \forall y \in \mathbb{R}^n, z \in \mathbb{R}^n \text{ için,}$$

Genelde normlar kullanıldığında, sadece herhangi bir norm tarafından sağlanan 3 temel özellikten çıkarılan sonuçların özellikleri kullanılır. Bu gibi durumlarda p indisi, normun herhangi bir p formu olabileceği belirtilerek düşünülür.

Matris Normları

Reel elemanlı ve $m \times n$ boyutlu bir A matrisinin p-normu şu şekilde tanımlanır:

$$\bullet \quad \|A\|_p = \sup_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p} = \max_{\|x\|_p=1} \|Ax\|_p$$

$A = (a_{ij})_{n \times n}$ matrisinin $p = 1, 2, \infty$ normları şu şekilde ifade edilebilir:

- $\|A\|_1 = \max_j \sum_{i=1}^m |a_{ij}|$
- $\|A\|_2 = [\lambda_{\max}(A^T A)]^{1/2}$
- $\|A\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$

3.2. MATRİS SINIFLARI

Matris sınıfları, Yapay Sinir Ağları'nın kararlılık analizlerinde, matematiksel işlemlerde kullanılmaktadır.

- Pozitif tanımlı matris: $n \times n$ boyutlu simetrik bir P matrisinin bütün özdeğerleri sıfırdan büyük ise, bu matris $P > 0$ şeklinde gösterilir ve pozitif tanımlı olarak adlandırılır.

- Pozitif yarıtanımlı matris: $n \times n$ boyutlu simetrik bir P matrisinin bazı özdeğerleri sıfırdan büyük ve diğer özdeğerleri sıfıra eşit ise, bu P matrisi pozitif yarıtanımlı bir matristir ve $P \geq 0$ ifadesi ile gösterilir.
- Pozitif kararlı matris: $n \times n$ boyutlu bir P matrisinin bütün özdeğerlerinin gerçel kısmı sıfırdan büyük ise, bu P matrisi pozitif kararlı bir matristir. Bu özellikteki matrisler aynı zamanda “H - kararlı matris” olarak isimlendirilir ve $P \in H$ ifadesi ile gösterilir.
- Pozitif yarıkararlı matris: $n \times n$ boyutlu bir P matrisinin bazı özdeğerlerinin gerçel kısmı sıfırdan büyük ve diğer özdeğerlerinin gerçel kısmı sıfıra eşit ise, bu P matrisi pozitif yarıkararlı bir matristir. Bu özellikteki matrisler aynı zamanda “ H_0 kararlı matris” olarak isimlendirilir ve $P \in H_0$ ifadesi ile gösterilir.
- Herhangi bir $P = \{p_{ij}\}$ matrisine ait elemanlar $p_{ij} \geq 0$ ve $p_{ij} \leq 0$ olacak şekilde seçilmiş olsun. Bu özellikteki bir P matrisi Z_n kümesinin bir elemanı olarak nitelendirilir ve $P \in Z_n$ olarak gösterilir.
- Tekil olmayan M-matrisi: P matrisi Z_n kümesine ait bir eleman olsun. Eğer P matrisi pozitif kararlı bir matris ise, P matrisi Tekil olmayan M – matris olarak isimlendirilir ve $P \in K$ ifadesi ile gösterilir.
- M-matrisi: P matrisi Z_n kümesine ait bir eleman olsun. Bu matris, aynı zamanda pozitif yarıkararlı bir matris ise, P matrisi M-matris olarak tanımlanır ve $P \in K_0$ şeklinde gösterilir.
- Kıyas matrisi: $n \times n$ boyutunda herhangi bir P matrisinin kıyas matrisi C matrisi olsun. $C = \{c_{ij}\}$ olarak ifade edilir ve $c_{ii} = p_{ii}$, $c_{ij} = -|p_{ij}|$ olarak tanımlanır.
- Tekil olmayan \mathcal{H} -matris: Herhangi bir P matrisi için köşegen elemanları $a_{ii} > 0$ verilmiş olsun. Eğer P matrisinin kıyas matrisi olan C , tekil olmayan M – matris ise, bu koşulda P matrisine Tekil olmayan H - matris denir ve $A \in C$ ile ifade edilir.
- \mathcal{H} -matris: Herhangi bir P matrisi için köşegen elemanları $a_{ii} > 0$ verilmiş olsun. Eğer P matrisinin kıyas matrisi olan C , M-matris ise, P matrisi H- matris olarak adlandırılır ve $A \in C_0$ olarak gösterilir.

- Kesin köşegen satır baskın matris: P matrisi, $n \times n$ boyutlu bir matris olsun. Eğer P matrisine ait elemanlar aşağıdaki eşitsizliği sağlıyorsa bu P matrisine, kesin köşegen satır baskın matris denir.

$$p_{ii} > \sum_{\substack{j=1 \\ j \neq i}}^n |p_{ij}|, \quad i = 1, \dots, n$$

- Köşegen satır baskın matris: P matrisi, $n \times n$ boyutlu bir matris olsun. Eğer P matrisine ait elemanlar aşağıdaki eşitsizliği sağlıyorsa bu P matrisine, köşegen satır baskın matris denir.

$$p_{ii} \geq \sum_{\substack{j=1 \\ j \neq i}}^n |p_{ij}|, \quad i = 1, \dots, n$$

- Kesin köşegen sütun baskın matris: P matrisi, $n \times n$ boyutlu bir matris olsun. Eğer P matrisine ait elemanlar aşağıdaki eşitsizliği sağlıyorsa bu P matrisine, kesin köşegen sütun baskın matris denir.

$$p_{ii} > \sum_{\substack{j=1 \\ j \neq i}}^n |p_{ji}|, \quad i = 1, \dots, n$$

- Köşegen sütun baskın matris: P matrisi, $n \times n$ boyutlu bir matris olsun. Eğer P matrisine ait elemanlar aşağıdaki eşitsizliği sağlıyorsa bu P matrisine, köşegen sütun baskın matris denir.

$$p_{ii} \geq \sum_{\substack{j=1 \\ j \neq i}}^n |p_{ji}|, \quad i = 1, \dots, n$$

Matris sınıflarına ait bazı özellikler aşağıdaki şekilde ifade edilmektedir:

- Sabit tanımlı matris: Eğer P matrisi C_0 ait bir eleman ise, yani $P \in C_0$, $\alpha > 0$ olması şartıyla, $\alpha I + P \in C$ olan bir α sabiti tanımlıdır.
- Z_n kümesinde yer alan bir matrisin kıyas matrisi kendisine eşit olduğundan K_0 kümesi C_0 kümesinin bir alt kümesidir.

- $n \times n$ boyutunda olan bir P matrisinin köşegen elemanları pozitif sayılar olsun. Eğer P matrisinin kıyas matrisi tekil olmayan M -matrisi ise,

$$d_i a_{ii} > \sum_{\substack{j=1 \\ j \neq i}}^n d_j |a_{ji}|, \quad i = 1, \dots, n$$

eşitsizliğini sağlayan pozitif $d_i, i = 1, \dots, n$ katsayıları mevcuttur.

3.3. KARARLILIK TEOREMLERİ

Bu kısımda, öncelikle kararlılık kavramı üzerinde durulmuş olup, global kararlılık, üstel kararlılık ve robust kararlılık gibi kararlılık çeşitleri hakkında genel bilgiler verilmiştir. Yapay Sınır Ağları'nın kararlılık analizinde kullanılan Lyapunov Kararlılık Teoremi, Hurwitz Kararlılık Teoremi ve LaSalle'nin Değişmezlik İlkesi ele alınmıştır.

Kararlılık Kavramı

Daha önceki kısımlarda belirtildiği gibi kullanılan uygulama türlerine göre Yapay Sınır Ağları'nın sahip olması gereken kararlılık özellikleri de çeşitlilik göstermektedir. Yapay Sınır Ağları'ndaki anlamı ve genel tanımı olarak, "kararlı bir sistem, denge konumuna geçmeye eğilimli ya da denge durumundaki sistem"dir. Dış etmenler, sistemin kararlı olma durumunu etkilemezken, sistemin denge durumuna geçme süresinin uzamasına neden olabilir. Teoride, genellikle kararlı konuma geçmiş bir sistemin, tekrar kararsız hale geçmeyeceği kabul edilmektedir. Bir sistemin kararlı olması, o sistemin en az bir denge noktasına sahip olması anlamına gelmektedir. Sistemin özelliklerine göre ya da kullanılan uygulamaya göre denge noktasının sayısı ve kararlılık türü değişebilmektedir. Yapay Sınır Ağları için geçerli olan denge noktası kavramı ve kararlılık çeşitleri aşağıda verilmiştir:

Denge Noktası:

Her $t \geq t_0$ için $f(x_e, t) = 0$ şartını sağlıyorsa, bu durumda x_e için $\dot{x} = f(x, t), x(t_0) = x_0$ sisteminin denge noktasıdır, denir.

Kararlılık:

Dinamik bir sistemin belli bir denge noktasının kararlı olması, diğer yörüngelerin ise bu noktanın belli komşuluğunda kalması olarak ifade edilmektedir.

Asimptotik Kararlılık:

Asimptotik kararlılık, kararlılık durumuna ek olarak denge noktasının, komşuluğunda olan diğer yörüngeler ile uzun bir zaman limitinde bir çekim etkisine sahip olma durumu şeklinde ifade edilebilir. Bir sistemin denge noktası, yerel veya global asimptotik kararlı ise bu denge noktası, sistemin tek denge noktasıdır. Bu sebeple, birden fazla denge noktasına sahip olan sistemler, asimptotik kararlı olma şartını sağlamazlar.

Üstel Kararlılık:

Bir x_e denge noktası, bir V komşuluğuna sahipse ve her $x(0) \in V$ için $t \rightarrow \infty$ a giderken $|x(t) - x_e| < e^{-at}$, yi sağlayan bir pozitif a sayısı bulunabiliyorsa, sistem üstel kararlıdır. Ayrıca, üstel kararlı sistemler, asimptotik kararlı ve dolayısıyla da kararlıdır.

Global Kararlılık:

Doğrusallaştırma teoremi, doğrusal olmayan bir sistemin denge noktasındaki davranışlarının çoğu durumda doğrusal sisteme benzediğini göstermektedir. Ancak, doğrusallaştırma işlemi basit düzeyde değil ise sağlıklı sonuç alınmasını engeller, sadece yerel bir bölge için gerçek sonuçları gösterebilir. Bu durum yerel kararlılık olarak adlandırılır. Yerel kararlılığa sahip olan sistemlerin yerel minimuma yaklaşan birden fazla denge noktası olabilir, bu da çoğu uygulama için istenmeyen bir durumdur. Bunun yerine, tek bir denge noktasına sahip olan ve global kararlı olan sistemler tasarlanmak istenir.

Bir sistemin, her noktadaki çözümünün doğrusal sisteme benzemesi ya da her noktada kararlı olma durumu, global kararlı olarak adlandırılır. Global kararlılık, etki alanına göre yapılan bir sınıflandırmadır. Kararlılık derecesi hakkında bilgi vermez.

Robust Kararlılık:

Sapmalardan etkilenip etkilenmeme durumu kararlılık sınıflandırmalarında bakılması gereken diğer bir konudur. Yapay Sinir Ağları'nda sistemin kararsızlığı gibi bazı durumlarda zaman gecikmelerinin olduğu görülmüştür ve daha doğru sonuçlar elde edebilmek için, modele gecikme eklenerek incelemeler yapılmıştır. Tasarlanmış sistemde, zaman gecikmesi en aza indirilse bile, dış etkenler ve model tasarımı sırasında meydana gelen hatalardan kaçınmak mümkün değildir. Dolayısıyla, zaman gecikmesi olan ağlarda, robust kararlılık durumunu da göz önünde bulundurmak gerekmektedir. Robust kararlılık, bir Yapay Sinir Ağı'nın, hiçbir

sapmadan etkilenmemesi anlamına gelmektedir. Türkçe’de güçlü ya da gürbüz anlamına gelen robust kelimesi, kararlılık kavramı ile bir arada kullanıldığında, güçlü kararlılık olarak düşünülebilir.

Sistemlerin kararlılık özelliklerinden bahsedilirken, genellikle hem kararlılık derecesi hem etki alanı hem de sapmalardan etkilenip etkilenmediği belirtilerek sınıflandırma yapılması daha uygun karşılanmaktadır. “global üstel kararlı” ya da “asimptotik robust kararlı” gibi tanımlamalar bunlardan bazılarıdır.

Lyapunov Kararlılık Teoremi:

Lyapunov Kararlılık Teoremi, denge noktasının kararlılık özellikleriyle ilgili bir sonuç çıkarmak için kullanılan ve pozitif bir enerji fonksiyonu tanımlanarak zamana bağlı türevinin incelenmesiyle denge noktasının kararlılığını karakterize edebilir. Lyapunov Kararlılık Teoremi genel olarak aşağıdaki gibi ifade edilir [10]:

$\dot{x} = f(x)$ şeklinde verilen bir sistem için denge noktası $x = 0$ olsun. $V(x): R^n \rightarrow R$, sürekli türevi alınabilen bir fonksiyon olsun. $V(x)$ fonksiyonun zamana göre türevi $\dot{V}(x)$ ile gösterilir ve aşağıda verilen (3.3) ile ifade edilir.

$$\dot{V}(x) = \sum_{i=1}^n \frac{\partial V(x)}{\partial x_i} \dot{x}_i = \sum_{i=1}^n \frac{\partial V(x)}{\partial x_i} f_i(x_i) = \frac{\partial V(x)}{\partial x} f(x) \quad (3.3)$$

- Eğer; $V(0) = 0$, $V(x) > 0$, $\forall x \neq 0$ ve $\dot{V}(x) \leq 0$, $\forall x \in R^n$ şartı sağlanıyorsa, $x=0$ için kararlıdır.
- Eğer, $\dot{V}(x) < 0$, $\forall x \neq 0$ şartı sağlanıyorsa, $x = 0$ asimptotik kararlıdır.
- Eğer, $\dot{V}(x) > 0$, $\forall x \neq 0$ şartı sağlanıyorsa, $x = 0$ kararsızdır.

Bu teoreme göre;

- $V(x)$ fonksiyonun zamana bağlı türevi negatif yarı tanımlı olan (yani, $\dot{V}(x) \leq 0$, $\forall x \neq 0$), sürekli türevi alınabilen pozitif tanımlı fonksiyon (yani, $V(x) > 0$, $\forall x \neq 0$ orijinin her komşuluğunda) bulunabilirse denge noktası kararlıdır.

- Eğer $\dot{V}(x)$ kesin negatif tanımlı (yani, $\dot{V}(x) < 0, \forall x \neq 0$) ise denge noktası asimptotik kararlıdır.
- Eğer $\dot{V}(x)$ pozitif tanımlı (yani, $\dot{V}(x) > 0, \forall x \neq 0$) ise denge noktası kararsızdır.

Bu teorem, Lyapunov Kararlılık Teoremi'nin Direkt Metodu olarak adlandırılır. Bu metodun üstünlüklerinden biri denge noktasının kararlılık özelliklerini, sisteme ait diferansiyel denklemleri çözmeden belirlememizi sağlamasıdır.

Hurwitz Kararlılık Teoremi:

Hurwitz Kararlılık Teoreminde, [10], $x = 0, \dot{x} = f(x)$ ile tanımlanmış sistemin denge noktası olsun. $\dot{x} = f(x)$ sisteminin $x = 0$ civarında doğrusallaştırılmış modeli aşağıdaki gibidir:

$$A = \left. \frac{\partial f(x)}{\partial x} \right|_{x=0}$$

Burada A, $\dot{x} = f(x)$ sisteminin Jacobian'ı olarak adlandırılır.

$\dot{x} = f(x)$ sisteminin orijini, A'nın tüm özdeğerlerinin gerçel kısmının ancak ve ancak negatif ya da sıfır olması durumunda kararlıdır. Ayrıca A'nın tüm özdeğerlerinin reel kısmı negatif ise orijin asimptotik kararlıdır. A'nın tüm özdeğerlerinin reel kısmı negatif olduğunda, A matrisine kararlılık matrisi ya da "Hurwitz Matrisi" denir. Eğer A'nın, gerçel kısmı pozitif olan en az 1 özdeğeri varsa, orijinin kararsız olacağı söylenir. Aslında yukarıdaki teoremler denge noktası için aynı asimptotik kararlılık sonucunu belirtir. Bu iki teorem arasındaki bağı bulmak için aşağıdaki Lyapunov Fonksiyonu'nun ele alındığını varsayalım.

$$V(x) = x^T P x$$

Burada P reel simetrik pozitif tanımlı matristir. Sistemin yörüngeleri boyunca V(x)'in türevi aşağıdaki Lyapunov denklemi ile verilir.

$$\dot{V}(x) = x^T [PA + A^T P] x = -x^T Q x$$

Burada Q matrisi aşağıda tanımlanmış şekilde simetrik bir matristir.

$$-Q = PA + A^T P$$

Ancak ve ancak verilmiş her pozitif tanımlı Q matrisi için Lyapunov denklemini sağlayan pozitif tanımlı bir P matrisi varsa, bu durumda A'ya "kararlılık matrisi" denir. Buradan, eğer Q pozitif tanımlı ise, Lyapunov kararlılık teoremine göre, $\dot{x} = f(x)$ ' in orijininin asimptotik kararlı olduğu sonucuna varılabilir. Yani, A'nın tüm özdeğerlerinin gerçel kısımları negatiftir.

LaSalle'nin Değişmezlik İlkesi:

LaSalle Değişmezlik İlkesi'nde, [10], $\dot{x} = f(x)$ sistemi için denge noktası $x = 0$ olsun. $V(x): D \rightarrow \mathbb{R}$, D içinde $\dot{V}(x) < 0$ şeklinde, orijinin D komşuluğunda sürekli türevi alınabilen pozitif tanımlı bir fonksiyon olsun.

$$S = \{x \in D \mid \dot{V}(x) = 0\}$$

Orijin dışında hiçbir çözümün S içinde sonsuza kadar kalamayacağı varsayalım. Bu durumda, denge noktası asimptotik kararlıdır.

$\dot{x} = f(x)$ sistemi için denge noktası $x = 0$ olsun. $V(x): \mathbb{R}^n \rightarrow \mathbb{R} \quad \forall x \in \mathbb{R}^n$ için $\dot{V}(x) < 0$ şeklinde, sürekli türevi alınabilen, radyal sınırsız pozitif tanımlı fonksiyon olsun (yani, $\|x\| \rightarrow \infty$ iken $V(x) \rightarrow \infty$).

$$S = \{x \in \mathbb{R}^n \mid \dot{V}(x) = 0\}$$

Orijin dışında hiçbir çözümün S içinde sonsuza kadar kalamayacağı varsayalım. Bu durumda, orijin global asimptotik kararlıdır.

Lyapunov teoreminden farklı olarak, LaSalle teoremi $V(x)$ fonksiyonun pozitif tanımlı olmasını gerektirmez. Bununla birlikte, radyal sınırsızlığı kontrol etmek için pozitif tanımlı fonksiyonlar için daha kolaydır. Eğer fonksiyon pozitif tanımlı değilse, bu yeterli olmayabilir. Örnek olarak, şu fonksiyonları ele alalım:

$$V(x) = (x_1 - x_2)^2$$

$x_1 = x_2$ için $V(x) = 0$ 'dır. Yani $\|x\| \rightarrow \infty$ olmasına rağmen $V(x)$ sonsuza gitmez.

Şunu önemle belirtmek gerekir ki, $\dot{x} = f(x)$ 'in orijini $\dot{x} = f(x)$ 'in yerel veya global asimptotik kararlı denge noktası ise, bu, sistemin tek denge noktası olmak zorundadır. Bu yüzden, birden çok denge noktası olan sistemler için global asimptotik kararlılık söz konusu değildir. Aynı

zamanda bir denge noktasının yerel asimptotik kararlı olmasının, onun global asimptotik kararlı olması için de gerekli olduğunu belirtmek gerekir.

$\dot{x} = f(x)$ 'in denge noktası olan orijin kararlı fakat asimptotik kararlı değilse orijin, sistemin tek denge noktası olmayabilir. Bu, sistem ilk koşullara bağlı olarak denge noktalarından birine yakınsayabilir anlamına gelir. Bu durumda, orijin belirli bir denge noktasına yakınsamıştır veya global kararlıdır denir.



4. BULGULAR

Bu bölümde, Nötral Tipteki Yapay Sinir Ağları hakkında genel bilgiler verilmiş, bu sinir ağlarının matematiksel modelleri incelenmiş ve bu modeller çeşitli kriterlere göre sınıflandırılmıştır.

4.1. NÖTRAL TİPTEKİ YAPAY SINIR AĞLARI'NIN TANIMI

Bu tez çalışmasının temelini oluşturan Nötral Tipteki Yapay Sinir Ağları bu kısımda ayrıntılı bir şekilde ele alınmıştır. Nötral Tipteki Yapay Sinir Ağları genel olarak hem durum denkleminde hem de türev denkleminde gecikme bulunan Yapay Sinir Ağı tipi olarak ifade edilebilir. Genel itibariyle, Gecikmeli Yapay Sinir Ağı sınıfına ait olan bu sistemler, diğer gecikmeli sistemlerden farklı yönere sahiptir.

Nötral Tipteki Yapay Sinir Ağları'nın, diferansiyel denkleminin her iki tarafında da gecikme olması bu modellerin analizini karmaşık hale getirmektedir ve kararlılık analizlerinin gerçekleştirilmesi için ileri matematik bilgisi kullanılması gerekmektedir. Bu durum dezavantaj gibi görünse de Nötral Tipteki Yapay Sinir Ağlarının, Klasik Model Yapay Sinir Ağları'ndan daha karmaşık problemlerin çözümünde kullanılabilir.

Nötral Tipteki Yapay Sinir Ağları'nın en genel modeli şu şekilde ifade edilebilir (4.1):

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau_{ij})) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta_{ij}) + u_i \quad (4.1)$$

Burada;

- n , ağdaki nöron sayısını,
- $x = (x_1, x_2, \dots, x_n)^T$, t anındaki nöron durum vektörünü,
- $A = \text{diag}(a_i)$ pozitif diyagonal matrisi,
- $B = (b_{ij})_{n \times n}$, $C = (c_{ij})_{n \times n}$ ve $D = (d_{ij})_{n \times n}$ nöronların ağırlık katsayılarını temsil eden bağlantı matrislerini,
- $U = (U_1, U_2, \dots, U_n)^T$ dış giriş vektörünü,
- $f(.) = (f_1(.), f_2(.), \dots, f_n(.))^T$ nöron aktivasyon fonksiyonunu,
- τ_{ij} zaman gecikmesini ve ζ_{ij} nötral gecikmeyi göstermektedir.

Nötral Tipteki Yapay Sinir Ağları'nın gecikmeye göre belirlenmiş diğer denklemleri şu şekilde ifade edilebilir:

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau_{ij})) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta_j) + u_i \quad (4.2)$$

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau_j)) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta_j) + u_i \quad (4.3)$$

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau)) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta) + u_i \quad (4.4)$$

Buradaki (4.1) modelinde, denklemdeki her iki gecikme de çift boyutlu olarak ele alınmıştır (τ_{ij}, ζ_{ij}) . Bu durum, her nöron çifti arasındaki gecikmenin farklı değerler taşıyabileceği anlamına gelmektedir. Buradaki gecikme $n \times n$ 'lik bir matris halinde ifade edilebilir. Gecikmenin bu şekilde kabul edildiği modeller, gerçeğe en yakın modellerdir çünkü gerçek Yapay Sinir Ağları uygulamalarında her nöron çifti arasındaki gecikme değerinin farklı olması muhtemeldir. Ancak aynı zamanda bu gecikme, sistemin kararlılık analizini oldukça zorlaştırmıştır çünkü matematiksel olarak çözümlemesi oldukça zor problemlere sebebiyet vermektedir. Bu durumu destekler şekilde, literatürde bu modeli inceleyen herhangi bir çalışmaya rastlanmamıştır.

(4.2) modelinde yine çift boyutlu bir gecikme durumu söz konusudur (τ_{ij}) . Her ne kadar sistemin sahip olduğu gecikmelerin biri tek boyutlu (ζ_j) olsa da yine de bu modelin de matematiksel analizleri oldukça zordur. Zira, literatürde nötral tipte olmasa bile çift boyutlu gecikmeye sahip olan modellerin bile matematiksel analizlerinin zor ve karmaşık işlemler içerdiği bilinmektedir. Yine bu durumu destekler şekilde, literatürde bu modeli inceleyen herhangi bir çalışmaya rastlanmamıştır.

(4.3) modelindeki gecikmeler, herhangi bir nöronun diğer tüm nöronlarla arasındaki gecikmenin sabit olduğu düşünülerek modele eklenen tek boyutlu gecikmelerdir (τ_j, ζ_j) . Bu modeldeki gecikme, tek bir sayı değil, her nöron için bir sayı olacak şekilde n elemanlı bir vektördür ve (4.1) ve (4.2)'ye göre matematiksel analizleri daha kolay gerçekleştirilebilen bir modeldir.

(4.4) modelindeki gecikmeler, tüm nöronlar arasındaki gecikmenin eşit olduğu kabul edilerek modele eklenen sabit birer sayıdır (τ, ζ). Diğer modellere göre matematiksel analizleri daha kolay olan bu model, literatürde en çok ele alınan modellerden biridir ve pek çok çalışmada incelenmiştir.

Yukarıda incelenen gecikmeli modellerde, gecikme herhangi bir parametreye bağlı değildir. Ancak donanım gerçeklemelerine daha uygun olması amacıyla gecikmelerin zamana bağlı olduğu pek çok model oluşturulmuş ve incelenmiştir. Literatürde, gecikmesi zamana bağlı olarak değişen nötral sistemlerin incelendiği pek çok çalışma mevcuttur.

(4.3) denklemi ile verilen nötral tipteki YSA'nın gecikmesinin zamana bağlı olan hali (4.5)'te; (4.4) denklemi ile verilen nötral tipteki YSA'nın gecikmesinin zamana bağlı olan hali (4.6)'da verilmiştir:

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau_j(t))) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta_j(t)) + u_i \quad (4.5)$$

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau(t))) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - \zeta(t)) + u_i \quad (4.6)$$

4.2. LİTERATÜRDEKİ NÖTRAL TİPTEKİ YAPAY SİNİR AĞI MODELLERİ

4.2.1. MODELLER VE AÇIKLAMALARI

Bu bölümde, literatürde bulunan Nötral Tipteki Yapay Sinir Ağlarına ait çalışmalar taranmış ve her bir çalışma ayrı bir model olarak gösterilerek, modele ait açıklamalar yapılmıştır.

Model 1:

[11] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij1} g_j(u_j(t)) + \sum_{j=1}^n w_{ij2} g_j(u_j(t - \tau)) + \sum_{j=1}^n d_{ij} \dot{u}_j(t - \tau) + \varphi_i,$$

$$i = 1, \dots, n$$

Burada, $\dot{u}_i(t)$ durum vektörünü, g_j aktivasyon fonksiyonunu, φ_i çıkış değerini, τ gecikmeyi ifade eder.

Model 2:

[12] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) + \sum_{j=1}^n e_{ij} \dot{x}_j(t - \tau_j) = -d_i(x_i(t)) \cdot \left(c_i(x_i(t)) - \sum_{j=1}^n a_{ij} f_j(x_j(t)) - \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau_j)) + J_i \right),$$

$$i = 1, \dots, n$$

Burada, $\dot{x}_i(t)$ durum vektörünü, $d_i(x_i)$ amplifikasyon fonksiyonunu, $c_i(x_i)$ davranış fonksiyonunu, a_{ij} bağlantı matrisini, b_{ij} geribildirim matrisini, J_i ($i = 1, \dots, n$) dış girişleri ifade eder.

Model 3:

[13] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau(t))) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - h(t)) + \sum_{j=1}^n e_{ij} \int_{-\infty}^t k_j(t - s) f_j(x_j(s)) ds + \sum_{j=1}^n f_{ij} \int_{-\infty}^t k_j(t - s) \dot{x}_j(s) ds + I_i, \quad i = 1, \dots, n$$

Burada, $\dot{x}_i(t)$ durum vektörünü, b_{ij} , c_{ij} , d_{ij} , e_{ij} , f_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, I_i dış girişi, $\tau(t)$, $h(t)$ gecikmeyi ifade eder.

Model 4:

[14] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij}^1 \bar{f}_j(u_j(t)) + \sum_{j=1}^n w_{ij}^2 \bar{g}_j(u_j(t - h)) + \sum_{j=1}^n v_{ij} \dot{u}_j(t - h) + b_i, \quad i = 1, 2, \dots, n$$

$$u_i(t) = \phi_i(t), \quad -h \leq t \leq 0$$

Burada, $\dot{u}_i(t)$ durum vektörünü, \bar{f}_j ve \bar{g}_j aktivasyon fonksiyonlarını, b_i dış girişi, A diyagonal matrisi, w_{ij}^1 , w_{ij}^2 , v_{ij} bağlantı matrislerini ifade eder.

Bu model vektör – matris formunda aşağıdaki gibi yazılabilir.

$$\dot{u}(t) = -Au(t) + W_1 \bar{f}(u(t)) + W_2 \bar{g}(u(t - h)) + V\dot{u}(t - h) + b$$

Model 5:

[15] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\dot{u}_i(t) &= -a_i u_i(t) + \sum_{j=1}^m w_{1ji} g_j(v_j(t-d)) + \sum_{j=1}^n w_{2ij} \dot{u}_j(t-h) + I_i, \quad i = 1, 2, \dots, n \\ \dot{v}_j(t) &= -b_j v_j(t) + \sum_{i=1}^n r_{1ij} g_i(u_i(t-h)) + \sum_{i=1}^m r_{2ji} \dot{v}_i(t-d) + J_j, \quad j = 1, 2, \dots, m\end{aligned}$$

Burada, \dot{u}_i ve \dot{v}_j durum vektörlerini, w_{1ji} , w_{2ij} , r_{1ij} , r_{2ji} bağlantı matrislerini, I_i ve J_j dış girişleri, g_j aktivasyon fonksiyonu ifade eder.

Model 6:

[16] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\frac{d}{dt}(x(t) - Dx(t-h)) \\ = -[C + \Delta C(t)]x(t) + [A + \Delta A(t)] \times f(x(t)) + [B + \Delta B(t)] \times g(x(t - \tau(t))) + J, \\ t \geq 0\end{aligned}$$

Burada, $x(t)$ durum vektörünü, f ve g aktivasyon fonksiyonunu, J dış girişi, C diyagonal matrisi, Δ parametrik bozukluğu ifade eder.

Model 7:

[17] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{v}(t) = -Av(t) + W_0 f(v(t)) + W_1 f(v(t-h(t))) + W_2 \int_{t-h(t)}^t f(v(s)) ds + V\dot{v}(t-h(t)) + b$$

Burada, $\dot{v}(t)$ durum vektörünü, W_0 , W_1 , W_2 , V bağlantı matrislerini, f aktivasyon fonksiyonunu, A diyagonal matrisi, b dış girişi, $h(t)$ gecikmeyi ifade eder.

Model 8:

[18] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t-\tau)) + \sum_{j=1}^n c_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds + \sum_{j=1}^n d_{ij} \dot{x}_j(t-h) + U_i,$$

$$i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, b_{ij} , c_{ij} , d_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, U_i dış girişi, τ ve h gecikmeyi ifade eder.

Model 9:

[19] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) + \sum_{j=1}^n e_{ij} \dot{x}_j(t-\tau_j) = -d_i(x_i) \left[c_i(x_i) - \sum_{j=1}^n a_{ij} f_j(x_j) - \sum_{j=1}^n b_{ij} f_j(x_j(t-\tau)) + u_i \right], \quad i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, $d_i(x_i)$ amplifikasyon fonksiyonunu, $c_i(x_i)$ davranış fonksiyonunu, a_{ij} , b_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, u_i dış girişi, τ gecikmeyi ifade eder.

Model 10:

[20] referans numaralı makalede ele alınan model şu şekildedir.

$$\frac{d}{dt}[x(t) - Dx(t-h)] = -[C + \Delta C(t)x(t) + [A + \Delta A(t)]f(x(t)) + [B + \Delta B(t)]f(x(t-h)) + J], \quad t \geq 0$$

Burada, $x(t)$ durum vektörünü, f aktivasyon fonksiyonunu, C diyagonal matrisi, A,B,D sabit matrisleri, Δ parametrik bozulmayı, J dış girişi ifade eder.

Model 11:

[21] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij}^1 \bar{f}_j(u_j(t)) + \sum_{j=1}^n w_{ij}^2 \bar{g}_j(u_j(t-h(t))) + \sum_{j=1}^n v_{ij} \dot{u}_j(t-\tau(t)) + b_i,$$

$$i = 1, 2, \dots, n$$

Burada, \dot{u}_i durum vektörünü, \bar{f}_j , \bar{g}_j aktivasyon fonksiyonlarını, b_i dış girişi, a_i diyagonal matrisi, w_{ij}^1 , w_{ij}^2 , v_{ij} bağlantı matrislerini ifade eder.

Model 12:

[22] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_p(t) = & -c_p(\eta_t)u_p(t) + \sum_{q=1}^n a_{pq}(\eta_t)g_q(u_q(t)) + \sum_{q=1}^n b_{pq}(\eta_t)g_q(u_q(t - \tau_q(t))) \\ & + \sum_{q=1}^n d_{pq}(\eta_t)\dot{u}_q(t - \tau_q(t)) + J_p, p = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{u}_p durum vektörünü, g_q aktivasyon fonksiyonunu, J_p dış girişi, a_{pq} , b_{pq} , d_{pq} skaler değerleri ifade eder.

Model 13:

[23] referans numaralı makalede ele alınan model şu şekildedir.

$$d[x(t) - Dx(t - \sigma(t))] = [-Cx(t) + Af(x(t)) + Bf(x(t - \sigma(t)))]dt + [H_1x(t) + H_2x(t - \sigma(t))]d\omega(t)$$

Burada, $x(t)$ durum vektörünü, C diyagonal matrisi, A, B bağlantı matrisini, f aktivasyon fonksiyonunu, $\omega(t)$ Brownian Hareketini ifade eder.

Model 14:

[24] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{y}(t) = -Ay(t) + B_1g(y(t - h)) + B_2 \int_{t-h}^t g(y(s))ds + B_3\dot{y}(t - h) + U, \\ y(t) = \varphi(t), \quad t \in [-h, 0] \end{cases}$$

Burada, $\dot{y}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, A diyagonal matrisi, U dış girişi ifade eder.

Model 15:

[25] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^n b_{ij} f_j(x_j(t)) + \sum_{j=1}^n c_{ij} f_j(x_j(t - \tau(t))) + \sum_{j=1}^n d_{ij} \dot{x}_j(t - h(t)) + u_i,$$

$$i = 1, 2, \dots, n$$

Burada, \dot{x}_i durum vektörünü, b_{ij} , c_{ij} , d_{ij} bağlantı matrisini, f_j aktivasyon fonksiyonunu, u_i dış girişi, $\tau(t)$, $h(t)$ gecikmeyi ifade eder.

Model 16:

[26] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = -Dx(t) + Af(x(t)) + Bf(x(t - \tau)) + C\dot{x}(t - \tau) + J$$

Burada, \dot{x} durum vektörünü, A, B, C ve D bağlantı matrislerini, f aktivasyon fonksiyonunu, J ise dış girişi ifade etmektedir. Bu model, en genel nötral tip modellerinden birini ifade etmektedir ve gecikme zamandan bağımsızdır.

Model 17:

[27] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = & -(c_i + \Delta c_i(t))u_i(t) \sum_{j=1}^n (a_{ij} + \Delta a_{ij}(t))f_j(u_j(t)) + \sum_{j=1}^n (d_{ij} + \Delta d_{ij}(t))\dot{u}_j(t - h(t)) \\ & + \sum_{j=1}^n b_{ij} + \Delta b_{ij}(t)f_j(u_j(t - \tau(t))) + J_i, \quad i = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{u}_i durum vektörünü, f_j aktivasyon fonksiyonunu, J_i dış girişi, a_{ij} , b_{ij} , d_{ij} bağlantı matrislerini, Δ parametrik belirsizliği ifade eder.

Model 18:

[28] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = & -c_i u_i(t) + \sum_{j=1}^n w_{ij} g_j(u_j(t)) + \sum_{j=1}^n a_{ij} g_j(u_j(t - \tau)) + \sum_{j=1}^n b_{ij} \int_{-\infty}^t k_j(t - s) g_j(u_j(s)) ds \\ & + \sum_{j=1}^n d_{ij} \dot{u}_j(t - \tau) + \varphi, \quad i = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{u}_i durum vektörünü, a_{ij} , b_{ij} , w_{ij} , d_{ij} bağlantı matrislerini, g_j aktivasyon fonksiyonunu, τ gecikmeyi, φ dış girişi ifade eder.

Model 19:

[29] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\dot{u}_i(t) &= -a_i u_i(t) + \sum_{j=1}^m w_{1ji} \tilde{f}_j(v_j(t-\tau)) + \sum_{j=1}^n w_{2ij} \dot{u}_j(t-h) + I_i, \quad i = 1, 2, \dots, n \\ \dot{v}_j(t) &= -b_j v_j(t) + \sum_{i=1}^n v_{1ij} \tilde{g}_i(u_i(t-\sigma)) + \sum_{i=1}^m v_{2ji} \dot{v}_i(t-d) + J_j, \quad j = 1, 2, \dots, m\end{aligned}$$

Burada, \dot{u}_i ve \dot{v}_j durum vektörlerini, w_{1ji} , w_{2ij} , v_{1ij} , v_{2ji} bağlantı matrislerini, I_i, J_j dış girişleri, \tilde{f}_j, \tilde{g}_i aktivasyon fonksiyonlarını ifade eder.

Model 20:

[30] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}d[x(t) - Dx(t - \mu(t))] \\ = \left[-Ax(t) + W^{(1)}f(x(t)) + W^{(2)}f(x(t - \tau(t))) \right. \\ \left. + W^{(3)} \int_{-\infty}^t K(t-s)f(x(s))ds \right] dt + \sigma(t, x(t), x(t - \tau(t)), x(t - \mu(t))) d\omega(t)\end{aligned}$$

Burada, $x(t)$ durum vektörünü, D ve $W^{(1)}, W^{(2)}, W^{(3)}$ bağlantı matrislerini, f aktivasyon fonksiyonunu, $\mu(t)$ ve $\tau(t)$ gecikmeyi, $\omega(t)$ Brownian hareketini ifade eder.

Model 21:

[31] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -(A_0 + \Delta A_0)y(t) + (W_0 + \Delta W_0)g(y(t), t) + (W_1 + \Delta W_1)g(y(t - \tau), t) + B_0\dot{y}(t - \eta(t)) + u(t)$$

Burada, $\dot{y}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, W_0, W_1, B_0 bağlantı matrislerini, $u(t)$ dış girişi ifade eder.

Model 22:

[32] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}(t) = -Dz(t) + A\bar{f}(z(t)) + B\bar{g}(z(t - d(t))) + Cz(t - \tau(t)) + U, \quad t \geq 0$$

Burada, $\dot{z}(t)$ durum vektörünü, \bar{f} ve \bar{g} aktivasyon fonksiyonunu, U dış girişi, D diyagonal matrisi ve A, B, C sabit matrisleri ifade eder.

Model 23:

[33] referans numaralı makalede ele alınan model şu şekildedir.

$$u'_i(t) = -a_i(u_i(t)) + \sum_{j=1}^m c_{1ij} \bar{f}_j(v_j(t)) + \sum_{j=1}^m c_{2ij} \bar{f}_j(v_j(t - \tau(t))) + \sum_{j=1}^m c_{3ij} \psi(t - h_1(t)) + I_i, i = 1, 2, \dots, n$$

$$v'_j(t) = -b_j(v_j(t)) + \sum_{i=1}^n d_{1ji} \bar{g}_i(u_i(t)) + \sum_{i=1}^n d_{2ji} \bar{g}_i(u_i(t - \sigma(t))) + \sum_{i=1}^n d_{3ji} \dot{u}(t - h_2(t)) + J_j, j = 1, 2, \dots, m$$

Burada, u_i ve v_j durum vektörünü, a_i , b_j sabitleri, c_{1ij} , c_{2ij} , c_{3ij} , d_{1ji} , d_{2ji} , d_{3ji} sinaptik bağlantı gücünü, \bar{f}_j , \bar{g}_i aktivasyon fonksiyonunu, $\tau(t)$, $\sigma(t)$ gecikmeyi, I_i , J_j dış girişi ifade eder.

Model 24:

[34] referans numaralı makalede ele alınan model şu şekildedir.

$$dx_i(t) = [-c_i x(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau)) + \sum_{j=1}^n I_{ij} \int_{-\infty}^t \hat{k}_j(t - s) f_j(x_j(s)) ds$$

$$+ \sum_{j=1}^n q_{ij} \dot{x}_j(t - \tau) + J_i] dt + \sum_{j=1}^n \sigma_{ij}(t, x_j(t)) dw_j(t) \quad t \neq t_k$$

$$i = 1, 2, \dots, n$$

Burada, x_i durum vektörünü, a_{ij} , b_{ij} , I_{ij} , q_{ij} bağlantı ağırlıklarını, f_j aktivasyon fonksiyonunu, w_j Brownian hareketini ifade eder.

Model 25:

[35] referans numaralı makalede ele alınan model şu şekildedir.

$$dy_i(t) - k_i dy_i(t - h)$$

$$= \left\{ -c_i(t) y_i(t) + \sum_{j=1}^n a_{ij}(t) g_j(y_j(t)) + \sum_{j=1}^n b_{ij}(t) g_j(y_j(t - \tau_j(t))) + \sum_{j=1}^n \sum_{l=1}^n T_{ijl}(t) g_j(y_j(t - \tau_j(t))) g_l(y_l(t - \tau_l(t))) + J_i \right\} dt$$

$$+ \rho_i(t, y_i(t), y_i(t - \tau_i(t))) dw_i(t), \quad i = 1, 2, \dots, n$$

Burada, y_i durum vektörünü, g_j aktivasyon fonksiyonunu, J_i dış girişi, w_i Brownian hareketini, τ_j gecikmeyi ifade eder.

Model 26:

[36] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}(t) = -Cx(t - \sigma) + Af(x(t - \tau(t))) + B \int_{-\infty}^t K(t - s)f(x(s))ds + D\dot{x}(t - h(t)) + J, \\ t > 0, x(s) = \varphi(s), \quad s \in (-\infty, 0], \end{cases}$$

Burada, \dot{x} durum vektörünü, C diyagonal matrisi, A, B, D bağlantı matrislerini, J dış girişi, f aktivasyon fonksiyonunu, $\tau(t)$, $h(t)$ gecikmeyi ifade eder.

Model 27:

[37] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t - \tau(t))) + D\dot{y}(t - h(t)), \quad t \neq t_k$$

Burada, \dot{y} durum vektörünü, A diyagonal matrisi, B, C, D bağlantı matrislerini, g aktivasyon fonksiyonunu, $\tau(t)$, $h(t)$ gecikmeyi ifade eder.

Model 28:

[38] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}(t) = -Au(t) + B\tilde{f}(u(t - \tau(t))) + C\dot{u}(t - h(t)) + J$$

Burada, \dot{u} durum vektörünü, A diyagonal matrisi, B, C bağlantı matrislerini, \tilde{f} aktivasyon fonksiyonunu, J dış girişi, $\tau(t)$ gecikmeyi ifade eder.

Model 29:

[39] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t - \tau(t))) + D\dot{y}(t - h(t)) + E \int_{t-r(t)}^t g(y(s))ds, \quad t \neq t_k,$$

Burada, \dot{y} durum vektörünü, A diyagonal matrisi, B,C,D,E bağlantı matrislerini, g aktivasyon fonksiyonunu, $r(t)$ gecikmeyi ifade eder.

Model 30:

[40] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n b_{ij} g_j(u_j(t)) + \sum_{j=1}^n e_{ij} g_j(u_j(t - \tau(t))) + \sum_{j=1}^n f_{ij} \int_{t-\tau(t)}^t g_j(u_j(s)) ds + \sum_{j=1}^n d_{ij} \dot{u}_j(t - \tau(t)) + U_i, \\ \Delta u_i(t) = I_{ki}(u_i), \quad t \neq t_k, \quad i = 1, 2, \dots, n \end{cases}$$

Burada, \dot{u}_i durum vektörünü, b_{ij} , e_{ij} , f_{ij} , d_{ij} bağlantı matrislerini, g aktivasyon fonksiyonunu, $\tau(t)$ gecikmeyi, U_i dış girişi ifade eder.

Model 31:

[41] referans numaralı makalede ele alınan model şu şekildedir.

$$d[x(t) - Dx(t - \tau(t))] = [-Cx(t) + Af(x(t)) + Bf(x(t - \tau(t)))]dt + [H_1x(t) + H_2x(t - \tau(t))]dB(t), t \geq 0$$

Burada, $x(t)$ durum vektörünü, C diyagonal matrisi, A , B bağlantı matrisini, f aktivasyon fonksiyonunu, H_1 , H_2 gerçek difüzyon katsayı matrislerini, $\tau(t)$ gecikmeyi ifade eder.

Model 32:

[42] referans numaralı makalede ele alınan model şu şekildedir.

$$x'_i(t) = -a_i(t)x_i(t) + \sum_{j=1}^m b_{ij}(t)f_j(x_j(t - \tau_{ij}(t))) + \sum_{j=1}^n d_{ij}(t)g_j(x'_j(t - \delta_{ij}(t))) + I_i,$$

$$i = 1, 2, \dots, n$$

Burada, x_i durum vektörünü, f_j , g_j aktivasyon fonksiyonunu, τ_{ij} , δ_{ij} gecikmeleri, I_i dış girişi ifade eder.

Model 33:

[43] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} dx(t) = & [-D \left(r(t)x(t) + A(r(t))\tilde{f}(x(t), r(t)) + B(r(t))\tilde{g}(x(t - \tau_1(t)), r(t)) \right. \\ & \left. + C(r(t)) \int_{t-\tau_2(t)}^t \tilde{h}(x(s), r(s)) ds + J \right) dt + E_1(r(t))d(x(t - \tau_1(t))) \\ & \left. + E_2(r(t))d(x(t - \tau_2(t))) + \sigma(x(t), x(t - \tau_1(t)), x(t - \tau_2(t)), t, r(t)) dw(t) \right] \end{aligned}$$

Burada, $x(t)$ durum vektörünü, D diyagonal matrisi, A , B , C , E_1 , E_2 ara bağlantı matrislerini, \tilde{f} , \tilde{g} , \tilde{h} aktivasyon fonksiyonlarını, J dış girişi, τ_1 , τ_2 gecikmeyi, $w(t)$ Brownian hareketini ifade eder.

Model 34:

[44] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = -Ax(t) + W_1\bar{f}(x(t)) + W_2\bar{f}(x(t-h(t))) + V\dot{x}(t-\tau(t)) + b$$

Burada, \dot{x} durum vektörünü, b dış girişi, \bar{f} aktivasyon fonksiyonunu, $\tau(t)$, $h(t)$ gecikmeyi, A diyagonal matrisi, W_1 , W_2 , V ara bağlantı matrislerini ifade eder.

Model 35:

[45] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}(t) = -Au(t) + W_1\bar{f}(v(t)) + W_2\bar{f}(v(t-\tau(t))) + W_3\dot{v}(t-h_1(t)) + I$$

$$\dot{v}(t) = -Bv(t) + V_1\bar{g}(u(t)) + V_2\bar{g}(u(t-\sigma(t))) + V_3\dot{u}(t-h_2(t)) + J$$

Burada, $\dot{u}(t)$, $\dot{v}(t)$ durum vektörlerini, A , B diyagonal matrisi, W_1 , W_2 , W_3 , V_1 , V_2 , V_3 sabitleri, \bar{f} , \bar{g} aktivasyon fonksiyonlarını, I ve J dış girişi, $\tau(t)$ ve $\sigma(t)$ gecikmeyi ifade eder.

Model 36:

[46] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{y}_p(t) = & -a_p(r_t)(y_p(t)) + \sum_{q=1}^n b_{pq}^0(r_t)g_q(y_q(t)) + \sum_{q=1}^n c_{pq}^1(r_t)g_q(y_q(t-\tau(t))) \\ & + \sum_{q=1}^n c_{pq}^2(r_t)\dot{y}_q(t-h(t)) + I_p, \quad p = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{y}_p durum vektörünü, g_q aktivasyon fonksiyonunu, I_p dış girişi, $\tau(t)$ ve $h(t)$ gecikmeyi ifade eder.

Model 37:

[47] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = & -d_i u_i(t) + \sum_{j=1}^n w_{ij} g_j(u_j(t)) + \sum_{j=1}^n a_{ij} g_j(u_j(t-\tau(t))) + \sum_{j=1}^n b_{ij} \int_{t-\tau(t)}^t g_j(u_j(s)) ds \\ & + \sum_{j=1}^n c_{ij} \dot{u}_j(t-\tau(t)) + J_i, \quad i = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{u}_i durum vektörünü, D diyagonal matrisi, w_{ij} , a_{ij} , b_{ij} , c_{ij} bağlantı matrislerini, g_j aktivasyon fonksiyonunu, $\tau(t)$ gecikmeyi, J_i dış girişi ifade eder.

Model 38:

[48] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}(t) = -Cx(t) + Af(x(t)) + Bf(x(t - \tau(t))) + D\dot{x}(t - \tau(t)) + F \int_{t-\tau}^t f(x(s))ds, \\ x(t_0^+ + s) = \phi(s), \quad s \in [t_0 - \tau, t_0], \\ \Delta x(t) = I_k(x), \quad t = t_k, \quad k \in N, \end{cases}$$

Burada, \dot{x} durum vektörünü, C diyagonal matrisi, A, B, D, F bağlantı matrislerini, f aktivasyon fonksiyonunu $\tau(t)$ gecikmeyi ifade eder.

Model 39:

[49] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) &= -a_i u_i(t - \sigma_i) + \sum_{j=1}^m b_{1ji} F_j(v_j(t)) + \sum_{j=1}^m c_{1ji} F_j(v_j(t - \tau(t))) + \sum_{j=1}^m d_{1ji} \int_{t-\tau(t)}^t F_j(v(s))ds \\ &\quad + \sum_{j=1}^n e_{1ij} \dot{u}_i(t - \rho(t)) + I_i, \quad t > 0, \quad t \neq t_k, \quad i = 1, 2, \dots, n \\ \Delta u(t_k) &= u(t_k) - u(t_k^-) = \mathbb{I}_k(u(t_k^-), x_{t_k^-}), \quad k \in \mathbb{Z}_+, \\ \dot{v}_j(t) &= -a_{2j} v_j(t - \sigma_2) + \sum_{i=1}^n b_{2ij} G_i(u_i(t)) + \sum_{i=1}^n c_{2ij} G_i(u_i(t - \rho(t))) + \sum_{i=1}^n d_{2ij} \int_{t-\gamma(t)}^t G_i(u(s))ds \\ &\quad + \sum_{i=1}^m e_{2ji} \dot{v}_j(t - \tau(t)) + J_j, \quad t > 0, t \neq t_k, \quad j = 1, 2, \dots, n \\ \Delta v(t_k) &= v(t_k) - v(t_k^-), \quad k \in \mathbb{Z}_+, \end{aligned}$$

Burada, \dot{u}_i ve \dot{v}_j durum vektörlerini, F_j, G_i aktivasyon fonksiyonunu, $b_{1ji}, b_{2ij}, c_{1ji}, c_{2ij}, d_{1ji}, d_{2ij}, e_{1ij}, e_{2ji}$ bağlantı matrislerini, I_i ve J_j dış girişleri ifade eder.

Model 40:

[50] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{x}(t) - C\dot{x}(t - \tau(t)) &= -(A + \Delta A(t))x(t) + (W_1 + \Delta W_1(t))f_1(x(t)) + (W_2 + \Delta W_2(t))f_2(x(t - h(t))) \\ &\quad + W_3 \int_{t-d(t)}^t f_3(x(s))ds + I(t), \end{aligned}$$

Burada, \dot{x} durum vektörünü, A diyagonal matrisi, C, W_1, W_2, W_3 bağlantı matrislerini, f aktivasyon fonksiyonunu, I dış girişi, $\tau(t), h(t)$ gecikmeyi ifade eder.

Model 41:

[51] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}_i(t) = -a_i(t)x_i(t) + \sum_{j=1}^n a_{ij}(t)f_j(x_j(t)) + \sum_{j=1}^n b_{ij}(t)g_j(x_j(t - \tau_{ij}(t))) + \sum_{j=1}^n c_{ij}(t)h_j(\dot{x}_j(t - r_{ij}(t))) + J_i(t), & t \neq t_k, \\ x_i(t) = p_{ik}(t, x_1(t^-), \dots, x_n((t - \tau_{in}(t))^-)), & t = t_k, \quad i = 1, 2, \dots, n \end{cases}$$

Burada, \dot{x}_i durum vektörünü, a_{ij} , b_{ij} , c_{ij} bağlantı matrislerini, τ_{ij} , r_{ij} gecikmeyi, J_i dış girişi, f_j , g_j , h_j aktivasyon fonksiyonunu ifade eder.

Model 42:

[52] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} c_i \frac{dx_i(t)}{dt} = -d_i x_i(t) + \sum_{j=1}^n \tilde{a}_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} g_j(x_j(t - \tau_{ij}(t))) + \sum_{j=1}^n c_{ij} h_j(\dot{x}_j(t - \tau_{ij}(t))) + I_i(t) \\ x_i(t) = \varphi_i(t) \quad t \in [-\tau, 0] \\ \dot{x}_i(t) = \psi_i(t) \quad t \in [-\tau, 0], \quad i = 1, 2, \dots, n \end{cases}$$

Burada, x_i durum vektörünü, \tilde{a}_{ij} , b_{ij} , c_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, τ_{ij} gecikmeyi, I_i dış girişi ifade eder.

Model 43:

[53] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{x}_i(t) &= -c_i(t)x_i(t) \\ &+ \sum_{j=1}^m a_{ij}(t)f_{1j}(y_j(t - \tau_{ij}(t))) + \sum_{j=1}^n b_{ji}(t)f_{2j}(\dot{x}_j(t - \bar{\delta}_{ji}(t))) + I_i(t), \quad i = 1, 2, \dots, m \\ \dot{y}_j(t) &= -d_j(t)y_j(t) + \sum_{i=1}^n p_{ji}(t)g_{1i}(x_i(t - \delta_{ji}(t))) + \sum_{i=1}^m q_{ij}(t)g_{2i}(\dot{y}_j(t - \bar{\tau}_{ij}(t))) + I_j(t), \\ &j = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{x}_i ve \dot{y}_j durum vektörünü, a_{ij} , b_{ji} , p_{ji} , q_{ij} bağlantı matrislerini, f ve g aktivasyon fonksiyonlarını, I_i ve I_j dış girişleri, $\bar{\delta}$, $\bar{\tau}$ gecikmeleri ifade eder.

Model 44:

[54] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{y}_i(t) = & -c_i y_i(t) + \sum_{j=1}^n w_{ij1} \bar{f}_j(y_j(t)) + \sum_{j=1}^n w_{ij2} \bar{g}_j(y_j(t - \tau(t))) + \sum_{j=1}^n a_{ij} \int_{-\infty}^t k_j(t-s) \bar{v}_j(y_j(s)) ds \\ & + \sum_{j=1}^n b_{ij} \dot{y}_j(t - h(t)) + I_i, \quad i = 1, \dots, n \end{aligned}$$

Burada, \dot{y}_i durum vektörünü, w_{ij1} , w_{ij2} , a_{ij} , b_{ij} bağlantı matrislerini, \bar{f}_j , \bar{g}_j , \bar{v}_j aktivasyon fonksiyonlarını, I_i dış girişi ifade eder.

Model 45:

[55] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) - C(\rho(t))\dot{y}(t - \tau(t)) = -A(\rho(t))y(t) + W(\rho(t))g(y(t - h(t))) + b$$

Burada, \dot{y} durum vektörünü, g aktivasyon fonksiyonunu, b dış girişi, C , W bağlantı matrislerini, A diyagonal matrisi, $\tau(t)$, $h(t)$ gecikmeleri ifade eder.

Model 46:

[56] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{x}_i(t) = & \tilde{\alpha}_i(x_i(t))[-\beta_i(x_i(t)) + \sum_{j=1}^n (a_{ij} + \delta a_{ij}(t)) \tilde{f}_j(x_j(t)) + \sum_{j=1}^n (b_{ij} + \delta b_{ij}(t)) \tilde{g}_j(x_j(t - \tau_{ij}(t))) \\ & + \sum_{j=1}^n (c_{ij} + \delta c_{ij}(t)) \int_{-\infty}^t k_j(t-s) \tilde{h}_j(x_j(s)) ds + \sum_{j=1}^n d_{ij} + \delta d_{ij}(t) \dot{x}_j(t - \varpi_j) + J_i], \\ & i = 1, 2, \dots, n \end{aligned}$$

Burada, \dot{x}_i durum vektörünü, $\tilde{\alpha}_i(x_i(t))$ amplifikasyon fonksiyonunu, $\beta_i(x_i(t))$ davranış fonksiyonunu, \tilde{f}_j , \tilde{g}_j , \tilde{h}_j aktivasyon fonksiyonunu, J_i dış girişi, a_{ij} , b_{ij} , c_{ij} , d_{ij} bağlantı matrislerini ifade eder.

Model 47:

[57] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} d\dot{u}(t) = \{-Au(t) + W_1^T f(v(t-d(t)) + W_2\dot{u}(t-h(t))\}dt + z_1(t, u(t), u(t-h(t)))d\omega(t) + I \\ d\dot{v}(t) = \{-Bv(t) + R_1^T g(u(t-h(t)) + R_2\dot{v}(t-d(t))\}dt + z_2(t, v(t), v(t-d(t)))d\omega(t) + F \end{cases}$$

Burada, \dot{u} ve \dot{v} durum vektörünü, A, B diyagonal matrisi, I ve F dış girişi, $h(t)$ ve $d(t)$ gecikmeleri, ω Brownian hareketi, f ve g aktivasyon fonksiyonunu ifade eder.

Model 48:

[58] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} d[x(t) - Cx(t-h(t))] \\ = \left[-A(t)x(t) + B(t)f(x(t-\tau(t))) + D(t) \int_{t-r(t)}^t f(x(s))ds \right] dt + [H_0(t)x(t) \\ + H_1(t)x(t-\tau(t))] dw(t) \end{aligned}$$

Burada, x durum vektörünü, B, C, D bağlantı matrislerini, f aktivasyon fonksiyonunu, A diyagonal matrisi ifade eder.

Model 49:

[59] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{y}(t) = -(A + \Delta A(t))y(t) + (W_1 + \Delta W_1(t))g(y(t)) + (W_2 + \Delta W_2(t))g(y(t-\tau(t))) \\ + (W_3 + \Delta W_3(t))\dot{y}(t-h(t)) + (W_4 + \Delta W_4(t)) \int_{t-r(t)}^t g(y(s))ds + I \end{aligned}$$

Burada, \dot{y} durum vektörünü, A diyagonal matrisi, W bağlantı matrisini, $\tau(t)$, $h(t)$, $r(t)$ gecikmeleri, g aktivasyon fonksiyonu, I dış girişi ifade eder.

Model 50:

[60] referans numaralı makalede ele alınan model şu şekildedir.

$$x'_i(t) + \sum_{j=1}^m e_{ij} x'_j(t-h) = -a_i(x_i(t)) \left\{ b_i(x_i(t)) - \sum_{j=1}^m s_{ij} f_j[x_j(t-\sigma_{ij}), y_j(t-\tau_{ij})] + I_i \right\},$$

$$i = 1, 2, \dots, m$$

$$y'_j(t) + \sum_{i=1}^m v_{ji} y'_i(t-d) = -c_j(y_j(t)) \left\{ d_j(y_j(t)) - \sum_{i=1}^m t_{ji} g_i[x_i(t-\delta_{ji}), y_i(t-\eta_{ji})] + J_j \right\},$$

$$j = 1, 2, \dots, m$$

Burada, x'_i, y'_j durum vektörünü, $a_i(x_i(t))$ ve $c_j(y_j(t))$ amplifikasyon fonksiyonlarını, $b_i(x_i(t)), d_j(y_j(t))$ davranış fonksiyonlarını, f_j, g_j aktivasyon fonksiyonlarını, I_i, J_j dış girişi, s_{ij}, v_{ji}, t_{ij} bağlantı matrislerini ifade eder.

Model 51:

[61] referans numaralı makalede ele alınan model şu şekildedir.

$$x'_i(t) = -a_i x_i(t) + \sum_{j=1}^m w_{1ij} f_j(y_j(t-\tau)) + \sum_{j=1}^m w_{2ij} x'_j(t-h) + c_i,$$

$$y'_j(t) = -b_j y_j(t) + \sum_{i=1}^m v_{1ji} g_i(x_i(t-\sigma)) + \sum_{i=1}^m v_{2ji} y'_i(t-d) + d_j, \quad i, j = 1, 2, \dots, m$$

Burada, x'_i ve y'_j durum vektörünü, $w_{1ij}, w_{2ij}, v_{1ji}, v_{2ji}$ bağlantı matrislerini, f_j ve g_i aktivasyon fonksiyonlarını, c_i, d_j dış girişi, τ, h, σ, d farklı gecikme tiplerini ifade eder.

Model 52:

[62] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = E(r(t))\dot{x}(t-\tau_{1,r(t)}) - A(r(t))x(t) + B(r(t))f(x(t)) + C(r(t))g(x(t-\tau_{2,r(t)}))$$

$$+ D(r(t)) \int_{t-\tau_{3,r(t)}}^{t-\tau_{4,r(t)}} h(x(s))ds,$$

Burada, \dot{x} durum vektörünü, E, B, C, D bağlantı matrislerini, A diyagonal matrisi, f, g, h aktivasyon fonksiyonlarını, $\tau_{1,r(t)}$ ve $\tau_{2,r(t)}$ gecikmeyi ifade eder.

Model 53:

[63] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = -c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t-\tau)) + \sum_{j=1}^n e_{ij} \dot{x}_j(t-\tau) + u_i, \quad i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, f_j aktivasyon fonksiyonunu, τ gecikmeyi, u_i dış girişi, a_{ij} , b_{ij} ara bağlantı matrislerini ifade eder.

Model 54:

[64] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{u}(t) = [-Au(t) + Bf(u(t)) + Ef(u(t-\tau(t))) + D\dot{u}(t-\tau(t))] + F \int_{t-\tau(t)}^t f(u(\eta)) d\eta + U, \\ t \neq t_k, \Delta u(t) = I_k(u), \quad t = t_k \end{cases}$$

Burada, \dot{u} durum vektörünü, f aktivasyon fonksiyonunu, $\tau(t)$ gecikmeyi, U dış girişi, B, E, D, F bağlantı matrislerini ifade eder.

Model 55:

[65] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) + \sum_{j=1}^n e_{ij} \dot{x}_j(t-\tau_j) = -c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t-\tau_j)) + u_i, \quad i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, a_{ij} , b_{ij} ara bağlantı matrislerini, f_j aktivasyon fonksiyonlarını, τ_j gecikmeyi, u_i dış girişi ifade eder.

Model 56:

[66] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = & -c_i u_i(t) + \sum_{i=1}^n a_{0ij} f_j(u_j(t)) + \sum_{i=1}^n a_{1ij} f_j(u_j(t-h)) + \sum_{i=1}^n b_{ij} \int_{-\infty}^t k_j(t-s) f_j(u_j(s)) ds \\ & + \sum_{i=1}^n d_{ij} \dot{u}_j(t-h) + J_i, \quad i = 1, \dots, n \end{aligned}$$

Burada, \dot{u}_i durum vektörünü, a_{0ij} , a_{1ij} , d_{ij} , b_{ij} ara bağlantı matrislerini, f_j aktivasyon fonksiyonunu, J_i dış girişi, h gecikmeyi ifade eder.

Model 57:

[67] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}
& dy_i(t) - k_i dy_i(t-h) \\
&= \left\{ -c_i y_i(t) \right. \\
&+ \sum_{j=1}^n a_{ij} g_j(y_j(t)) \\
&+ \sum_{j=1}^n b_{ij} g_j(y_j(t - \tau_j(t))) \\
&+ \sum_{j=1}^n \sum_{l=1}^n T_{ijl} g_j(y_j(t - \tau_j(t))) g_l(y_l(t - \tau_l(t))) \\
&\left. + \sum_{j=1}^n d_{ij} \int_{t-\tau_j(t)}^t g_j(y_j(s)) ds + J_i \right\} dt + \rho_i(y_i(t), y_i(t - \tau_i(t)), t) d\omega_i(t),
\end{aligned}$$

Burada, y_i durum vektörünü, a_{ij} , b_{ij} , d_{ij} birinci dereceden sinaptik ağırlıkları, T_{ijl} ikinci dereceden sinaptik ağırlığı, J_i dış girişi, τ gecikmeyi, g_j aktivasyon fonksiyonu ifade eder.

Model 58:

[68] referans numaralı makalede ele alınan model şu şekildedir.

$$dx(t) = \left[-Ax(t) + W_1 f(x(t)) + W_2 f(x(t - \tau(t))) + W_3 \dot{x}(t - h(t)) \right] dt + \sigma(t, x(t), x(t - \tau(t))) d\omega(t)$$

Burada, $x(t)$ durum vektörünü, A diyagonal matrisi, W_1 , W_2 , W_3 bağlantı matrislerini, $\omega(t)$ Brownian hareketini, f aktivasyon fonksiyonunu, $\tau(t)$ ve $h(t)$ gecikmeyi ifade eder.

Model 59:

[69] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}
\dot{y}_i(t) = & -a_i y_i(t) + \sum_{j=1}^n b_{ij} g_j(y_j(t)) + \sum_{j=1}^n c_{ij} g_j(y_j(t - \tau)) + \sum_{j=1}^n d_{ij} \int_{t-r}^t g_j(y_j(s)) ds \\
& + \sum_{j=1}^n e_{ij} \dot{y}_j(t - d) + I_i, \quad i = 1, \dots, n
\end{aligned}$$

Burada, \dot{y}_i durum vektörünü, g_j aktivasyon fonksiyonunu, b_{ij} , c_{ij} , d_{ij} , e_{ij} bağlantı matrislerini, r , d ve τ gecikmeleri, I_i dış girişi ifade eder.

Model 60:

[70] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}(t) - D(r_t)\dot{z}(t - \sigma(t)) = -A(r_t)z(t) + B(r_t)g(z(t)) + C(r_t)g(z(t - \tau(t))) + W(r_t) \int_{-\infty}^t \bar{k}(t - s)g(z(s))ds + I$$

Burada, $\dot{z}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, I dış girişi, A diyagonal matrisi, B, C, W bağlantı matrislerini, $\sigma(t)$ ve $\tau(t)$ gecikmeleri ifade eder.

Model 61:

[71] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg_1(y(t)) + Cg_2(y(t - \tau(t))) + D\dot{y}(t - h(t)) + E \int_{t-r(t)}^t g_3(y(s))ds + u(t)$$

Burada, \dot{y} durum vektörünü, A diyagonal matrisi, B, C, D, E bağlantı matrislerini, g aktivasyon fonksiyonlarını, $u(t)$ dış girişi, $\tau(t)$, $h(t)$ ve $r(t)$ gecikmeleri ifade eder.

Model 62:

[72] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}(t) = -\bar{A}_{\sigma(t)}x(t) + \bar{W}_{1\sigma(t)}f(x(t)) + \bar{W}_{2\sigma(t)}f(x(t - \tau(t))) + \bar{A}_{h\sigma(t)}\dot{x}(t - h(t)) + \bar{D}_{1\sigma(t)}v(t) + \bar{B}_{1\sigma(t)}u(t), \\ z(t) = C_{\sigma(t)}x(t) + D_{2\sigma(t)}v(t) + B_{2\sigma(t)}u(t), \\ x(t) = \phi(t) \text{ for every } t \in [-\tilde{\tau}, 0] \end{cases}$$

Burada, $x(t)$ durum vektörünü, $u(t)$ kontrol giriş vektörünü, $z(t)$ çıkış vektörünü, f aktivasyon fonksiyonunu, A diyagonal matrisi, $\tau(t)$, $h(t)$ gecikmeleri, σ anahtarlama sinyalini ifade eder.

Model 63:

[73] referans numaralı makalede ele alınan model şu şekildedir.

$$d[u(t) - E(r(t))u(t - h)] = \left[-A(r(t))u(t) + B(r(t))\tilde{f}(u(t)) + C(r(t))\tilde{f}(u(t - \tau)) + D(r(t)) \int_{t-r}^t \tilde{f}(u(s))ds \right] dt \\ + \left[W_1(r(t))u(t) + W_2(r(t))u(t - \tau) + W_3(r(t))\tilde{f}(u(t)) + W_4(r(t))\tilde{f}(u(t - \tau)) + W_5(r(t)) \int_{t-r}^t \tilde{f}(u(s))ds \right] dw(t)$$

Burada, $u(t)$ durum vektörünü, A diyagonal matrisi, $B, C, D, E, W_1, W_2, W_3, W_4, W_5$ bağlantı matrislerini, \tilde{f} aktivasyon fonksiyonunu, τ, r, h gecikmeleri, $w(t)$ Brownian hareketini ifade eder.

Model 64:

[74] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t-\tau)) + u_i \right] + \sum_{j=1}^n e_{ij} \dot{x}_j(t-\tau)$$

$$i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, $d_i(x_i(t))$ amplifikasyon fonksiyonunu, $c_i(x_i(t))$ davranış fonksiyonunu, f_j aktivasyon fonksiyonunu, u_i dış girişi, a_{ij} , b_{ij} ara bağlantı matrislerini, τ gecikmeyi ifade eder.

Model 65:

[75] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -d_i(u_i(t)) \left[a_i(u_i(t)) - \sum_{j=1}^n w_{0ij} f_j(u_j(t)) - \sum_{j=1}^n w_{1ij} f_j(u_j(t-r(t))) - \sum_{j=1}^n w_{2ij} \int_{t-r(t)}^t f_j(u_j(s)) ds - \sum_{j=1}^n c_{ij} \dot{u}_j(t-h(t)) \right] + J_i, \quad i = 1, 2, \dots, n$$

Burada, \dot{u}_i durum vektörünü, $d_i(u_i(t))$ amplifikasyon fonksiyonunu, $a_i(u_i(t))$ davranış fonksiyonunu, w_{0ij} , w_{1ij} , w_{2ij} , c_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, J dış girişi, $r(t)$ ve $h(t)$ gecikmeleri ifade eder.

Model 66:

[76] referans numaralı makalede ele alınan model şu şekildedir.

$$x'_{ij}(t) = -a_{ij}(t)x_{ij}(t) - \sum_{C_{kl} \in N_r(i,j)} C_{ij}^{kl}(t) \int_0^\infty K_{ij}(u) f(x_{kl}(t-u)) du x_{ij}(t) - \sum_{D_{kl} \in N_s(i,j)} D_{ij}^{kl}(t) \int_0^\infty \Psi_{ij}(u) g(x'_{kl}(t-u)) du x_{ij}(t) + L_{ij}(t)$$

$$i = 1, \dots, n$$

Burada, x_{ij} aktiviteyi, L_{ij} dış girişi, f ve g aktivasyon fonksiyonunu, C_{ij}^{kl} , D_{ij}^{kl} bağlantıları ifade eder.

Model 67:

[77] referans numaralı makalede ele alınan model şu şekildedir.

$$dx(t) = -Ax(t - \delta) + W_1f(x(t)) + W_2f(x(t - \tau(t))) + W_3\dot{x}(t - h(t)), \quad t \neq t_k$$

Burada, $x(t)$ durum vektörünü, f aktivasyon fonksiyonunu, A diyagonal matrisi, W_1, W_2, W_3 bağlantı matrislerini, $\delta, \tau(t), h(t)$ farklı tipteki gecikmeleri ifade eder.

Model 68:

[78] referans numaralı makalede ele alınan model şu şekildedir.

$$\left\{ \begin{array}{l} d[x(t) - Ex(t - \tau)] = [(A(\gamma_t) + \Delta A(\gamma_t))x(t) + (A_1(\gamma_t) + \Delta A_1(\gamma_t))x(t - \tau) + B\phi(u, \gamma_t) + G(\gamma_t)v(t)]dt + g(x(t), \gamma_t)d\omega(t), \\ y(t) = C(\gamma_t)x(t), \\ x(\theta, \gamma_0) = \varphi(\theta, \gamma_0), \quad \theta \in [-\tau, 0], \quad \gamma_0 \in \mathbb{S} \end{array} \right\}$$

Burada, $x(t)$ durum vektörünü, $\phi(u, \gamma_t)$ kontrol girişini, $(x(t), \gamma_t)$ stokastik bozulmaları, $\omega(t)$ Brownian hareketini, Δ parametrik belirsizlikleri, τ gecikmeyi, $y(t)$ kontrollü çıktıyı ifade eder.

Model 69:

[79] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t - h(t))) + D \int_{t-r}^t g^T(y(s))ds + E\dot{y}(t - \tau) + J$$

Burada, $\dot{y}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, J dış girişi, A diyagonal matrisi, B, C, D, E sabit matrisleri ifade eder.

Model 70:

[80] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = W_0y(t) + W_1g(y(t)) + W_2g(y(t - h)) + W_3 \int_{t-r}^t g(y(s))ds + W_4\dot{y}(t - h) + I$$

Burada, \dot{y} durum vektörünü, g aktivasyon fonksiyonunu, I dış girişi, W_0 diyagonal matrisi, W_1, W_2, W_3, W_4 bağlantı matrislerini ifade eder.

Model 71:

[81] referans numaralı makalede ele alınan model şu şekildedir.

$$\frac{d}{dt} \left[u_i(t) - \sum_{k=1}^r \sum_{j=1}^n a_{ij}^{(k)} g_j(u_j(t - \tau_j^{(k)})) \right] = -a_i u_i(t) + \sum_{k=1}^r \sum_{j=1}^n w_{ij}^{(k)} g_j(u_j(t - \tau_j^{(k)})) + I_i, \\ i = 1, 2, \dots, n$$

Burada, u_i durum vektörünü, A diyagonal matrisi, I_i dış girişi, $w_{ij}^{(k)}$ bağlantı matrisini, g aktivasyon fonksiyonunu, τ gecikmeyi ifade eder.

Model 72:

[82] referans numaralı makalede ele alınan model şu şekildedir.

$$d[x(t) - D(r(t))x(t - \tau)] \\ = [-A(r(t))x(t) + W(r(t))\varphi(x(t)) + W_a(r(t))\varphi(x(t - \tau)) + U(r(t))]dt \\ + g(t, r(t), x(t), x(t - \tau))d\omega(t)$$

Burada, $x(t)$ durum vektörünü, φ aktivasyon fonksiyonunu, τ gecikmeyi, $\omega(t)$ Brownian hareketini ifade eder.

Model 73:

[83] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}_i(t) = -a_i x_i(t) + \sum_{j=1}^m a_{ij} f_j(y_j(t)) + \sum_{j=1}^m b_{ij} f_j(y_j(t - \tau_j(t))) + \sum_{j=1}^n c_{ij} h_j(\dot{x}_j(t - \rho_j(t))) + I_i, & i = 1, 2, \dots, n, \\ \dot{y}_j(t) = -b_j y_j(t) + \sum_{i=1}^n m_{ji} g_i(x_i(t)) + \sum_{i=1}^n n_{ji} g_i(x_i(t - \sigma_i(t))) + \sum_{i=1}^m r_{ji} k_i(\dot{y}_i(t - \mu_i(t))) + J_j, & j = 1, 2, \dots, m \end{cases}$$

Burada, \dot{x}_i ve \dot{y}_j durum vektörlerini, a_{ij} , b_{ij} , c_{ij} , m_{ji} , n_{ji} , r_{ji} bağlantı matrislerini, I_i ve J_j dış girişleri, τ , ρ , σ , μ gecikmeleri ifade eder.

Model 74:

[84] referans numaralı makalede ele alınan model şu şekildedir.

$$d[x(t) + px(t - \tau(t))] = [-ax(t) + b \tanh x(t - \sigma(t))]dt + g(t, x(t), x(t - \tau(t)), x(t - \sigma(t)))dw(t), \quad t \geq 0$$

Burada, $x(t)$ durum vektörünü, τ , σ gecikmeleri, $w(t)$ Brownian hareketini, g aktivasyon fonksiyonunu ifade eder.

Model 75:

[85] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t-h(t))) + D\dot{y}(t-\tau(t)) + I$$

Burada, \dot{y} durum vektörünü, g aktivasyon fonksiyonunu, I dış girişi, A diyagonal matrisi, B, C, D ara bağlantı matrislerini ifade eder.

Model 76:

[86] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{x}(t) = & E(r_t, t)\dot{x}(t-\tau_1(t)) + A(r_t, t)x(t) + B(r_t, t)f(x(t)) + C(r_t, t)f(x(t-\tau_2(t))) \\ & + D(r_t, t) \int_{t-\tau_3(t)}^t f(x(s))ds \end{aligned}$$

Burada, \dot{x} durum vektörünü, f aktivasyon fonksiyonunu, τ gecikmeyi ifade eder.

Model 77:

[87] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} \dot{x}(t) = -Dx(t) + Af(x(t)) + Bf(x(t-\tau(t))) + C \int_{t-\sigma(t)}^t f(x(s))ds + E\dot{x}(t-\varrho(t)) + J, & t > 0 \\ x(t) = \varphi(t), & t \in [-\bar{\tau}, 0] \end{cases}$$

Burada, \dot{x} durum vektörünü, D diyagonal matrisi, A, B, C, E bağlantı matrislerini, f aktivasyon fonksiyonunu, J dış girişi, τ ve ϱ gecikmeleri ifade eder.

Model 78:

[88] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} x'_i(t) = & -c_i(t) \int_0^\infty h_i(s)x_i(t-s)ds + \sum_{j=1}^n a_{ij}(t)f_j(x_j(t-\tau_{ij}(t))) + \sum_{j=1}^n \tilde{a}_{ij}(t)\tilde{f}_j(x'_j(t-\tilde{\tau}_{ij}(t))) \\ & + \sum_{j=1}^n b_{ij}(t) \int_0^\infty K_{ij}(u)g_j(x_j(t-u))du + \sum_{j=1}^n \tilde{b}_{ij}(t) \int_0^\infty \tilde{K}_{ij}(u)\tilde{g}_j(x'_j(t-u))du \\ & + I_i(t), \quad i = 1, 2, \dots, n \end{aligned}$$

Burada, x'_i durum vektörünü, $f_j, \tilde{f}_j, g_j, \tilde{g}_j$ aktivasyon fonksiyonlarını, I_i dış girişi, τ_{ij}, u gecikmeleri ifade eder.

Model 79:

[89] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij1} \tilde{f}_j(u_j(t)) + \sum_{j=1}^n w_{ij2} \tilde{g}_j(u_j(t-\tau)) + \sum_{j=1}^n v_{ij} \dot{u}_j(t-\tau) + I_i,$$

$$i = 1, 2, \dots, n$$

Burada, \dot{u}_i durum vektörünü, \tilde{f}_j , \tilde{g}_j aktivasyon fonksiyonunu, w_{ij1} , w_{ij2} , v_{ij} nöronların kuvvetlerini belirten kuvvetleri, I_i dış girişi ifade eder.

Model 80:

[90] referans numaralı makalede ele alınan model şu şekildedir.

$$dx(t) = -A_1 x(t) + B_1 f(y(t)) + C_1 f(y(t - \tau_1(t) - \tau_2(t))) + D_1 \int_{t-r(t)}^t f(y(s)) ds + E_1 \dot{x}(t - d(t)),$$

$$dy(t) = -A_2 y(t) + B_2 g(x(t)) + C_2 g(x(t - d_1(t) - d_2(t))) + D_2 \int_{t-\rho(t)}^t g(x(s)) ds + E_2 \dot{y}(t - \tau(t))$$

Burada, $x(t)$ ve $y(t)$ durum vektörlerini, f ve g aktivasyon fonksiyonlarını, A_1 , A_2 diyagonal matrisi, B_1 , B_2 , C_1 , C_2 , D_1 , D_2 , E_1 , E_2 bağlantı matrislerini, τ ve d gecikmeleri ifade eder.

Model 81:

[91] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = E(r_t, t) \dot{y}(t - \tau_1(t)) + A(r_t, t) y(t) + B(r_t, t) g(y(t)) + C(r_t, t) g(y(t - \tau_2(t)))$$

$$+ D(r_t, t) \int_{t-\tau_3(t)}^t g(y(s)) ds + I$$

Burada, \dot{y} durum vektörünü, g aktivasyon fonksiyonunu, I dış girişi, A diyagonal matrisi, B, C, D, E sabit matrislerini ifade eder.

Model 82:

[92] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} x'_i(t) - r_i x'_i(t - c) = -a_i x_i(t - \alpha) + \sum_{j=1}^m p_{ij} f_j(y_j(t - \tau)) + I_i, & i = 1, 2, \dots, n \\ y'_j(t) - r_j^* y'_j(t - d) = -b_j y_j(t - \beta) + \sum_{i=1}^n q_{ji} g_i(x_i(t - \sigma)) + J_j, & j = 1, 2, \dots, m \end{cases}$$

Burada, x'_i ve y'_j nöron aktivasyonlarının, f_j ve g_i aktivasyon fonksiyonlarını, α , β , τ , σ , c , d gecikmeleri, p_{ij} , r_i geri besleme şablonlarını, q_{ji} , r_j^* ileri besleme şablonlarını, I_i ve J_j dış girişleri ifade eder.

Model 83:

[93] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} d[x_i(t) - \sum_{j=1}^n p_{ij} x_j(t - \tau_1(t))] = [-d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} g_j(x_j(t - \tau_1(t))) + \sum_{j=1}^n c_{ij} \int_{t-\tau_2(t)}^t h_j(x_j(s) ds + u_i(t))] dt + \sum_{j=1}^n \sigma_{ij} (x_i(t), x_j(t - \tau_1(t)), x_j(t - \tau_2(t))) d\omega_j(t) \\ x_i(t) = \xi_i(t), \quad -\bar{\tau} \leq t \leq 0, \end{cases}$$

Burada, x_i durum vektörünü, a_{ij} , b_{ij} , c_{ij} nöronun ağırlık katsayılarını, f_j , g_j , h_j aktivasyon fonksiyonlarını, u_i dış girişi, ω_j Brownian hareketi, τ_1 , τ_2 gecikmeleri, σ_{ij} Borel ölçülebilir fonksiyonunu ifade eder.

Model 84:

[94] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}(t) - D_1 \dot{u}(t - \eta(t)) = -Au(t) + W_0 g(u(t)) + W_1 g(u(t - h(t))) + W_2 g(\dot{u}(t - \eta(t))) + J$$

Burada, $\dot{u}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, W_0 , W_1 , W_2 bağlantı matrislerini, J dış girişi, $\eta(t)$ ve $h(t)$ gecikmeleri ifade eder.

Model 85:

[95] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = & -r_i u_i(t) + \sum_{j=1}^n a_{ij} f_j(u_j(t)) + \sum_{j=1}^n b_{ij} g_j(u_j(t - \tau_1(t))) + \sum_{j=1}^n c_{ij} \int_{-\infty}^t k_{ij}(t-s) h_j(u_j(s)) ds \\ & + d_i \dot{u}_i(t - \tau_2(t)) + \sum_{j=1}^n e_{ij} \int_{t-\tau_3}^t p_j u_j(s) ds + I_i \quad i = 1, 2, \dots, n \end{aligned}$$

Burada, $\dot{u}(t)$ durum vektörünü, τ gecikmeyi, a_{ij} , b_{ij} , c_{ij} , d_{ij} , e_{ij} bağlantı matrislerini, f_j , g_j , p_j aktivasyon fonksiyonlarını, I_i dış girişi ifade eder.

Model 86:

[96] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \ddot{m}_i(t) = & -a_i \ddot{m}_i(t) - b_i \dot{m}_i(t) + \sum_{j=1}^n w_{ij}^1 g_j(m_j(t)) + \sum_{j=1}^n w_{ij}^2 g_j(m_j(t-h)) + \sum_{j=1}^n d_{ij} \ddot{m}_j(t-h) + I_i, \\ & i = 1, 2, \dots, n \end{aligned}$$

Burada, m_i durum vektörünü, w_{ij}^1 , w_{ij}^2 , d_{ij} bağlantı matrislerini, g aktivasyon fonksiyonunu, h gecikmeyi, I_i dış girişi ifade eder.

Model 87:

[97] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{cases} x'_i(t) + \sum_{j=1}^m e_{ij} x'_j(t-h) = -a_i(x_i(t)) \left\{ b_i(x_i(t)) - \sum_{j=1}^m s_{ij} f_j(x_j(t-\sigma_{ij}), y_j(t-\tau_{ij})) + I_i \right\}, i = 1, 2, \dots, m \\ y'_j(t) + \sum_{i=1}^m v_{ji} y'_i(t-d) = -c_j(y_j(t)) \left\{ d_j(y_j(t)) - \sum_{i=1}^m t_{ji} g_i(x_i(t-\delta_{ji}), y_i(t-\eta_{ji})) + J_i \right\} \end{cases}$$

Burada, x ve y durum vektörünü, $a_i(x_i(t))$, $c_j(y_j(t))$ amplifikasyon fonksiyonlarını, $b_i(x_i(t))$, $d_j(y_j(t))$ davranış fonksiyonunu, f_j , g_i aktivasyon fonksiyonlarını, s_{ij} , t_{ji} , e_{ij} , v_{ji} bağlantı matrislerini, I_i , J_i dış girişleri, σ_{ij} , δ_{ji} , τ_{ij} , η_{ji} , h , d farklı tipteki gecikmeleri ifade eder.

Model 88:

[98] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}(t) = -Az(t - \delta(t)) + Bg(z(t)) + Cg(z(t - h_1(t) - h_2(t))) + Dz(t - \tau(t)) + J$$

Burada, $\dot{z}(t)$ durum vektörünü, A diyagonal matrisi, B, C, D bağlantı matrislerini, g aktivasyon fonksiyonunu, h_1, h_2, τ gecikmeleri, J dış girişi ifade eder.

Model 89:

[99] referans numaralı makalede ele alınan model şu şekildedir.

$$E\dot{x}(t) = -Ax(t) + B\dot{x}(t - \tau(t)) + Cf(x(t)) + Df(x(t - \tau(t))) + J$$

Burada, $\dot{x}(t)$ durum vektörünü, J dış girişi, A diyagonal matrisi, f aktivasyon fonksiyonunu, τ gecikmeyi, B, C, D, E bağlantı matrislerini ifade eder.

Model 90:

[100] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -\alpha_i(u_i(t)) \left[a_i(u_i(t)) - \sum_{j=1}^n w_{0ij} f_j(v_j(t)) - \sum_{j=1}^n w_{1ij} f_j(v_j(t - r_1(t))) - \sum_{j=1}^n w_{2ij} \int_{t-r_1(t)}^t f_j(v_j(s)) ds - \sum_{j=1}^n c_{1ij} \dot{u}_j(t - \sigma(t)) \right],$$

$$\dot{v}_i(t) = -\beta_i(v_i(t)) \left[b_i(v_i(t)) - \sum_{j=1}^n x_{0ij} g_j(u_j(t)) - \sum_{j=1}^n x_{1ij} g_j(u_j(t - r_2(t))) - \sum_{j=1}^n x_{2ij} \int_{t-r_2(t)}^t g_j(u_j(s)) ds - \sum_{j=1}^n c_{2ij} \dot{v}_j(t - \tau(t)) \right], \quad j = 1, 2, \dots, n$$

Burada, \dot{u}_i ve \dot{v}_i durum vektörünü, $\alpha_i(u_i(t))$ ve $\beta_i(v_i(t))$ amplifikasyon fonksiyonunu, $a_i(u_i(t))$, $b_i(v_i(t))$ davranış fonksiyonlarını, $w_{0ij}, w_{1ij}, w_{2ij}, c_{1ij}, c_{2ij}, x_{0ij}, x_{1ij}, x_{2ij}$ bağlantı matrislerini, f ve g aktivasyon fonksiyonlarını, r, τ, σ gecikmeleri ifade eder.

Model 91:

[101] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}_1(t) = -D_1 z_1(t) + A_1 f(z_2(t)) + B_1 f(z_2(t - \tau)) + E_1 \dot{z}_1(t - \tau) + u_1$$

$$\dot{z}_2(t) = -D_2 z_2(t) + A_2 g(z_1(t)) + B_2 g(z_1(t - \tau)) + E_2 \dot{z}_2(t - \tau) + u_2$$

Burada, \dot{z}_1 ve \dot{z}_2 durum vektörünü, f , g aktivasyon fonksiyonunu, u_1 , u_2 dış girişi, A , B , E bağlantı matrislerini, D diyagonal matrisi ifade eder.

Model 92:

[102] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = -Cx(t - \sigma) + Ag(x(t)) + Bg(x(t - d)) + D \int_{t-r(t)}^t g(x(s)) ds + E\dot{x}(t - h(t)) + J(t),$$

Burada, \dot{x} durum vektörünü, C diyagonal matrisi, A , B , D , E bağlantı matrislerini, g aktivasyon fonksiyonunu, J dış girişi, σ , d , h , r gecikmeleri ifade eder.

Model 93:

[103] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{e}(t) = -Ae(t - \delta) + W_1 f(e(t)) + W_2 f(e(t - \tau(t))) + W_3 \dot{e}(t - h(t))$$

Burada, $\dot{e}(t)$ durum vektörünü, W_1 , W_2 , W_3 bağlantı matrislerini, A diyagonal matrisi, f aktivasyon fonksiyonunu, τ ve h gecikmeleri ifade eder.

Model 94:

[104] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{x}_i(t) = & -a_i(t)x_i(t - \alpha_i(t)) + \sum_{j=1}^m a_{ji}(t)f_j(y_j(t - \tau_{ji}(t))) + \sum_{j=1}^m p_{ji}(t)f_j^1(y_j'(t - \sigma_{ji}(t))) \\ & + \sum_{j=1}^m c_{ji}(t) \int_0^{+\infty} K_{ji}(s)g_j(y_j(t - s)) ds + I_i(t) \quad i = 1, \dots, n \end{aligned}$$

$$\begin{aligned} \dot{y}_j(t) = & -b_j(t)y_j(t - \beta_j(t)) + \sum_{i=1}^n b_{ij}(t)h_i(x_i(t - \zeta_{ij}(t))) + \sum_{i=1}^n q_{ij}(t)h_j^1(x_i'(t - \varsigma_{ij}(t))) \\ & + \sum_{i=1}^n d_{ij}(t) \int_0^{+\infty} N_{ij}(s)l_i(x_i(t - s)) ds + J_j(t) \quad j = 1, \dots, m \end{aligned}$$

Burada, $\dot{x}_i(t)$ ve $\dot{y}_j(t)$ durum vektörünü, $f_j, f_j^1, h_j^1, g_j, l_i$ aktivasyon fonksiyonunu, $\alpha_i, \beta_j, \tau_{ji}, \sigma_{ji}, \zeta_{ij}, \varsigma_{ij}$ gecikmeleri, a_{ji}, p_{ji}, c_{ji} geribildirim şablonları, b_{ij}, q_{ij}, d_{ij} ileri beslemeli şablonları, I_i ve J_j dış girişleri ifade eder.

Model 95:

[105] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{z}(t) - (D + \Delta D(t))\dot{z}(t - \tau_1(t)) \\ = -(C + \Delta C(t))z(t) + (A + \Delta A(t))g(z(t)) + (B + \Delta B(t))g(z(t - \tau_2(t))) + J \end{aligned}$$

Burada, $\dot{z}(t)$ durum vektörünü, g aktivasyon fonksiyonunu, J dış girişi, C diyagonal matrisi, A, B, D sabit matrisleri, τ gecikmeyi ifade eder.

4.2.2. MODELLER ARASI İLİŞKİLER

Burada birbirleri ile olan ilişkilerinin bazıları aşağıdaki gibi ifade edilebilir:

[26] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = -Dx(t) + Af(x(t)) + Bf(x(t - \tau)) + C\dot{x}(t - \tau) + J$$

Burada, \dot{x} durum vektörünü, A, B, C ve D bağlantı matrislerini, f aktivasyon fonksiyonunu, J ise dış girişi ifade etmektedir. Bu model, en genel nötral tip modellerinden birini ifade etmektedir ve gecikme zamandan bağımsızdır.

[26] modelinin gecikmesinin zamana bağlı versiyonu [32], [37], [44], [77], [85], [99], [103], çalışmalarındaki modellerde görülmektedir.

[26] modelinin denkleminde dış giriş olan J 'nin kullanılmadığı bir model, [37] çalışmasında incelenmiştir.

[37] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t - \tau(t))) + D\dot{y}(t - h(t)), \quad t \neq t_k$$

Burada, \dot{y} durum vektörünü, A diyagonal matrisi, B, C, D bağlantı matrislerini, g aktivasyon fonksiyonunu, $\tau(t)$, $h(t)$ gecikmeyi ifade eder.

Tek bir aktivasyon fonksiyonunun kullanıldığı ve gecikmenin zamana bağımlı olduğu model, [44]ve [85] çalışmalarında kullanılmıştır.

[44] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}(t) = -Ax(t) + W_1\bar{f}(x(t)) + W_2\bar{f}(x(t-h(t))) + V\dot{x}(t-\tau(t)) + b$$

Burada, \dot{x} durum vektörünü, b dış girişi, \bar{f} aktivasyon fonksiyonunu, $\tau(t)$, $h(t)$ gecikmeyi, A diyagonal matrisi, W_1 , W_2 , V ara bağlantı matrislerini ifade eder.

[85] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{y}(t) = -Ay(t) + Bg(y(t)) + Cg(y(t-h(t))) + D\dot{y}(t-\tau(t)) + I$$

Burada, \dot{y} durum vektörünü, g aktivasyon fonksiyonunu, I dış girişi, A diyagonal matrisi, B, C, D ara bağlantı matrislerini ifade eder.

Bu modelin birden fazla aktivasyon fonksiyonu kullanılan hali [32] çalışmasında yer almaktadır.

[32] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}(t) = -Dz(t) + A\bar{f}(z(t)) + B\bar{g}(z(t-d(t))) + C\dot{z}(t-\tau(t)) + U, \quad t \geq 0$$

Burada, $\dot{z}(t)$ durum vektörünü, \bar{f} ve \bar{g} aktivasyon fonksiyonunu, U dış girişi, D diyagonal matrisi ve A, B, C sabit matrisleri ifade eder.

Bu modele tekil bir E matrisinin eklendiği bir model [99] çalışmasında kullanılmıştır.

[99] referans numaralı makalede ele alınan model şu şekildedir.

$$E\dot{x}(t) = -Ax(t) + B\dot{x}(t - \tau(t)) + Cf(x(t)) + Df(x(t - \tau(t))) + J$$

Burada, $\dot{x}(t)$ durum vektörünü, J dış girişi, A diyagonal matrisi, f aktivasyon fonksiyonunu, τ gecikmeyi, B, C, D, E bağlantı matrislerini ifade eder.

[37] modeline sabit gecikme (δ) eklenerek [77] ve [103] çalışmalarındaki modeller elde edilmiştir.

[77] referans numaralı makalede ele alınan model şu şekildedir.

$$dx(t) = -Ax(t - \delta) + W_1f(x(t)) + W_2f(x(t - \tau(t))) + W_3\dot{x}(t - h(t)), \quad t \neq t_k$$

Burada, $x(t)$ durum vektörünü, f aktivasyon fonksiyonunu, A diyagonal matrisi, W_1, W_2, W_3 bağlantı matrislerini, $\delta, \tau(t), h(t)$ farklı tipteki gecikmeleri ifade eder.

[103] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{e}(t) = -Ae(t - \delta) + W_1f(e(t)) + W_2f(e(t - \tau(t))) + W_3\dot{e}(t - h(t))$$

Burada, $\dot{e}(t)$ durum vektörünü, W_1, W_2, W_3 bağlantı matrislerini, A diyagonal matrisi, f aktivasyon fonksiyonunu, τ ve h gecikmeleri ifade eder.

[98] çalışmasında kullanılan model, temelde [77] ve [103] çalışmalarına benzemekle beraber, gecikmenin (δ) de zamana bağlı olarak ifade edildiği görülmüştür, ayrıca durum gecikmesi iki farklı değerle gösterilmiştir.

[98] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{z}(t) = -Az(t - \delta(t)) + Bg(z(t)) + Cg(z(t - h_1(t) - h_2(t))) + D\dot{z}(t - \tau(t)) + J$$

Burada, $\dot{z}(t)$ duurm vektörünü, A diyagonal matrisi, B, C, D bağlantı matrislerini, g aktivasyon fonksiyonunu, h_1, h_2, τ gecikmeleri, J dış girişi ifade eder.

[23] ve [41] çalışmalarında ele alınan model benzerlik göstermektedir. Bu çalışmalarda sırasıyla, $\sigma(t)$ ve $\tau(t)$ nötral gecikmeyi; f aktivasyon fonksiyonunu ifade etmektedir.

[23] referans numaralı makalede ele alınan model şu şekildedir.

$$d[x(t) - Dx(t - \sigma(t))] = [-Cx(t) + Af(x(t)) + Bf(x(t - \sigma(t)))]dt + [H_1x(t) + H_2x(t - \sigma(t))]d\omega(t)$$

Burada, $x(t)$ durum vektörünü, C diyagonal matrisi, A , B bağlantı matrisini, f aktivasyon fonksiyonunu, $\omega(t)$ Brownian Hareketini ifade eder.

[41] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} d[x(t) - Dx(t - \tau(t))] \\ = [-Cx(t) + Af(x(t)) + Bf(x(t - \tau(t)))]dt + [H_1x(t) + H_2x(t - \tau(t))]dB(t), \\ t \geq 0 \end{aligned}$$

Burada, $x(t)$ durum vektörünü, C diyagonal matrisi, A , B bağlantı matrisini, f aktivasyon fonksiyonunu, H_1, H_2 gerçek difüzyon katsayı matrislerini, $\tau(t)$ gecikmeyi ifade eder.

Çalışmalarda ele alınan [11] ve [14] modelleri birbirine benzerdir.

[11] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij1} g_j(u_j(t)) + \sum_{j=1}^n w_{ij2} g_j(u_j(t - \tau)) + \sum_{j=1}^n d_{ij} \dot{u}_j(t - \tau) + \varphi_i \\ i = 1, 2, \dots, n \end{aligned}$$

Burada, $\dot{u}_i(t)$ durum vektörünü, g_j aktivasyon fonksiyonunu, φ_i çıkış değerini, τ gecikmeyi ifade eder.

[14] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned} \dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^n w_{ij}^1 \bar{f}_j(u_j(t)) + \sum_{j=1}^n w_{ij}^2 \bar{g}_j(u_j(t - h)) + \sum_{j=1}^n v_{ij} \dot{u}_j(t - h) \\ + b_i, \quad i = 1, 2, \dots, n \end{aligned}$$

$$u_i(t) = \phi_t(t), \quad -h \leq t \leq 0$$

Bu model vektör – matris formunda aşağıdaki gibi yazılabilir.

$$\dot{u}(t) = -Au(t) + W_1\bar{f}(u(t)) + W_2\bar{g}(u(t-h)) + V\dot{u}(t-h) + b$$

Burada, $\dot{u}_i(t)$ durum vektörünü, \bar{f}_j ve \bar{g}_j aktivasyon fonksiyonlarını, b_i dış girişi, A diyagonal matrisi, $w_{ij}^1, w_{ij}^2, v_{ij}$ bağlantı matrislerini ifade eder.

19 ile 74 modelleri benzerdir, arasındaki farklılık, nötral gecikmenin 19 çalışmasında vektörel (τ_j); 74 çalışmasında ise skaler (τ) olmasıdır.

[19] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) + \sum_{j=1}^n e_{ij} \dot{x}_j(t - \tau_j) = -d_i(x_i) \left[c_i(x_i) - \sum_{j=1}^n a_{ij} f_j(x_j) - \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau)) + u_i \right], \quad i = 1, \dots, n$$

Burada, \dot{x}_i durum vektörünü, $d_i(x_i)$ amplifikasyon fonksiyonunu, $c_i(x_i)$ davranış fonksiyonunu, a_{ij}, b_{ij} bağlantı matrislerini, f_j aktivasyon fonksiyonunu, u_i dış girişi, τ gecikmeyi ifade eder.

[74] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{x}_i(t) = d_i(x_i(t)) \left[-c_i(x_i(t)) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau)) + u_i \right] + \sum_{j=1}^n e_{ij} \dot{x}_j(t - \tau)$$

$$i = 1, 2, \dots, n$$

Burada, \dot{x}_i durum vektörünü, $d_i(x_i(t))$ amplifikasyon fonksiyonunu, $c_i(x_i(t))$ davranış fonksiyonunu, f_j aktivasyon fonksiyonunu, u_i dış girişi, a_{ij}, b_{ij} ara bağlantı matrislerini, τ gecikmeyi ifade eder.

[15] ve [29] modelleri benzerdir. [15] referans numaralı makalede ele alınan model şu şekildedir.

$$\dot{u}_i(t) = -a_i u_i(t) + \sum_{j=1}^m w_{1ji} g_j(v_j(t-d)) + \sum_{j=1}^n w_{2ij} \dot{u}_j(t-h) + I_i, \quad i = 1, 2, \dots, n$$

$$\dot{v}_j(t) = -b_j v_j(t) + \sum_{i=1}^n r_{1ij} g_i(u_i(t-h)) + \sum_{i=1}^m r_{2ji} \dot{v}_i(t-d) + J_j, \quad j = 1, 2, \dots, m$$

Burada, \dot{u}_i ve \dot{v}_j durum vektörlerini, w_{1ji} , w_{2ij} , r_{1ij} , r_{2ji} bağlantı matrislerini, I_i ve J_j dış girişleri, g_j aktivasyon fonksiyonu ifade eder.

[29] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\dot{u}_i(t) &= -a_i u_i(t) + \sum_{j=1}^m w_{1ji} \tilde{f}_j(v_j(t-\tau)) + \sum_{j=1}^n w_{2ij} \dot{u}_j(t-h) + I_i, \quad i = 1, 2, \dots, n \\ \dot{v}_j(t) &= -b_j v_j(t) + \sum_{i=1}^n v_{1ij} \tilde{g}_i(u_i(t-\sigma)) + \sum_{i=1}^m v_{2ji} \dot{v}_i(t-d) + J_j, \quad j = 1, 2, \dots, m\end{aligned}$$

Burada, \dot{u}_i ve \dot{v}_j durum vektörlerini, w_{1ji} , w_{2ij} , v_{1ij} , v_{2ji} bağlantı matrislerini, I_i, J_j dış girişleri, \tilde{f}_j, \tilde{g}_i aktivasyon fonksiyonlarını ifade eder.

[61] modelinin vektör matris formunda yazılmış hali [101] modelinde görülmektedir.

$$\begin{aligned}\dot{x}_i(t) &= -a_i x_i(t) + \sum_{j=1}^m w_{1ij} f_j(y_j(t-\tau)) + \sum_{j=1}^m w_{2ij} x'_j(t-h) + c_i \\ \dot{y}_j(t) &= -b_j y_j(t) + \sum_{i=1}^m v_{1ji} g_i(x_i(t-\sigma)) + \sum_{i=1}^m v_{2ji} y'_i(t-d) + d_j\end{aligned}$$

BAM türündeki bir modelin vektör-matris formunda yazılmış hali [91] çalışmasında kullanılmıştır. [101] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\dot{z}_1(t) &= -D_1 z_1(t) + A_1 f(z_2(t)) + B_1 f(z_2(t-\tau)) + E_1 \dot{z}_1(t-\tau) + u_1 \\ \dot{z}_2(t) &= -D_2 z_2(t) + A_2 g(z_1(t)) + B_2 g(z_1(t-\tau)) + E_2 \dot{z}_2(t-\tau) + u_2\end{aligned}$$

Burada, \dot{z}_1 ve \dot{z}_2 durum vektörünü, f, g aktivasyon fonksiyonunu, u_1, u_2 dış girişi, A, B, E bağlantı matrislerini, D diyagonal matrisi ifade eder.

[101] çalışmasındaki modelde gecikmelerin zamana bağlı olduğu bir versiyon [45] numaralı çalışmada yer almaktadır. [45] referans numaralı makalede ele alınan model şu şekildedir.

$$\begin{aligned}\dot{u}(t) &= -Au(t) + W_1 \bar{f}(v(t)) + W_2 \bar{f}(v(t-\tau(t))) + W_3 \dot{v}(t-h_1(t)) + I \\ \dot{v}(t) &= -Bv(t) + V_1 \bar{g}(u(t)) + V_2 \bar{g}(u(t-\sigma(t))) + V_3 \dot{u}(t-h_2(t)) + J\end{aligned}$$

Burada, $\dot{u}(t)$, $\dot{v}(t)$ durum vektörlerini, A, B diyagonal matrisi, $W_1, W_2, W_3, V_1, V_2, V_3$ sabitleri, \bar{f}, \bar{g} aktivasyon fonksiyonlarını, I ve J dış girişi, $\tau(t)$ ve $\sigma(t)$ gecikmeyi ifade eder. Görüldüğü gibi birçok çalışmadaki modellerin benzer olduğu fakat analiz kısmında farklılıklar olduğu saptanmıştır.

4.3. NÖTRAL TİPTEKİ YAPAY SİNİR AĞI MODELLERİNİN SINIFLANDIRILMASI

Bu kısımda Nötral Tipteki Yapay Sinir Ağı Modelleri; gecikmelerine göre, kararlılık tipine göre, aktivasyon fonksiyonlarına göre sınıflandırılmıştır.

Bu sınıflandırmadan önce genel bir fikir vermesi açısından incelenen makalelerin yayın yılları ve yayımlandıkları dergiler, aşağıdaki tabloda sunulmuştur.

Tablo 4.1: Literatürdeki Nötral Tipteki Yapay Sinir Ağı Çalışmaları

| Makale No | Tarih | Dergi Adı |
|-----------|-------|--|
| 11 | 2005 | Journal of Computational and Applied Mathematics |
| 12 | 2006 | IEEE Transactions On Systems, Man, And Cybernetics |
| 13 | 2008 | Applied Mathematics and Computation |
| 14 | 2008 | Applied Mathematics and Computation |
| 15 | 2008 | Applied Mathematics and Computation |
| 16 | 2008 | IEEE Transactions On Systems, Man, And Cybernetic |
| 17 | 2008 | Modern Physics Letters B |
| 18 | 2008 | Neurocomputing |
| 19 | 2009 | Applied Mathematics and Computation |
| 20 | 2009 | Chaos, Solitons and Fractals |
| 21 | 2009 | Chaos, Solitons and Fractals |
| 22 | 2009 | Chaos, Solitons and Fractals |
| 23 | 2009 | Commun Nonlinear Sci Numer Simulat |
| 24 | 2009 | Expert Systems with Applications |
| 25 | 2009 | International Journal of Computer Mathematics |
| 26 | 2009 | Journal of Computational and Applied Mathematics |
| 27 | 2009 | Neurocomputing |
| 28 | 2009 | Neurocomputing |
| 29 | 2009 | Neurocomputing |
| 30 | 2010 | Applied Mathematics and Computation |
| 31 | 2010 | Applied Mathematics and Computation |
| 32 | 2010 | IEEE Transactions On Systems, Man, And Cybernetics |
| 33 | 2010 | International Journal of Computer Mathematics |
| 34 | 2010 | Modern Physics Letters B |
| 35 | 2010 | Neural Process Lett |
| 36 | 2010 | Nonlinearity |
| 37 | 2010 | Nonlinear Analysis: Real World Applications |
| 38 | 2010 | Nonlinear Analysis: Hybrid Systems |
| 39 | 2010 | Nonlinear Analysis: Hybrid Systems |
| 40 | 2010 | Neurocomputing |
| 41 | 2010 | Neurocomputing |
| 42 | 2010 | Neurocomputing |
| 43 | 2010 | Neurocomputing |

Tablo 4.1 (devamı): Literatürdeki Nötral Tipteki Yapay Sinir Ağı Çalışmaları

| | | |
|----|------|---|
| 44 | 2010 | Physics Letters A |
| 45 | 2011 | Procedia Engineering |
| 46 | 2011 | Can. J. Phys. |
| 47 | 2011 | Circuits Syst Signal Process |
| 48 | 2011 | Commun Nonlinear Sci Numer Simulat |
| 49 | 2011 | International Journal of Computer Mathematics |
| 50 | 2011 | Nonlinearity |
| 51 | 2011 | Nonlinear Dyn |
| 52 | 2011 | Neurocomputing |
| 53 | 2012 | Abstract and Applied Analysis |
| 54 | 2012 | Abstract and Applied Analysis |
| 55 | 2012 | Expert Systems with Applications |
| 56 | 2012 | International Journal of Computer Mathematics |
| 57 | 2012 | J Control Theory Appl |
| 58 | 2012 | Journal of Applied Mathematics |
| 59 | 2012 | Journal Of Computers |
| 60 | 2012 | Neural Networks |
| 61 | 2012 | Neurocomputing |
| 62 | 2012 | Neurocomputing |
| 63 | 2012 | Neurocomputing |
| 64 | 2012 | Nonlinear Dyn |
| 65 | 2013 | Abstract and Applied Analysis |
| 66 | 2013 | ISA Transactions |
| 67 | 2013 | ISA Transactions |
| 68 | 2013 | Neural Comput & Applic |
| 69 | 2013 | Neurocomputing |
| 70 | 2013 | Neurocomputing |
| 71 | 2014 | Circuits Syst Signal Process |
| 72 | 2014 | International Journal Of Adaptive Control And Signal Processing |
| 73 | 2014 | Journal of the Franklin Institute |
| 74 | 2014 | Journal of the Franklin Institute |
| 75 | 2014 | Neurocomputing |
| 76 | 2014 | Network: Computation in Neural Systems |
| 77 | 2015 | Applied Mathematics and Computation |
| 78 | 2015 | Automatica |
| 79 | 2015 | ISA Transactions |
| 80 | 2015 | Journal of the Franklin Institute |
| 81 | 2015 | Neurocomputing |
| 82 | 2015 | Neurocomputing |
| 83 | 2015 | Neurocomputing |
| 84 | 2015 | Neurocomputing |
| 85 | 2015 | Neurocomputing |
| 86 | 2015 | Neurocomputing |
| 87 | 2015 | Neurocomputing |
| 88 | 2015 | Neurocomputing |
| 89 | 2016 | Journal of Mathematical Control Science and Applications |
| 90 | 2016 | Neurocomputing |
| 91 | 2016 | Neurocomputing |
| 92 | 2016 | Neurocomputing |
| 93 | 2016 | Neurocomputing |
| 94 | 2016 | Neurocomputing |
| 95 | 2017 | Neurocomputing |
| 96 | 2017 | Neurocomputing |
| 97 | 2017 | Neural Comput & Applic |
| 98 | 2017 | International Journal of Control, Automation and Systems |

Tablo 4.1 (devamı): Literatürdeki Nötral Tipteki Yapay Sinir Ağı Çalışmaları

| | | |
|-----|------|---|
| 99 | 2017 | International Journal of Machine Learning and Cybernetics |
| 100 | 2017 | Neural Process Lett |
| 101 | 2017 | Nonlinear Dyn |
| 102 | 2017 | International Journal of Systems Science |
| 103 | 2018 | Advances in Difference Equations |
| 104 | 2018 | Chaos, Solitons and Fractals |
| 105 | 2018 | Neurocomputing |

Verilen tabloda görüldüğü üzere, 2005 yılında 1 çalışma, 2006 yılında 1 çalışma, 2008 yılında 6 çalışma, 2009 yılında 11 çalışma, 2010 yılında 15 çalışma, 2011 yılında 8 çalışma, 2012 yılında 12 çalışma, 2013 yılında 6 çalışma, 2014 yılında 6 çalışma, 2015 yılında 12 çalışma, 2016 yılında 6 çalışma, 2017 yılında 8 çalışma, 2018 yılında 3 çalışma yapılmıştır. Nötral Tipteki Yapay Sinir Ağları alanında her yıl çalışma yapıldığı ve en çok çalışmanın 2015 yılında yapıldığı görülmüştür. Bu alandaki çalışmaların çoğunlukla Neurocomputing dergisinde yayınlandığı görülmüştür.

4.3.1. Gecikmeye Göre Sınıflandırma

Bu bölümde literatürdeki çalışmalarda yer alan Nötral Tipteki Yapay Sinir Ağı modelleri gecikme tiplerine göre sınıflandırılmışlardır.

Tablo 4.2: Gecikmelerine Göre Sınıflandırma

| Makale No | Durum Gecikmesi | Nötral Gecikme |
|-----------|----------------------|----------------------------|
| 11 | $u_j(t - \tau)$ | $\dot{u}_j(t - \tau)$ |
| 12 | $x_j(t - \tau_j)$ | $\dot{x}_j(t - \tau_j)$ |
| 13 | $x_j(t - \tau(t))$ | $\dot{x}_j(t - h(t))$ |
| 14 | $u_j(t - h)$ | $\dot{u}_j(t - h)$ |
| 15 | $v_j(t - d)$ | $\dot{u}_j(t - h)$ |
| | $u_i(t - h)$ | $\dot{v}_i(t - d)$ |
| 16 | $x(t - \tau(t))$ | $\dot{x}(t - h)$ |
| 17 | $v(t - h(t))$ | $\dot{v}(t - h(t))$ |
| 18 | $x_j(t - \tau)$ | $\dot{x}_j(t - h)$ |
| 19 | $x_j(t - \tau)$ | $\dot{x}_j(t - \tau_j)$ |
| 20 | $x(t - h)$ | $\dot{x}(t - h)$ |
| 21 | $u_j(t - h(t))$ | $\dot{u}_j(t - \tau(t))$ |
| 22 | $u_q(t - \tau_q(t))$ | $\dot{u}_q(t - \tau_q(t))$ |
| 23 | $x(t - \sigma(t))$ | $\dot{x}(t - \sigma(t))$ |
| 24 | $y(t - h)$ | $\dot{y}(t - h)$ |
| 25 | $x_j(t - \tau(t))$ | $\dot{x}_j(t - h(t))$ |
| 26 | $x(t - \tau)$ | $\dot{x}(t - \tau)$ |
| 27 | $u_j(t - \tau(t))$ | $\dot{u}_j(t - h(t))$ |
| 28 | $u_j(t - \tau)$ | $\dot{u}_j(t - \tau)$ |
| 29 | $v_j(t - \tau)$ | $\dot{u}_j(t - h)$ |
| | $u_i(t - \sigma)$ | $\dot{v}_i(t - d)$ |

Tablo 4.2 (devamı): Gecikmelerine Göre Sınıflandırma

| | | |
|----|--|--|
| 30 | $x(t - \tau(t))$ | $\dot{x}(t - \mu(t))$ |
| 31 | $y(t - \tau)$ | $\dot{y}(t - \eta(t))$ |
| 32 | $z(t - d(t))$ | $\dot{z}(t - \tau(t))$ |
| 33 | $v_j(t - \tau(t))$ $u_i(t - \sigma(t))$ | $\dot{v}(t - h_1(t))$ $\dot{u}(t - h_2(t))$ |
| 34 | $x_j(t - \tau)$ | $\dot{x}_j(t - \tau)$ |
| 35 | $y_j(t - \tau_j(t))$ | $\dot{y}_i(t - h)$ |
| 36 | $x(t - \tau(t))$ | $\dot{x}(t - h(t))$ |
| 37 | $y(t - \tau(t))$ | $\dot{y}(t - h(t))$ |
| 38 | $u(t - \tau(t))$ | $\dot{u}(t - h(t))$ |
| 39 | $y(t - \tau(t))$ | $\dot{y}(t - h(t))$ |
| 40 | $u_j(t - \tau(t))$ | $\dot{u}_j(t - \tau(t))$ |
| 41 | $x(t - \tau(t))$ | $\dot{x}(t - \tau(t))$ |
| 42 | $x_j(t - \tau_{ij}(t))$ | $x_j'(t - \delta_{ij}(t))$ |
| 43 | $x(t - \tau_1(t))$ | $x'(t - \tau_1(t))$ |
| 44 | $x(t - h(t))$ | $\dot{x}(t - \tau(t))$ |
| 45 | $v(t - \tau(t))$ $u(t - \sigma(t))$ | $\dot{v}(t - h_1(t))$ $\dot{u}(t - h_2(t))$ |
| 46 | $y_q(t - \tau(t))$ | $\dot{y}_q(t - h(t))$ |
| 47 | $u_j(t - \tau(t))$ | $\dot{u}_i(t - \tau(t))$ |
| 48 | $x(t - \tau(t))$ | $\dot{x}(t - \tau(t))$ |
| 49 | $v_j(t - \tau(t))$ $u_i(t - \rho(t))$ | $\dot{u}_i(t - \rho(t))$ $\dot{v}_j(t - \tau(t))$ |
| 50 | $x(t - h(t))$ | $\dot{x}(t - \tau(t))$ |
| 51 | $x_j(t - \tau_{ij}(t))$ | $\dot{x}_j(t - r_{ij}(t))$ |
| 52 | $x_j(t - \tau_{ij}(t))$ | $\dot{x}_j(t - \tau_{ij}(t))$ |
| 53 | $y_j(t - \tau_{ij}(t))$ $x_i(t - \delta_{ji}(t))$ | $\dot{x}_j(t - \bar{\delta}_{ji}(t))$ $\dot{y}_j(t - \bar{\tau}_{ij}(t))$ |
| 54 | $y_j(t - \tau(t))$ | $\dot{y}_j(t - h(t))$ |
| 55 | $y(t - h(t))$ | $\dot{y}(t - \tau(t))$ |
| 56 | $x_j(t - \tau_{ij}(t))$ | $\dot{x}_j(t - \varpi_j)$ |
| 57 | $v(t - d(t))$ $u(t - h(t))$ | $u(t - h(t))$ $v(t - d(t))$ |
| 58 | $x(t - \tau(t))$ | $\dot{x}(t - h(t))$ |
| 59 | $y(t - \tau(t))$ | $\dot{y}(t - h(t))$ |
| 60 | $x_j(t - \sigma_{ij})$ $x_i(t - \delta_{ji})$ | $x_j'(t - h)$ $y_i'(t - d)$ |
| 61 | $y_j(t - \tau)$ $x_i(t - \sigma)$ | $x_j'(t - h)$ $y_i'(t - d)$ |
| 62 | $x(t - \tau_{2,r}(t))$ | $\dot{x}(t - \tau_{1,r}(t))$ |
| 63 | $x_j(t - \tau)$ | $\dot{x}_j(t - \tau)$ |
| 64 | $u(t - \tau(t))$ | $\dot{u}(t - \tau(t))$ |
| 65 | $x_j(t - \tau_j)$ | $\dot{x}_j(t - \tau_j)$ |
| 66 | $u_j(t - h)$ | $\dot{u}_j(t - h)$ |
| 67 | $y_j(t - \tau_j(t))$ | $\dot{y}_i(t - h)$ |

Tablo 4.2 (devamı): Gecikmelerine Göre Sınıflandırma

| | | |
|-----|--|---|
| 68 | $x(t - \tau(t))$ | $\dot{x}(t - h(t))$ |
| 69 | $y_j(t - \tau)$ | $\dot{y}_j(t - d)$ |
| 70 | $z(t - \tau(t))$ | $\dot{z}(t - \sigma(t))$ |
| 71 | $y(t - \tau(t))$ | $\dot{y}(t - h(t))$ |
| 72 | $x(t - \tau(t))$ | $\dot{x}(t - h(t))$ |
| 73 | $u(t - \tau)$ | $\dot{u}(t - h)$ |
| 74 | $x_j(t - \tau)$ | $\dot{x}_j(t - \tau)$ |
| 75 | $u_j(t - r(t))$ | $\dot{u}_j(t - h(t))$ |
| 76 | $x_{kl}(t - u)$ | $x'_{kl}(t - u)$ |
| 77 | $x(t - \tau(t))$ | $\dot{x}(t - h(t))$ |
| 78 | $x(t - \tau)$ | $\dot{x}(t - \tau)$ |
| 79 | $y(t - h(t))$ | $\dot{y}(t - \tau)$ |
| 80 | $y(t - h)$ | $\dot{y}(t - h)$ |
| 81 | $u_j(t - \tau_j^{(k)})$ | $\dot{u}_j(t - \tau_j^{(k)})$ |
| 82 | $x(t - \tau)$ | $\dot{x}(t - \tau)$ |
| 83 | $y_j(t - \tau_j(t))$ $x_i(t - \sigma_i(t))$ | $\dot{x}_j(t - \rho_j(t))$ $\dot{y}_i(t - \mu_i(t))$ |
| 84 | $x(t - \tau(t))$ | $\dot{x}(t - \tau(t))$ |
| 85 | $y(t - h(t))$ | $\dot{y}(t - \tau(t))$ |
| 86 | $x(t - \tau_2(t))$ | $\dot{x}(t - \tau_1(t))$ |
| 87 | $x(t - \tau(t))$ | $\dot{x}(t - \varrho(t))$ |
| 88 | $x_j(t - \tau_{ij}(t))$ | $x'_j(t - \tilde{\tau}_{ij}(t))$ |
| 89 | $u_j(t - \tau)$ | $\dot{u}_j(t - \tau)$ |
| 90 | $y(t - \tau_1(t) - \tau_2(t))$ $x(t - d_1(t) - d_2(t))$ | $\dot{x}(t - d(t))$ $\dot{y}(t - \tau(t))$ |
| 91 | $y(t - \tau_2(t))$ | $\dot{y}(t - \tau_1(t))$ |
| 92 | $y_j(t - \tau)$ $x_i(t - \sigma)$ | $x'_i(t - c)$ $y'_j(t - d)$ |
| 93 | $x_j(t - \tau_1(t))$ | $\dot{x}_j(t - \tau_1(t))$ |
| 94 | $u(t - h(t))$ | $\dot{u}(t - \eta(t))$ |
| 95 | $u_j(t - \tau_1(t))$ | $\dot{u}_i(t - \tau_2(t))$ |
| 96 | $m_j(t - h)$ | $\ddot{m}_j(t - h)$ |
| 97 | $x_j(t - \sigma_{ij})$ $x_i(t - \delta_{ji})$ | $x'_j(t - h)$ $y'_i(t - d)$ |
| 98 | $z(t - h_1(t) - h_2(t))$ | $\dot{z}(t - \tau(t))$ |
| 99 | $x(t - \tau(t))$ | $\dot{x}(t - \tau(t))$ |
| 100 | $v_j(t - r_1(t))$ $u_j(t - r_2(t))$ | $\dot{u}_j(t - \sigma(t))$ $\dot{v}_j(t - \tau(t))$ |
| 101 | $z_2(t - \tau)$ $z_1(t - \tau)$ | $\dot{z}_1(t - \tau)$ $\dot{z}_2(t - \tau)$ |
| 102 | $x(t - d)$ | $\dot{x}(t - h(t))$ |
| 103 | $e(t - \tau(t))$ | $\dot{e}(t - h(t))$ |
| 104 | $y_j(t - \tau_{ji}(t))$ $x_i(t - \zeta_{ij}(t))$ | $y'_j(t - \sigma_{ji}(t))$ $x'_i(t - \varsigma_{ij}(t))$ |
| 105 | $z(t - \tau_2(t))$ | $\dot{z}(t - \tau_1(t))$ |

Görüldüğü gibi incelenen makalelerde $x(t - \tau)$, $x_j(t - \tau)$, $x_j(t - \tau_j)$, $x_j(t - \tau_{ij})$, $x(t - \tau(t))$, $x_j(t - \tau(t))$, $x_j(t - \tau_j(t))$, $x_j(t - \tau_{ij}(t))$, $x(t - \tau_j(t))$, $x_{ij}(t - \tau)$, $x_j(t - \tau_j^{(k)})$, $x_j(t - \tau_j^{(k)})$, $x(t - \tau_i(t) - \tau_j(t))$ gibi çeşitli gecikme türleri incelenmiştir. Gecikme türlerine bakıldığında, gecikmenin sabit ya da zamana bağlı olarak alındığı pek çok farklı gecikmenin bulunduğu görülmektedir. Her gecikmenin incelendiği çalışmalar ve çalışma sayısı aşağıdaki gibi derlenebilir.

- $x(t - \tau)$ gecikmesi: [20, 24, 26, 31, 73, 78, 80, 82, 102] (9 adet)
- $x_j(t - \tau)$ gecikmesi: [11, 14, 15, 18, 19, 28, 29, 34, 61, 63, 66, 69, 74, 89, 92, 96, 101] (17 adet)
- $x_j(t - \tau_j)$ gecikmesi: [12, 65] (2 adet)
- $x_j(t - \tau_{ij})$ gecikmesi: [60, 97] (2 adet)
- $x(t - \tau(t))$ gecikmesi: [16, 17, 23, 30, 32, 36, 37, 38, 39, 41, 44, 45, 48, 50, 55, 57, 58, 59, 64, 68, 70, 71, 72, 77, 79, 84, 85, 87, 94, 99, 103] (31 adet)
- $x_j(t - \tau(t))$ gecikmesi: [13, 21, 25, 27, 33, 40, 46, 47, 49, 54, 75] (11 adet)
- $x_j(t - \tau_j(t))$ gecikmesi: [22, 35, 67, 83, 93, 95, 100] (7 adet)
- $x_j(t - \tau_{ij}(t))$ gecikmesi: [42, 51, 52, 53, 56, 88, 104] (7 adet)
- $x(t - \tau_j(t))$ gecikmesi: [43, 62, 86, 91, 105] (5 adet)
- $x_{ij}(t - \tau)$ gecikmesi: [76] (1 adet)
- $x_j(t - \tau_j^{(k)})$ gecikmesi: [81] (1 adet)
- $x(t - \tau_i(t) - \tau_j(t))$ gecikmesi: [90, 98] (2 adet)

4.3.2. Kararlılık Tipine Göre Sınıflandırma

Literatürde taranmış olan çalışmalar özelliklerine göre, global, stokastik ve robust olmak üzere 3 sınıfa ayrılabilir. Bir modelin bu sınıfa ait birden fazla özelliği olabilir. Örneğin, [20] referans numaralı çalışma, hem global hem robust sınıfına aittir. Kararlılık tipine göre, üstel ve asimptotik olmak üzere 2'ye ayrılır. Bu grupta bulunan modeller bu iki sınıftan birine ait olmalıdır. Gecikmeye bağlı olup olmama durumlarına göre ise, gecikme bağımlı, gecikme bağımsız ve tanımlanamamış tipler olmak üzere 3'e ayrılmıştır. Burada stokastik kararlılıktan

kast edilen, stokastik bir sistemin kararlılık özelliklerinin incelenmesidir. Sistem stokastik olarak tanımlanmadıysa stokastik kararlılık diye bir kavramdan bahsetmek mümkün değildir.

Literatürdeki sınıflandırma şu şekildedir (Tablo 4.3):

Tablo 4.3: Kararlılık Tipine Göre Sınıflandırma

| Makale No | Kararlılık Özelliği | | | Kararlılık Türü | | Gecikmesi | | |
|-----------|---------------------|-----------|--------|-----------------|------------|--------------|-------------------|---------------|
| | Global | Stokastik | Robust | Üstel | Asimptotik | Zamana Bağlı | Zamandan Bağımsız | Tanımlı Değil |
| 11 | x | | | x | | x | | |
| 12 | x | | | | x | | x | |
| 13 | x | | | | x | x | | |
| 14 | x | | | | x | x | | |
| 15 | x | | | | x | x | | |
| 16 | x | | | x | | x | | |
| 17 | x | | | | x | x | | |
| 18 | x | | | x | | | | |
| 19 | x | | | | x | | x | |
| 20 | x | | | x | | | x | |
| 21 | x | | | | x | | | |
| 22 | | x | | | | | | |
| 23 | x | | | | x | x | | |
| 24 | x | | | | x | x | | |
| 25 | x | | | x | | | | |
| 26 | x | | | x | | | | |
| 27 | | | x | | | x | | |
| 28 | x | | | | x | x | | |
| 29 | x | | | | x | x | | |
| 30 | x | | | | | | | |
| 31 | x | | | x | | | | |
| 32 | | | | | | | | |
| 33 | x | | | x | | | | |
| 34 | x | | | x | | | | |
| 35 | x | | x | x | | | | |
| 36 | x | | | | x | | | |
| 37 | x | | | x | | | | |
| 38 | x | | | x | | | | |
| 39 | x | | | x | | | | |
| 40 | x | | | x | | x | | |
| 41 | x | | | x | | x | | |
| 42 | x | | | | x | | | |
| 43 | x | | | | x | | | x |
| 44 | | | x | | x | | | |
| 45 | | | | | x | x | | |
| 46 | | | x | | | | | |
| 47 | | | x | x | | | | |
| 48 | x | | | x | | | | |
| 49 | x | | | | x | | | |
| 50 | x | | x | | | x | | |
| 51 | x | | | x | | | | |
| 52 | X | | | x | | | | |

Tablo 4.3 (devamı): Kararlılık Tipine Göre Sınıflandırma

| | | | | | | | | |
|-----|---|---|---|---|---|---|---|---|
| 53 | x | | | x | | | | |
| 54 | x | | | | x | | | |
| 55 | | | | | | x | | |
| 56 | x | | x | x | | | | |
| 57 | x | | | x | | x | | |
| 58 | | x | x | | | | | |
| 59 | | | x | | | | | |
| 60 | x | | | | x | | | x |
| 61 | x | | | | x | | | x |
| 62 | x | | | x | | x | | |
| 63 | x | | | | x | | x | |
| 64 | x | | | x | | | | |
| 65 | x | | | | x | | | |
| 66 | x | | | | x | x | | |
| 67 | x | | | x | | | | |
| 68 | | | x | | | | | |
| 69 | x | | | x | | x | | |
| 70 | | x | | | | x | | |
| 71 | | x | | | | | | |
| 72 | | | x | x | | | | |
| 73 | | x | | | x | | | |
| 74 | x | | | | x | | x | |
| 75 | | | x | | | | | |
| 76 | | | | x | | | | |
| 77 | | | | | | | | |
| 78 | | x | | | | | | |
| 79 | | | | | x | | | |
| 80 | | | | | | | | |
| 81 | | | | x | | | | |
| 82 | | x | | | | | | |
| 83 | | | | | | | | |
| 84 | x | | | x | | | | |
| 85 | | | | | | x | | |
| 86 | | x | x | | | | | |
| 87 | x | | | | x | | | x |
| 88 | | | | x | | | | |
| 89 | x | x | x | | | | | |
| 90 | | | | | | x | | |
| 91 | | | | | | | | |
| 92 | x | | | x | | | | |
| 93 | | | | | | | | |
| 94 | | | | x | | x | | |
| 95 | | | | | | | | |
| 96 | x | | | | | | | |
| 97 | | | | | | | | |
| 98 | | | | | | | | |
| 99 | X | | | x | | x | | |
| 100 | | | | | x | x | | |
| 101 | X | | | | x | x | | |
| 102 | | | | | | | | |
| 103 | | | | | | x | | |
| 104 | X | | | x | | | | |
| 105 | | | | | | x | | |

Tablodan da görüldüğü üzere, kararlılık özellikleri dikkate alındığında, global kararlılığın çoğunlukta olduğu, stokastik ve robust kararlılığın ise daha az kullanıldığı görülmüştür. Bunun yanı sıra, kararlılık türüne göre yapılan sınıflandırmada, üstel ve asimptotik kararlılığın çalışmalarda sıkça kullanıldığı gözlenmiştir.

4.3.3. Aktivasyon Fonksiyonlarına Göre Sınıflandırma

Yapay Sinir Ağları'nda toplama fonksiyonundan çıkan net fonksiyon hücre çıktısı oluşturulmak üzere aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonları, Yapay Sinir Ağları'nın kararlılık analizinde kullanılan ve toplama fonksiyonundan gelen değeri, gerçek bir çıktıya dönüştüren fonksiyonlardır. Aktivasyon fonksiyonları genellikle doğrusal olmayan fonksiyonlardır. Diğer önemli nokta ise, seçilen aktivasyon fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Geri beslemeli ağlarda, hesaplamının uzun sürmemesi için türevin kolay hesaplanabileceği bir fonksiyon seçilmektedir. Aktivasyon fonksiyonları, Yapay Sinir Ağları'na doğrusal olmayan özellikleri tanıtmak için kullanılan fonksiyonlardır. Aktivasyon fonksiyonu kullanılmazsa, çıkış sinyali basit bir doğrusal fonksiyon olarak üretilir, bu da tek dereceli polinomlardır ve ağ sınırlı öğrenme gücüne sahip olur. Fakat Yapay Sinir Ağları'na öğrenilmesi için gösterilen girdiler; görüntü, ses, yazı gibi karmaşık gerçek bilgilerdir. Yapay Sinir Ağı'nın bu karmaşık verilerden anlamlı çıktılar üretebilmesi için aktivasyon fonksiyonu kullanılır.

Aktivasyon fonksiyonları literatürde aşağıdaki şekilde sınıflara ayrılmıştır.

1. tip aktivasyon fonksiyonu

Sınırlı, Lipschitz

$$0 \leq \frac{f_i(\xi_1) - f_i(\xi_2)}{\xi_1 - \xi_2} \leq \sigma_i \quad i = 1, 2, \dots, n$$

Herhangi $\xi_1, \xi_2 \in R$ $\xi_1 \neq \xi_2$ olduğunda $\sigma_i > 0$ için $i = 1, 2, \dots, n$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir:

[11, 14, 21, 22, 24, 28, 30, 34, 35, 37, 39, 40, 46, 48, 50, 55, 56, 66, 67, 68, 70, 81, 82, 86, 89]

2. tip aktivasyon fonksiyonu

Yapı olarak 1. tip aktivasyon fonksiyonunun aynısı olmakla beraber sınır değerleri farklılık göstermektedir, buna göre 1. tip fonksiyona göre daha genel bir şart sağlamaktadır.

Dolayısıyla hem sigmoid aktivasyon fonksiyonlarındaki hem de Lipschitz tipi aktivasyon fonksiyonlarındaki açıklamalardan daha az kısıtlayıcıdır.

Sınırlı, Lipschitz

$$\sigma_i^- \leq \frac{f_i(\xi_1) - f_i(\xi_2)}{\xi_1 - \xi_2} \leq \sigma_i^+ \quad i = 1, 2, \dots, n$$

herhangi $\xi_1, \xi_2 \in R$ $\xi_1 \neq \xi_2$ olduğunda σ_i^- ve σ_i^+ ($i = 1, 2, \dots, n$) bunlar bazı sabitlerdir, pozitif, negatif veya sıfır olabilirler.

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir:

[23, 36, 41, 47, 53, 54, 59, 62, 69, 71, 72, 73, 75, 77, 79, 80, 85, 87, 88, 90, 91, 92, 94, 96]

3. tip aktivasyon fonksiyonu

Her $f_i = R \rightarrow R$ $i \in \{1, 2, \dots, n\}$ sınırlıdır, bütün $x_i \in R$ ve Lipschitz sabiti $L_i > 0$ ile Lipschitz koşulları sağlanmış olur.

Örneğin, $|f_i(u) - f_i(v)| \leq L_i |u - v| \quad \forall u, v \in R, u \neq v$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir:

[12, 15, 16, 17, 19, 20, 26, 27, 29, 31, 32, 33, 42, 45, 49, 51, 57, 61, 63, 64, 65, 74, 78, 84, 93, 95]

4. tip aktivasyon fonksiyonu

Yapı olarak 3. tip aktivasyon fonksiyonunun aynısı olmakla beraber sınır değerleri farklılık göstermektedir, buna göre 3. tip fonksiyona göre daha genel bir şart sağlamaktadır.

Bu aktivasyon fonksiyon türü hem normal sigmoid aktivasyon fonksiyonlarının hem de parçalı doğrusal fonksiyonun daha genel halidir:

$$f_i = \frac{1}{2}(|x + 1| - |x - 1|)$$

$$0 \leq |f_i(u) - f_i(v)| \leq L_i|u - v| \quad \forall u, v \in \mathbb{R}, u \neq v$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [13, 18, 25]

5. tip aktivasyon fonksiyonu

Yapı olarak 3. ve 4. aktivasyon fonksiyonuna benzer ancak sınır değerleri farklıdır.

$$|f_i(x, y) - f_i(u, v)| \leq \alpha_j|x - u| + \beta_j|y - v|$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [60]

6. tip aktivasyon fonksiyonu

Yapı olarak 3. aktivasyon fonksiyonuna benzer ancak $f(u)$ için de bir sınır bulunmaktadır.

$$|f(u) - f(v)| \leq L_f|u - v|, \quad |f(u)| \leq M_f$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [76]

7. tip aktivasyon fonksiyonu

Kullanılan aktivasyon fonksiyonlarından biri de sigmoid fonksiyonudur ve şu şekilde tanımlanır:

$$f_i(\cdot) = \begin{cases} f_i(0) = 0, f_i(x_i) \in C(\mathbb{R}, \mathbb{R}), D^+f_i(x_i) \geq 0 \\ |f_i(x_i)| \leq k_i, \quad \forall x_i \in \mathbb{R} \end{cases}$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [52, 83]

8. tip aktivasyon fonksiyonu

$$|f_i(x)| \leq l_i|x|, \quad \forall x \in \mathbb{R}, i = 1, 2, \dots, n$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [38]

9. tip aktivasyon fonksiyonu

$$u_{\bar{1}j} \leq \frac{\tilde{f}_j(k_1, k_3) - \tilde{f}_j(k_2, k_3)}{k_1 - k_2} \leq u_{1j}^+$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [43]

10. tip aktivasyon fonksiyonu

Doygunluk Fonksiyonu:

$$\text{sat}(x_i(t)) = \begin{cases} x_i(t), & |x_i(t)| \leq x_i^{\max} \\ \text{sign}(x_i(t)), & |x_i(t)| > x_i^{\max} \end{cases}$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [13]

11. tip aktivasyon fonksiyonu

$f(\cdot)$ sınırlıdır ve aşağıda verilen şartı sağlamaktadır:

$$\|f(x)\| \leq \|Gx\| \text{ where } G \in \mathbb{R}^{n \times n} \text{ bilinen bir sabit matristir.}$$

Literatürde, bu tipteki aktivasyon fonksiyonunu kullanan çalışmalar şu şekildedir: [58]

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında, Nötral Tipteki Yapay Sinir Ağlarına ait modeller incelenmiş ve çeşitli özelliklerine göre sınıflandırılmıştır. Bu amaç doğrultusunda, Nötral Tipteki Yapay Sinir Ağı modelleri taranmış, elde edilen çalışmalar modellere ayrıştırılmış ve detaylı bir inceleme yapılarak yorumlanmıştır. İncelenen çalışmalar; gecikmelerine göre, kararlılık tipine göre ve aktivasyon fonksiyonlarına göre analiz edilmiştir.

İncelenen Nötral Tipteki Yapay Sinir Ağlarına ait 95 çalışma sonucunda;

Çalışmalar gecikmelerine göre olmak üzere $x(t - \tau)$, $x_j(t - \tau)$, $x_j(t - \tau_j)$, $x_j(t - \tau_{ij})$, $x(t - \tau(t))$, $x_j(t - \tau(t))$, $x_j(t - \tau_j(t))$, $x_j(t - \tau_{ij}(t))$, $x(t - \tau_j(t))$, $x_{ij}(t - \tau)$, $x_j(t - \tau_j^{(k)})$, $x_j(t - \tau_j^{(k)})$, $x(t - \tau_i(t) - \tau_j(t))$ olmak üzere 13 sınıfa, kararlılık özelliklerine göre global, stokastik ve robust olmak üzere 3 sınıfa, kararlılık türüne göre üstel ve asimtotik olmak üzere 2 sınıfa, gecikmeye bağlı olup olmama durumlarına göre ise, gecikme bağımlı, gecikme bağımsız ve tanımlanamamış tipler olmak üzere 3'e ayrılmıştır. Ayrıca aktivasyon fonksiyonlarına göre de 11 tip olarak gruplandırılmıştır.

Bu tez çalışmasının sonunda, Nötral Tipteki Yapay Sinir Ağı çalışmaları incelenmiştir. Bu alanda yapılan çalışma sayısı oldukça az olduğundan bu tez çalışmasının literatüre bir katkı sağlanması beklenmektedir.

Nötral Tipteki Yapay Sinir Ağına ait sistemler ve modeller oldukça karmaşık sistemlerdir bu sebeple, bu konu üzerine yapılan her çalışma sistemi kolaylaştıracak niteliktedir.

Bu tez çalışması Nötral Tipteki Yapay Sinir Ağı çalışmalarını içeren detaylı bir derleme çalışmasıdır. Tez çalışması bir derleme niteliği taşıdığından modellerin sınıflandırılması büyük önem taşıdığı düşünülmektedir.

KAYNAKLAR

- [1] Simon, H., 1999. Neural Networks, Prentice-Hall, New Jersey.
- [2] Forti, M., Manetti, S., Marini, M., 1992. A Condition for Global Convergence of a Class of Symmetric Neural Circuits, IEEE Transactions on Circuits and Systems- I, 39, 480-483.
- [3] Abe, S., Gee, A. H., 1995. A Condition for Global Convergence of a Class of Symmetric Neural Circuits, IEEE Transactions on Circuits and Systems-II, 42, 39-45.
- [4] Fang, Y., Kincaid, T. K., 1995. Stability Analysis of Dynamical Neural Networks, IEEE Transactions on Neural Networks, 7, 4, 996-1006.
- [5] Kelly, D. G., 1990. Stability in Contractive Nonlinear Neural Networks, IEEE Trans.Biomed.Eng., 3, 231-242.
- [6] Gopalsamy, K., He, X. 1994. Stability in Asymmetric Hopfield Nets with Transmission Delays, Physica D, 76, 344-358.
- [7] Arik, S., 2002. An Improved Global Stability Result for Delayed Cellular Neural Networks, IEEE Transactions on Circuits and Systems-I, 49, 1211-1214.
- [8] Joy, M., 1999. On the Global Convergence of a Class of Differential Equations with Applications in Neural Networks, Journal Mathematical Analysis and Applications, .232, 61-81.
- [9] Liao, X., Chen, G, Sanchez, E. N., 2002. LMI-Based Approach for Asymptotic Stability Analysis of Delayed Neural Networks, IEEE Transactions on Circuits and Systems-I, 49, 1033-1039.
- [10] Grujic, L.T., Michel, A.N., 1991. Exponential Stability and Trajectory Bounds of Neural Networks Under Variations, IEEE Transactions on Circuits and Systems, 38, 1182-1192.
- [11] Xu, S., Lam, J., Ho, D. W. C., Zou, Y., 2005. Delay-dependent exponential stability for a class of neural networks with time delays, Journal of Computational and Applied Mathematics. 183, 16–28.
- [12] Cheng, C., Liao, T., Yan, J., Hwang, C., 2006. Globally Asymptotic Stability of a Class of Neutral-Type Neural Networks With Delays, IEEE Transactions On Systems, Man, And Cybernetics - Part B. 36, 1191-1195.
- [13] Rakkiyappan, R., Balasubramaniam, P., 2008. LMI conditions for global asymptotic stability results for neutral-type neural networks with distributed time delays, Applied Mathematics and Computation. 204, 317–324.
- [14] Park, J. H., Kwon, O.M., Lee, S.M. 2008. LMI optimization approach on stability for delayed neural networks of neutral-type, Applied Mathematics and Computation. 196, 236–244.

- [15] Park, J. H., Park, C.H., Kwon, O.M., Lee, S.M., 2008. A new stability criterion for bidirectional associative memory neural networks of neutral-type, *Applied Mathematics and Computation*. 199, 716–722.
- [16] Lien, C., Yu, K., Lin, Y., Chung, Y., Chung, L., 2008. Global Exponential Stability for Uncertain Delayed Neural Networks of Neutral Type With Mixed Time Delays, *IEEE Transactions On Systems, Man, And Cybernetics –Part B*. 38, 709-720.
- [17] Park, J. U. H., Kwon, O. M., 2008. Analysis On Global Stability Of Stochastic Neural Networks Of Neutral Type, *Modern Physics Letters B*. 22, 3159–3170.
- [18] Rakkiyappan, R., Balasubramaniam, P., 2008. New global exponential stability results for neutral type neural networks with distributed time delays, *Neurocomputing*. 71, 1039–1045.
- [19] Samli, R., Arik, S., 2009. New results for global stability of a class of neutral-type neural systems with time delays, *Applied Mathematics and Computation*. 210, 564–570.
- [20] Lien, C., Yu, K., Lin, Y., Chung, Y. J., Chung, L. Y., 2009. Exponential convergence rate estimation for uncertain delayed neural networks of neutral type, *Chaos, Solitons and Fractals*. 40, 2491–2499.
- [21] Park, J. H., Kwon, O. M., 2009. Global stability for neural networks of neutral-type with interval time-varying delays, *Chaos, Solitons and Fractals*. 41, 1174–1181.
- [22] Lou, X., Cui, B., 2009. Stochastic stability analysis for delayed neural networks of neutral type with Markovian jump parameters, *Chaos, Solitons and Fractals*. 39, 2188–2197.
- [23] Su, W., Chen, Y., 2009. Global asymptotic stability analysis for neutral stochastic neural networks with time-varying delays, *Communications in Nonlinear Science and Numerical Simulation*. 14, 1576–1581.
- [24] Liu, L., Han, Z., Li, W., 2009. Global stability analysis of interval neural networks with discrete and distributed delays of neutral type, *Expert Systems with Applications*. 36, 7328–7331.
- [25] Rakkiyappan, R., Balasubramaniam, P., 2009. Global exponential stability results for delayed neural networks of neutral type, *International Journal of Computer Mathematics*. 86(9), 1591–1602.
- [26] Mai, H., Liao, X., Li, C., 2009. A semi-free weighting matrices approach for neutral-type delayed neural networks, *Journal of Computational and Applied Mathematics*. 225, 44–55.
- [27] Zhu, J., Zhang, Q., Yang, C., 2009. Delay-dependent robust stability for Hopfield neural networks of neutral-type, *Neurocomputing*. 72, 2609–2617.
- [28] Feng, J., Xu, S., Zou, Y., 2009. Delay-dependent stability of neutral type neural networks with distributed delays, *Neurocomputing*. 72, 2576–2580.

- [29] Liu, J., Zong, G., 2009. New delay-dependent asymptotic stability conditions concerning BAM neural networks of neutral type, *Neurocomputing*. 72, 2549–2555.
- [30] Li, X., 2010. Global robust stability for stochastic interval neural networks with continuously distributed delays of neutral type, *Applied Mathematics and Computation*. 215, 4370–4384.
- [31] Mahmoud, M. S., Ismail, A., 2010. Improved results on robust exponential stability criteria for neutral-type delayed neural networks, *Applied Mathematics and Computation*. 217, 3011–3019.
- [32] Zhang, H., Liu, Z., Huang, G., 2010. Novel Delay-Dependent Robust Stability Analysis for Switched Neutral-Type Neural Networks With Time-Varying Delays via SC Technique, *IEEE Transactions On Systems, Man, And Cybernetics—Part B*. 40, 1480–1491.
- [33] Balasubramaniam, P., Rakkiyappan, R., 2010. Global exponential stability for neutral-type BAM neural networks with time-varying delays, *International Journal of Computer Mathematics*. 87, 2064–2075.
- [34] Sakthivel, R., Samidurai, R., Anthoni, S. M., 2010. Exponential Stability for Stochastic Neural Networks of Neutral Type with Impulsive Effects, *Modern Physics Letters B*. 24, 1099–1110.
- [35] Gan, Q., Xu, R., 2010. Global Robust Exponential Stability of Uncertain Neutral High-Order Stochastic Hopfield Neural Networks with Time-Varying Delays, *Neural Processing Letters*. 32, 83–96.
- [36] Li, X., Cao, J., 2010. Delay-dependent stability of neural networks of neutral type with time delay in the leakage term, *Nonlinearity*. 23, 1709–1726.
- [37] Rakkiyappan, R., Balasubramaniam, P., Cao, J., 2010. Global exponential stability results for neutral-type impulsive neural networks, *Nonlinear Analysis: Real World Applications*. 11, 122–130.
- [38] Zong, G., Liu, J., Zhang, Y., Hou, L., 2010. Delay-range-dependent exponential stability criteria and decay estimation for switched Hopfield neural networks of neutral type, *Nonlinear Analysis: Hybrid Systems*. 4, 583–592.
- [39] Samidurai, R., Anthoni, S. M., Balachandran, K., 2010. Global exponential stability of neutral-type impulsive neural networks with discrete and distributed delays, *Nonlinear Analysis: Hybrid Systems*. 4, 103–112.
- [40] Zhang, H., Dong, M., Wang, Y., Sun, N., 2010. Stochastic stability analysis of neutral-type impulsive neural networks with mixed time-varying delays and Markovian jumping, *Neurocomputing*. 73, 2689–2695.
- [41] Chen, H., Zhang, Y., Hu, P., 2010. Novel delay-dependent robust stability criteria for neutral stochastic delayed neural networks, *Neurocomputing*. 73, 2554–2561.

- [42] Wang, K., Zhu, Y., 2010. Stability of almost periodic solution for a generalized neutral-type neural networks with delays, *Neurocomputing*. 73, 3300–3307.
- [43] Zhu, Q., Cao, J., 2010. Stability analysis for stochastic neural networks of neutral type with both Markovian jump parameters and mixed time delays, *Neurocomputing*. 73, 2671–2680.
- [44] Lee, S. M., Kwon, O. M., Park, J. H., 2010. A novel delay-dependent criterion for delayed neural networks of neutral type, *Physics Letters A*. 374, 1843–1848.
- [45] Liu, G., Yang, S. X., 2011. Stability Criterion for BAM Neural Networks of Neutral-Type with Interval Time-Varying Delays, *Procedia Engineering*. 15, 28.
- [46] Lakshmanan, S., Balasubramaniam, P., 2011. New results of robust stability analysis for neutral-type neural networks with time-varying delays and Markovian jumping parameters, *Canadian Journal of Physics*. 89, 827–840.
- [47] Muralisankar, S., Gopalakrishnan, N., Balasubramaniam, P., 2011. Robust Exponential Stability Criteria for T–S Fuzzy Stochastic Delayed Neural Networks of Neutral Type, *Circuits, Systems, and Signal Processing*. 30, 1617–1641.
- [48] Bao, H., Cao, J., 2011. Stochastic global exponential stability for neutral-type impulsive neural networks with mixed time-delays and Markovian jumping parameters, *Communications in Nonlinear Science and Numerical Simulation*. 16, 3786–3791.
- [49] Balasubramaniam, P., Vembarasan, V., 2011. Asymptotic stability of BAM neural networks of neutral-type with impulsive effects and time delay in the leakage term, *International Journal of Computer Mathematics*. 88, 3271–3291.
- [50] Lu, C., 2011. A delay-dependent approach to robust control for neutral uncertain neural networks with mixed interval time-varying delays, *Nonlinearity*. 24, 1121–1136.
- [51] Wang, X., Li, S., Xu, D. 2011. Globally exponential stability of periodic solutions for impulsive neutral-type neural networks with delays, *Nonlinear Dynamics*. 64, 65–75.
- [52] Luo, Q., Zeng, Z., Liao, X., 2011. Global exponential stability in Lagrange sense for neutral type recurrent neural networks, *Neurocomputing*. 74, 638–645.
- [53] Pan, T., Shi, B., Yuan, J., 2012. Global Stability of Almost Periodic Solution of a Class of Neutral-Type BAM Neural Networks, *Abstract and Applied Analysis*.
- [54] Liu, G., Zhou, S., Huang, H., 2012. New LMI-Based Conditions on Neural Networks of Neutral Type with Discrete Interval Delays and General Activation Functions, *Abstract and Applied Analysis*.
- [55] Park, M. J., Kwon, O. M., Park, J. H., Lee, S. M., 2012. Simplified stability criteria for fuzzy Markovian jumping Hopfield neural networks of neutral type with interval time-varying delays, *Expert Systems with Applications*. 39, 5625–5633.

- [56] Zheng, C., Li, J., Wang, Z., 2012. New stability criteria for neutral-type Cohen–Grossberg neural networks with discrete and distributed delays, *International Journal of Computer Mathematics*. 89, 443–466.
- [57] Chen, B., Yu, L., Zhang, W., 2011. Exponential stability analysis for neutral BAM neural networks with time-varying delays and stochastic disturbances, *Journal of Control Theory and Applications*. 10, 92–99.
- [58] Zhang, W., Wang, L., 2012. Robust Stochastic Stability Analysis for Uncertain Neutral-Type Delayed Neural Networks Driven by Wiener Process, *Journal of Applied Mathematics*.
- [59] Liu, G., Yang, S. X., Fu, W. 2012. New Robust Stability of Uncertain Neutral-Type Neural Networks with Discrete Interval and Distributed Time-Varying Delays, *Journal Of Computers*. 7, 264-271.
- [60] Zhang, Z., Liu, W., Zhou, D., 2012. Global asymptotic stability to a generalized Cohen–Grossberg BAM neural networks of neutral type delays, *Neural Networks*. 25, 94–105.
- [61] Zhang, Z., Liu, K., Yang, Y., 2012. New LMI-based condition on global asymptotic stability concerning BAM neural networks of neutral type, *Neurocomputing*. 81, 24–32.
- [62] Liu, Y., Wang, Z., Liu, X., 2012. Stability analysis for a class of neutral-type neural networks with Markovian jumping parameters and mode-dependent mixed delays, *Neurocomputing*. 94, 46–53.
- [63] Orman, Z., 2012. New sufficient conditions for global stability of neutral-type neural networks with time delays, *Neurocomputing*. 97, 141–148.
- [64] Gao, Y., Zhou, W., Ji, C., Tong, D., Fang, J., 2012. Globally exponential stability of stochastic neutral-type delayed neural networks with impulsive perturbations and Markovian switching, *Nonlinear Dynamics*. 70, 2107–2116.
- [65] Orman, Z., Arik, S., 2013. An Analysis of Stability of a Class of Neutral-Type Neural Networks with Discrete Time Delays, *Abstract and Applied Analysis*.
- [66] Liu, P., 2013. Improved delay-dependent stability of neutral type neural networks with distributed delays, *ISA Transactions*. 52, 717–724.
- [67] Huang, H., Du, Q., Kang, X., 2013. Global exponential stability of neutral high-order stochastic Hopfield neural networks with Markovian jump parameters and mixed time delays, *ISA Transactions*. 52, 759–767.
- [68] Liu, G., Yang, S. X., Chai, Y., Feng, W., Fu, W., 2013. Robust stability criteria for uncertain stochastic neural networks of neutral-type with interval time-varying delays, *Neural Computing and Applications*. 22, 349–359.

- [69] Lakshmanan, S., Park, J. H., Jung, H. Y., Kwon, O. M., Rakkiyappan, R., 2013. A delay partitioning approach to delay-dependent stability analysis for neutral type neural networks with discrete and distributed delays, *Neurocomputing*. 111, 81–89.
- [70] Chen, W., Wang, L., 2013. Delay-dependent stability for neutral-type neural networks with time-varying delays and Markovian jumping parameters, *Neurocomputing*. 120, 569–576.
- [71] Zhang, G., Lin, X., Zhang, X., 2014. Exponential Stabilization of Neutral-Type Neural Networks with Mixed Interval Time-Varying Delays by Intermittent Control: A CCL Approach, *Circuits, Systems and Signal Processing*. 33, 371–391.
- [72] Mathiyalagan, K., Sakthivel, R., Marshal Anthoni, S., 2014. Robust exponential stability and H_∞ control for switched neutral-type neural networks, *International Journal Of Adaptive Control And Signal Processing*. 28, 429–443.
- [73] Rakkiyappan, R., Zhu, Q., Chandrasekar, A., 2014, Stability of stochastic neural networks of neutral type with Markovian jumping parameters: A delay-fractioning approach, *Journal of the Franklin Institute*. 351, 1553–1570.
- [74] Arik, S., 2014. An analysis of stability of neutral-type neural systems with constant time delays, *Journal of the Franklin Institute*. 351, 4949–4959.
- [75] Muralisankar, S., Gopalakrishnan, N., 2014. Robust stability criteria for Takagi–Sugeno fuzzy Cohen–Grossberg neural networks of neutral type, *Neurocomputing*. 144, 516–525.
- [76] Xu, C., Zhang, Q., Wu, Y., 2014. Existence and stability of pseudo almost periodic solutions for shunting inhibitory cellular neural networks with neutral type delays and time-varying leakage delays, *Network: Computation in Neural Systems*. 25(4), 168–192.
- [77] Raja, R., Zhu, Q., Senthilraj, S., Samidurai, R., 2015. Improved stability analysis of uncertain neutral type neural networks with leakage delays and impulsive effects, *Applied Mathematics and Computation*. 266, 1050–1069.
- [78] Kao, Y., Xie, J., Wang, C., Karimi, H. R., 2015. A sliding mode approach to H_∞ non-fragile observer-based control design for uncertain Markovian neutral-type stochastic systems, *Automatica*. 52, 218–226.
- [79] Shi, K., Zhu, H., Zhong, Zeng, S. Y., Zhang, Y., Wang, W., 2015. Stability analysis of neutral type neural networks with mixed time-varying delays using triple-integral and delay-partitioning methods, *ISA Transactions*. 58, 85–95.
- [80] Shi, K., Zhu, H., Zhong, S., Zeng, Y., Zhang, Y., 2015. New stability analysis for neutral type neural networks with discrete and distributed delays using a multiple integral approach, *Journal of the Franklin Institute*. 352, 155–176.
- [81] Liao, X., Liu, Y., Wang, H., Huang, T., 2015. Exponential estimates and exponential stability for neutral-type neural networks with multiple delays, *Neurocomputing*. 149, 868–883.

- [82] Zhou, L., Wang, Z., Hu, X., Chu, B., Zhou, W., 2015. Adaptive almost sure asymptotically stability for neutral-type neural networks with stochastic perturbation and Markovian switching, *Neurocomputing*. 156, 151–156.
- [83] Jian, J., Wang, B., 2015. Stability analysis in Lagrange sense for a class of BAM neural networks of neutral type with multiple time-varying delays, *Neurocomputing*. 149, 930–939.
- [84] Arthi, G., Park, J. H., Jung, H. Y., Yoo, J. H., 2015. Exponential stability criteria for a neutral type stochastic single neuron system with time-varying delays, *Neurocomputing*. 154, 317–324.
- [85] Shi, K., Zhong, S., Zhu, H., Liu, X., Zeng, Y., 2015. New delay-dependent stability criteria for neutral-type neural networks with mixed random time-varying delays, *Neurocomputing*. 168, 896–907.
- [86] Xia, J., Park, J. H., Zeng, H., 2015. Improved Delay-dependent Robust Stability Analysis for Neutral-type Uncertain Neural Networks with Markovian jumping Parameters and Time-varying Delays, *Neurocomputing*. 149, 1198–1205.
- [87] Zheng, C., Gu, Y., Liang, W., Wang, Z., 2015. Novel delay-dependent stability criteria for switched Hopfield neural networks of neutral type, *Neurocomputing*. 158, 117–126.
- [88] Liu, B., 2015. Pseudo almost periodic solutions for neutral type CNNs with continuously distributed leakage delays, *Neurocomputing*. 148, 445–454.
- [89] Qiu, J., Cao, J., 2016. Delay-dependent Robust Stability of Neutral-type Neural Networks with Time Delays, *Journal of Mathematical Control Science and Applications*. 2, 29–38.
- [90] Senthilraj, S., Raja, R., Jiang, F., Zhu, Q., Samidurai, R., 2016. New delay-interval-dependent stability analysis of neutral type BAM neural networks with successive time delay components, *Neurocomputing*. 171, 1265–1280.
- [91] Yin, C., Cheng, Y., Huang, X., Zhong, S., Li, Y., Shi, K., 2016. Delay-partitioning approach design for stochastic stability analysis of uncertain neutral-type neural networks with Markovian jumping parameters, *Neurocomputing*. 207, 437–449.
- [92] Peng, W., Wu, Q., Zhang, Z., 2016. LMI-based global exponential stability of equilibrium point for neutral delayed BAM neural networks with delays in leakage terms via new inequality technique, *Neurocomputing*. 199, 103–113.
- [93] Song, Y., Sun, W., Jiang, F., 2016. Mean-square exponential input-to-state stability for neutral stochastic neural networks with mixed delays, *Neurocomputing*. 205, 195–203.
- [94] Weera, W., Niamsup, P., 2016. Novel delay-dependent exponential stability criteria for neutral-type neural networks with non-differentiable time-varying discrete and neutral delays, *Neurocomputing*. 173, 886–898.

- [95] Zheng, M., Li, L., Peng, H., Xiao, J., Yang, Y., Zhao, H., 2017. Finite-time stability analysis for neutral-type neural networks with hybrid time-varying delays without using Lyapunov method, *Neurocomputing*, 238, 67–75.
- [96] Lakshmanan, S., Lima, C. P., Prakash, M., Nahavandi, S., Balasubramaniam, P., 2017. Neutral-type of delayed inertial neural networks and their stability analysis using the LMI Approach, *Neurocomputing*, 230, 243–250.
- [97] Xiong, W., Shi, Y., Cao, J., 2017. Stability analysis of two-dimensional neutral-type Cohen–Grossberg BAM neural networks, *Neural Computing and Applications*, 28(4), 703-713.
- [98] Samidurai, R., Rajavel, S., Sriraman, R., Cao, J., Alsaedi, A., Alsaadi, F. E., 2017. Novel results on stability analysis of neutral-type neural networks with additive time-varying delay components and leakage delay, *International Journal of Control, Automation and Systems*, 15(4), 1888–1900.
- [99] Ma, Y., Ma, N., Chen, L., Zheng, Y., Han, Y., 2017. Exponential stability for the neutral-type singular neural network with time-varying delays, *International Journal of Machine Learning and Cybernetics*, yayın aşamasında.
- [100] Ali, M. S., Saravanan, S., Rani, M. E., Elakkia, S., Cao, J., Alsaedi, A., Hayat, T., 2017. Asymptotic Stability of Cohen–Grossberg BAM Neutral Type Neural Networks with Distributed Time Varying Delays, *Neural Processing Letters*, 46(3), 991-1007.
- [101] Xu, D., Tan, M., 2017. Delay-independent stability criteria for complex-valued BAM neutral-type neural networks with time delays, *Nonlinear Dynamics*, 89(2), 819-832.
- [102] Samidurai, R., Rajavel, S., Cao, J., Alsaedi, A., Alsaadi, F., Ahmad, B., 2017. Delay-partitioning approach to stability analysis of state estimation for neutral-type neural networks with both time-varying delays and leakage term via sampled-data control, *International Journal of Systems Science*, 48(8), 1752-1765.
- [103] Manivannan, R., Samidurai, R., Cao, J., Alsaedi, A., Alsaadi, F. E., 2018. Delay-dependent stability criteria for neutral-type neural networks with interval time-varying delay signals under the effects of leakage delay, *Advances in Difference Equations*, yayın aşamasında.
- [104] Aouti, C., Gharbia, I. B., Cao, J., M'hamdi, M. S., Alsaedi, A., 2018. Existence and global exponential stability of pseudo almost periodic solution for neutral delay BAM neural networks with time-varying delay in leakage terms, *Chaos, Solitons & Fractals*, 107, 111-127.
- [105] Zhang, G., Wang, T., Li, T., Fei, S., 2018. Multiple integral Lyapunov approach to mixed-delay-dependent stability of neutral neural networks, *Neurocomputing*, 275, 1782-1792.

ÖZGEÇMİŞ

Kişisel Bilgiler

| | |
|----------------|------------------------|
| Adı Soyadı | ZELİHA DOĞAN |
| Doğum Yeri | ŞİŞLİ |
| Doğum Tarihi | 12.07.1994 |
| Uyruğu | T.C. |
| E-Posta Adresi | zelihadogan2@gmail.com |

Eğitim Bilgileri

Lisans

| | |
|----------------|---|
| Üniversite | ALTINBAŞ ÜNİVERSİTESİ |
| Fakülte | MÜHENDİSLİK VE DOĞA BİLİMLERİ FAKÜLTESİ |
| Bölümü | BİLGİSAYAR MÜHENDİSLİĞİ (İNGİLİZCE) |
| Mezuniyet Yılı | 2017 |

Yüksek Lisans

| | |
|----------------|----------------------------------|
| Üniversite | İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA |
| Enstitü Adı | LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ |
| Anabilim Dalı | BİLGİSAYAR MÜHENDİSLİĞİ |
| Programı | BİLGİSAYAR MÜHENDİSLİĞİ |
| Mezuniyet Yılı | 2019 |

Makale ve Bildiriler

Zeliha DOGAN, Eylem YUCEL, Ruya SAMLI, A Survey About Neutral Type BAM Neural Networks, 5th International Conference on Engineering and Natural Science (ICENS), 12-16 Haziran 2019, Prag/ÇEKYA.