



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



YÜKSEK LİSANS TEZİ

BULANIK YAPAY SİNİR AĞLARININ DİNAMİK DAVRANIŞ ANALİZİ

Nilay SALT

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

**DANIŞMAN
Yrd. Doç. Dr. Sibel SENAN**

Haziran, 2016

İSTANBUL

S. Senan

Bu çalışma 15.06.2016 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Programında Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Jürisi:




Yrd. Doç. Dr. Sibel SENAN(Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi




Prof. Dr. Ahmet SERTBAŞ
İstanbul Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Sabri ARIK
İstanbul Üniversitesi
Mühendislik Fakültesi



Doç. Dr. Fethullah KARABİBER
Yıldız Teknik Üniversitesi
Mühendislik Fakültesi



Yrd. Doç. Dr. Tolga ENSARİ
İstanbul Üniversitesi
Mühendislik Fakültesi

ÖNSÖZ

Yüksek lisans öğrenimim sırasında ve tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Yard. Doç. Dr. Sibel SENAN’a en içten dileklerimle teşekkür ederim.

Bu çalışma boyunca bana her zaman destek olan aileme teşekkürü borç bilirim.

Haziran, 2016

Nilay SALT

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	i
İÇİNDEKİLER	ii
ŞEKİL LİSTESİ	iv
TABLO LİSTESİ	v
SİMGE VE KISALTMA LİSTESİ	vi
ÖZET	vii
SUMMARY	viii
1. GİRİŞ	1
1.1. YAPAY SİNİR AĞLARI(YSA)	1
1.2. BİYOLOJİK SİNİR AĞLARI (BSA)	2
1.3. YAPAY SİNİR AĞI - BİYOLOJİK SİNİR AĞI	2
1.4. YAPAY SİNİR AĞI ÇEŞİTLERİ	3
1.5. YAPAY SİNİR AĞLARINDA ÖĞRENME	4
1.6. BULANIK YAPAY SİNİR AĞLARI (BYSA)	5
1.7. HÜCRESEL SİNİR AĞLARI (HSA)	6
1.8. BULANIK HÜCRESEL SİNİR AĞLARI (BHSA)	7
1.9. KARARLILIK ÇALIŞMALARI	9
2. GENEL KISIMLAR	11
3. MALZEME VE YÖNTEM	12
3.1. NORMLAR	13
3.1.1. Öklit Uzayı	13
3.1.2. Vektör ve Matris Normları	13
3.2. MATRİS SINIFLARI VE ÖZELLİKLERİ	13

3.3. DOĞRUSAL OLMAYAN SİSTEMLERDE KARARLILIK ANALİZİ	16
3.3.1. Lyapunov Kararlılık Teoremi	16
3.3.2. M-Matris Teoremi	17
3.3.3. Young Eşitsizliği	17
3.3.4. Lineer Matris Eşitsizliği	17
3.3.5. Brownian Hareketi	18
3.3.6. Ito Kuralı	18
3.3.7. Sabit Nokta Teoremi	18
3.3.8. Jensen İntegral Eşitsizliği	19
3.3.9. Kuadratik Konveks Birleştirme	19
3.3.10. Tesadüf Derecesinin Devamı Teoremi	19
3.3.11. Homeomorfizma Haritalama Teoremi	19
3.3.12. M-koni Tanımı	19
3.3.13. Negatif Olmayan Matrislerin Spektral Yarıçapının Özuzayı	20
3.3.14. Dürtüsel Başlangıç Koşullu İntegro Diferansiyel Eşitsizliği	20
3.3.15. Aktivasyon Fonksiyonları	21
4. BULGULAR	25
4.1. BULANIK HÜCRESEL SİNİR AĞI MODELLERİ	25
4.2. BULANIK HÜCRESEL SİNİR AĞLARININ KARARLILIK ANALİZİ ÇALIŞMALARINDA KULLANILAN YÖNTEMLERİN ANALİZİ	62
4.3. BULANIK HÜCRESEL SİNİR AĞLARININ KARARLILIK ANALİZİNDE LYAPUNOV TEOREMİ KULLANILAN ÇALIŞMALARIN ANALİZİ	67
5. TARTIŞMA VE SONUÇ	83
KAYNAKLAR	87
ÖZGEÇMİŞ	96

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1: Sinir Hücresi.	3
Şekil 1.2: Hücresel Sinir Ağı.	6

TABLO LİSTESİ

	Sayfa No
Tablo 5.1: Yıllara göre yapılan çalışma sayısı.	84
Tablo 5.2: Kararlılık türüne göre yapılan çalışmalar.	84
Tablo 5.3: Kararlılık analizinde kullanılan yöntemler.	85

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
BSA	:Biyolojik Sinir Ağı
BHSA	:Bulanık Hücresel Sinir Ağı
BYSA	:Bulanık Yapay Sinir Ağı
HSA	:Hücresel Sinir Ağı
MAX	:Maximum
MIN	:Minimum
YSA	:Yapay Sinir Ağı

ÖZET

YÜKSEK LİSANS TEZİ

BULANIK YAPAY SİNİR AĞLARININ DİNAMİK DAVRANIŞ ANALİZİ

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman : Yard. Doç. Dr. Sibel SENAN

Bu tez çalışmasında bulanık hücresel sinir ağlarının modelleri, bu modellerde kullanılan kararlılık analizi yöntemleri ve kararlılık analizinde önemli bir yeri olan Lyapunov fonksiyonları incelenerek dinamik davranış analizi yapılmıştır. Tez çalışması kapsamında bulanık hücresel sinir ağlarının kararlılığı ile ilgili literatürdeki tüm çalışmalar taranmış, çalışmalar ilk olarak modellere ayrıştırılmış ve detaylı modelleri sunulmuştur. Daha sonra her bir model için kullanılan kararlılık yöntemleri çıkarılmış ve Lyapunov Teoremini kullanan çalışmaların ayrı bir analizi yapılarak özel olarak ele alınmıştır. Bulanık hücresel sinir ağlarının literatüre kazandırıldığı ilk günden, günümüze kadar (1996- 2015 yılları arasında) kararlılık analizi ile ilgili yapılmış tüm çalışmaları içeren detaylı bir survey çalışması yapılmıştır.

Haziran 2016, 104 Sayfa

Anahtar Kelimeler: Kararlılık Analizi, Bulanık Hücresel Sinir Ağları, Lyapunov Fonksiyonları

SUMMARY

M.Sc. THESIS

ANALYSIS OF DYNAMICAL BEHAVIOUR OF FUZZY NEURAL NETWORKS

Istanbul University

Institute of Graduate Studies in Science and Engineering

Department of Computer Engineering

Supervisor : Asst. Prof. Dr. Sibel SENAN

This thesis studies models of fuzzy cellular neural networks, stability analysis methods used in these models, and lyapunov functions as an important part of stability analysis methods for a dynamic behavior analysis. The thesis surveyed all studies related to the stability of fuzzy cellular neural networks, followed by breaking down the studies according to the model used and detailing the model itself. Then for each model, the stability analysis method was identified and studies using lyapunov theorem were separately analysed with a special emphasis. This culminated in a survey of all studies carried out since the introduction of fuzzy artificial neural networks into the literature up to date (between 1996-2015).

June 2016, 104 Pages

Keywords: Stability Analysis, Fuzzy Cellular Neural Networks, Lyapunov Functionals

1. GİRİŞ

1.1. YAPAY SİNİR AĞLARI(YSA)

Yapay sinir ağları (YSA), karmaşık gerçek dünya problemlerine insan beyninin bilgi edinme süreçlerini simüle ederek, sayısal modelleme ile çözüm sunan bilgisayar programlarıdır. Yapay sinir ağları veri işleme ve bilgi gösterimi için güçlü paralel hesaplamalar yapabilen, basit adaptif işlem elemanlarından oluşan yapılardır. Yapay sinir ağlarının bu temel işlem elemanları düğüm veya nöron olarak adlandırılır. YSA, her bir nöronun aşağıdaki transfer fonksiyonu işlevi gördüğü yönlü bir graf olarak tanımlanır:

$$y_i = f_i\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right) \quad (1)$$

burada y_i , i nöronunun çıktısı, x_j nöronun j inci girdisi ve w_{ij} i ve j nöronları arasındaki bağlantı ağırlığıdır. θ_i nöronun eşiğidir. f_i aktivasyon fonksiyonudur ve genellikle lineer olmayan sigmoid veya Gaussian fonksiyondur.

YSA'ların çekiciliği doğrusal olmama, yüksek paralellik, sağlamlık, arıza ve arıza toleransı, öğrenme, belirsiz ve bulanık bilgi işleme yeteneği ve genelleme yeteneği gibi biyolojik sistemlerin dikkat çekici bilgi işleme özelliklerinden gelmektedir. Burada doğrusal olmama özelliği; verilere daha iyi uyuma izin verir, gürültü duyarsızlığı; belirsiz veri ve ölçüm hataları varlığında doğru tahmin sağlar, yüksek paralellik; hızlı işlem ve yazılım hata toleransı sağlar, öğrenme ve uyarlanabilirlik; sisteme değişen ortama yanıt olarak içyapısını güncellemesi için izin verir.

Özellikle insan beyni üzerindeki yoğun araştırmalar vasıtasıyla, biyolojik sinir ağlardan ilham alarak ortaya çıkan YSA'ların ana fikri, biyolojik sistemlerin çalışmasını birebir kopyalamak değil, karmaşık problemlerin çözülmesinde biyolojik sinir ağların işlevselliğinden faydalan-

maktır. YSA'lar programlamayla değil, insanların yaptığı gibi uygun öğrenme örnekleri ile deneyimleme vasıtasıyla öğrenirler. Sinir ağları verideki örüntü ve ilişkileri tespit ederek bilgileri bir araya getirir.

YSA'lar sınıflandırma, tahmin, kontrol sistemleri, optimizasyon ve karar verme gibi birçok alanda çeşitli uygulamalarda kullanılmıştır[119],[120].

1.2. BİYOLOJİK SİNİR AĞLARI (BSA)


Biyolojik nöronlar sinir sisteminin ana yapı bloklarıdır. Bunlarla ilgili yapılan çalışmalar yapay nöron işlemlerini ve yapay sinir ağları ile biyolojik sinir ağları arasındaki benzerliği daha iyi anlamaya yardımcı olmuştur.

Ortalama bir insan beyni yaklaşık olarak 100 milyar nörondan oluşmaktadır. Her bir nöronun diğer bir nöronla 1000 - 10000 arasında bağlantısı vardır. Yapay sinir ağları nadiren birkaç yüz veya birkaç binden fazla işlem elemanından oluşur. Dolayısıyla yapay ağlar, insan beyninin karmaşıklığı ve entelektüel işlevlerinin birçoğunun hala tanınmamış olması nedeniyle insan beyniyle karşılaştırıldığında beklentilerin çok altındadır.

Biyolojik nöronlar, hücre aktivitelerinin kontrolünü gerçekleştiren hücre çekirdeğini içeren soma adı verilen hücre gövdesi, diğer nöronlardan aldığı sinyalleri hücre gövdesine ileten dendritler ve sinyalleri diğer nörona taşıyan aksonlar olmak üzere 3 ana fonksiyonel birimden oluşur. Uyarılar aksonlardan geçerek diğer nöron sinapsisine gelir ve bilgi ön işleminden geçirilerek bir sonraki sinir hücresinin dendritine bilginin ya tamamı iletilir ya da bilgi hiç iletilmez.

1.3. YAPAY SİNİR AĞI - BİYOLOJİK SİNİR AĞI

Biyolojik sinir ağları; dendritler, soma ve aksonlardan oluşan sinir hücrelerinin meydana getirdiği yapılardır. İki sinir hücre arası iletişimi sağlayan dendrit ve akson arasındaki boşluklara



Şekil 1.1: Sinir Hücresi.

sinaps adı verilir. Biyolojik nöronlar arasındaki sinyal iletimi sinapslar aracılığı ile sağlanır. Bir biyolojik nöronun çalışma mekanizması şu şekildedir;

1. Sinapslar aracılığı ile sinyaller hücrenin dendritine gelir.
2. Tüm dendritlerdeki sinyaller hücre gövdesinde toplanır.
3. Toplam sinyal değeri bir eşik değerinden büyükse nöron aksonu aracılığı ile diğer nöronlara uyarı sinyali gönderir.

Yapay sinir ağları, yapay nöronlardan oluşmuş, biyolojik sinir sisteminden ilham alınmış modellerdir. YSA'lerden, nöronlar olarak bilinen, bağlantılı bilgi işleme elemanlarının bir kümesi olarak bahsedilebilir. İşlem elemanları ağırlıklandırılmış girdiler, aktivasyon fonksiyonu ve bir çıktıdan oluşur. Burada, yapay nöron çevreden uyarıcıları girdi olarak alır, net bir girdi oluşturmak için onları ağırlıklandırılmış biçimde birleştirir ve doğrusal bir eşik kapısından geçirerek diğer nörona sinyali iletir.

1.4. YAPAY SİNİR AĞI ÇEŞİTLERİ

Yapay sinir ağları; öğrenme yöntemi, mimarisi, bağlantı yapısı gibi çeşitli kriterlere göre sınıflandırılabilir. YSA'lar genel olarak 3 ana kritere göre sınıflandırılır. Aşağıda detayları yer alan öğrenme yöntemlerine göre, YSA'lar öğreticili ve öğreticisiz öğrenmeli olarak sınıflandırılabilir.

Ağın kullandığı veriye göre sınıflandırma ise kalitatif ve kantitatif olarak yapılır. Kalitatif yöntemler kişi düşüncelerine bağlı veriler için, kantitatif yöntemler ise matematiksel modellere dayanan, elde yeterli sayısal veri olması halinde kullanılan yöntemlerdir. Bir diğer sınıflandırma yöntemi ise ağın yapısına göre yapılan sınıflandırmadır; ileri beslemeli sinir ağı ve geri beslemeli sinir ağı.

İleri beslemeli sinir ağı, işlem elemanları arasında döngünün olmadığı(işaretler tek yönlü olarak ileri doğru iletilir, geriye doğru geçişe izin vermez) ağlardır. Dolayısıyla girdiye hızlı karşılık üretirler. Geri beslemeli sinir ağı ise döngü içeren ağlardır(işaretler ileri ve geri olmak üzere çift yönlü iletilir). Girdiye yavaş karşılık üretirler ve bu nedenle öğrenme süreçleri ileri beslemeli ağlara kıyasla daha uzundur.

1.5. YAPAY SİNİR AĞLARINDA ÖĞRENME

Yapay sinir ağlarının genellikle mevcut eğitim örüntülerinden bağlantı ağırlıklarını öğren-mesi gerekmektedir. Bağlantı ağırlıklarında gerçekleştirilecek güncellemeler ile performans zamanla artırılır. Öğrenme sürecini anlamak ve oluşturmak için öncelikle sinir ağının faaliyet gösterdiği çevrenin bir modeli oluşturulmalıdır. Modelin oluşturulması bir öğrenme stratejisinin belirlenmesidir. İkincil olarak ağ ağırlıklarının hangi öğrenme kuralına göre güncelleneceği belirlenmelidir.

Öğreticili öğrenme, öğreticisiz öğrenme ve karma olmak üzere 3 ana öğrenme stratejisi vardır. Öğreticili öğrenmede ağ her bir örüntü modeli için arzu edilen çıktıyı sağlamalıdır. Ağırlıklar, ağın bilinen doğru cevaplara mümkün olduğunca en yakın cevapları üretmesi için bir korelasyona göre güncellenir. Öğreticisiz öğrenme, öğreticili öğrenmenin aksine eğitim veri kümesindeki her girdi modeli ile ilişkili doğru bir cevap gerektirmez. Verinin temel yapısını ve verideki modeller arasındaki korelasyonu araştırarak, bu korelasyonlardan modelleri kategorilere göre sınıflandırır. Öğreticili ve öğreticisiz öğrenme metodlarının her ikisinin de kullanıldığı karma öğrenmede diğerleri öğreticisiz öğrenme ile belirlenirken, ağırlıklar genellikle kısmi öğreticili öğrenme ile gerçekleştirilir.

Eğitim modellerinden bir çözüm tahmin etmek için bir öğrenme algoritması için gereken süre hesaplama karmaşıklığı olarak tanımlanır. Yüksek hesaplama karmaşıklığına sahip birçok öğrenme algoritması mevcuttur. Yapay ağ öğrenmeleri için etkili algoritmalar konusunda birçok aktif araştırma mevcuttur.

1.6. BULANIK YAPAY SİNİR AĞLARI (BYSA)

Bulanık mantık kullanılarak geliştirilen bulanık kural, son yıllarda aktif bir araştırma alanı haline gelmiştir [1]. Bulanık mantık, belirsizliği modelleme ve işleme için doğal bir araçtır. Dolayısıyla bulanık kurallar muğlak ve belirsiz bilgiye uygun bir yönetim sunması ile klasik üretim kurallarından üstündür. Sayısal değerler yerine dilsel etiketleri kullanarak bilgiyi temsil ederler. Böylece insanlar için daha anlaşılabilir ve kolay yorumlanabilirler.


Zadeh tarafından bulanık kümeler olarak ele alınmış, belirsiz veriler çoğu alanda mevcuttur[2]. Bir üyelik fonksiyonu ile temsil edilen bu belirsizlik, polinom bulanık fonksiyonlar[3,4], tarım [5], piyasa tahmini[6], görüntü işleme[7] gibi sezgisel hesaplamaadaki birçok uygulamada kullanılmıştır. Sezgisel hesaplama teknikleri olarak kullanılan YSA'lar üyelik fonksiyonları bulup ayarlama ve bulanık çıkarım yaklaşımları oluşturmada kullanılmalarına rağmen, karma teknikler kullanılan sezgisel hesaplama daha iyi sonuçlar vermektedir. Genetik hesaplama, bulanık mantık ve sinirsel hesaplama sezgisel hesaplama kullanılan başlıca tekniklerdir.

Hatalı verilerin çoğalması, bu tip veriler için uygun bir fonksiyon ihtiyacını doğurmuştur. BYSA lar aynı anda bulanık verileri alma ve giriş çıkış ilişkilerini incelemek için birleştirici teknikleri dolayısıyla bu uygun fonksiyonları bulmada kullanılabilirler. Bir bulanık yapay sinir ağı, parametreler üretmek için YSA'nın öğrenme algoritmalarını kullanan bulanık sistemdir[8]. Ürettiği parametreleri optimizasyonu sağlamak için uyarlar. BYSA sistemi yardımcı veya melez olmak üzere 2 tipte olabilir. Yardımcı sistemde bulanık sistemler ve YSA'lar birbirinden ayrı ve bağımsızdır. Melez sistemler ise bulanık mantık ve YSA'nın entegre olduğu sistemlerdir. Melez

sistemlere örnek olarak ANFIS, FuNe, Fuzzy RuleNet, GARIC verilebilir.

BYSA'lar için önerilen 2 öğrenme yöntemi vardır; geri yayılım algoritması ve genetik algoritmalar.

1.7. HÜCRESEL SINIR AĞLARI (HSA)



Şekil 1.2: Hücresel Sinir Ağı.

Hücresel Sinir Ağları gerçek zamanlı sinyaller işleyen, yerel bağımsız, düzenli olarak tekrar eden grid yapılı analog devreler olarak tanımlanabilir. HSA'ların temel devre elemanları hücrelerdir. Sinir ağındaki her bir hücre yalnızca en yakınındaki komşu hücrelerle bağlantılıdır[9]. Birbiriyle direkt bağlantılı olmayan hücreler, ağın sürekli zamanlı dinamiklerinin yayılma etkileri ile dolaylı olarak birbirlerini etkileyebilir. Bir hücre, genellikle kapasitörler, lineer dirençler, doğrusal ve doğrusal olmayan kontrollü kaynaklar ve bağımsız kaynaklar gibi doğrusal ve doğrusal olmayan devre elemanları içerir. HSA'nın devre elemanları ve örüntü bağlantı yapısı, 2 boyutlu hücresel sinir ağı örneğinde de görülebilir[10]. Teorik olarak herhangi boyutta bir hücresel sinir ağı yapısı tanımlanabilir. İlgili referanstaki araştırmacılar görüntü işleme üzerine odaklandıkları için, 2 boyutlu olma durumunu ele almışlardır.

İlk olarak 1988 yılında L.O. Chua and L.Yang tarafından öne sürülmüş[10], sinir ağlarının bir türü olan HSA'larla ilgili teoride ve uygulamada pek çok çalışma yapılmıştır. HSA'lar sinyal

işleme, çağrışımlı bellekler, doğrusal olmayan matematiksel denklemlerin çözümü gibi birçok alanda kullandığı gibi, ağırlıklı olarak örüntü tanıma ve görüntü işleme(özellikle statik) ile ilgili problemlerde başarılı çözümler sunmaktadır.

Bu uygulamaların HSA'ların dinamik davranış analizine dayandığı görülmektedir. Kararlılık bu davranışla ilgili en önemli konulardan birisidir. HSA'ların kararlılık analizleri son zamanlarda birçok araştırmacı tarafından ele alınmış ve bu konuda yapılan çalışmalarda önemli sonuçlar elde edilmiştir. Öte yandan zaman gecikmelerinin varlığı bilgi işlemenin sonlu hızı nedeniyle sinir ağlarında sapma, salınım ve istikrarsızlığa neden olabilir. Zaman gecikmeli hücrel sinir ağlarının kararlılık analizi konusu ile ilgili de birçok araştırma yapılmıştır[9],[10], [113-118].

1.8. BULANIK HÜCRESEL SİNİR AĞLARI (BHSA)

Gerçek dünya problemlerinin matematiksel modellenmesinde belirsizlik ve kesin olmama ile bulanık teoriye başvurulmuştur. İlk olarak 1996 yılında T. Yang ve L.B. Yang [106] tarafından ileri sürülen bulanık hücrel sinir ağları, geleneksel hücrel sinir ağları ile bulanık mantığı birleştiren ve hücreler arasında yerel bağlantı sağlayan yeni bir hücrel sinir ağı tipidir.

Bulanık Hücrel Sinir Ağlarının dinamik davranış modeli aşağıdaki diferansiyel denklemlerle tanımlanmıştır[106]:

$$\begin{aligned}
 C \frac{dx_{ij}}{dt} = & -\frac{1}{R_x} x_{ij} + \sum_{C_{kl} \in N_{\gamma}(i,j)} A(i,j;k,l) y_{kl} + \sum_{C_{kl} \in N_{\gamma}(i,j)} B(i,j;k,l) u_{kl} + I \\
 & + \bigwedge_{C_{kl} \in N_{\gamma}(i,j)} A_{fmin}(i,j;k,l) y_{kl} + \bigvee_{C_{kl} \in N_{\gamma}(i,j)} A_{fmax}(i,j;k,l) y_{kl} \\
 & + \bigwedge_{C_{kl} \in N_{\gamma}(i,j)} B_{fmin}(i,j;k,l) u_{kl} + \bigvee_{C_{kl} \in N_{\gamma}(i,j)} B_{fmax}(i,j;k,l) u_{kl}, \\
 & 1 \leq i \leq M, \quad 1 \leq j \leq N
 \end{aligned}$$

Burada $A_{fmin}(i,j;k,l)$, $A_{fmax}(i,j;k,l)$, $B_{fmin}(i,j;k,l)$ ve $B_{fmax}(i,j;k,l)$ sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN

şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır. $A(i, j; k, l)$ ve $B(i, j; k, l)$ sırasıyla geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_{ij} , y_{ij} , u_{ij} ve I sırasıyla C_{ij} nin durum, çıktı, girdi ve sapmalarını temsil eder.

Görüntü tanıma gibi üst düzey bilgi işleme yeteneği ile HSA'ların düşük düzeyli bilgi işleme kapasitesini birleştirmesine izin veren bulanık hücresel sinir ağları, sinaptik kural hesaplamasında bulanık işlemleri kullanan HSA ların bir genellemesidir [99].

Geleneksel hücresel sinir ağının yapısından farklı olarak, bulanık hücresel sinir ağları çarpım toplamı işleminin yanı sıra şablon girdi ve/veya çıktıları arasında bulanık mantığa sahiptir. Dolayısıyla BHSA'lar geleneksel hücresel sinir ağlarına kıyasla çok daha fazla amaca hizmet etmektedir.

BHSA'lar görüntü işleme problemleri için çok kullanışlı paradigmadır ki, bu görüntü işleme ve örüntü tanımada köşe taşıdır. Bu alanda literatürde BHSA lar kullanılarak yapılmış bir çok çalışma mevcuttur; gri ölçek görüntülerinin görüntü işlemesi [19], [20], kenar algılama [18], görüntü işleme [21], Öklid uzaklığı dönüşümü [22] bunlara örnek olarak verilebilir.

BHSA'lar kullanılarak tıp alanında da birçok çalışma yapılmıştır. Literatürde BHSA'ların kullanıldığı tıp uygulama alanlarından bazıları şunlardır: beyaz kan hücresi tespiti[14], hesaplamalı tomografi karaciğer görüntüleri [16], [17].

Bulanık hücresel sinir ağlarının dinamik davranışında stokastik gürültü karışıklığı ve difüzyon etkileri ihmal edilemezdir. Bu nedenle difüzyon parametrelerini içeren senkronizasyon kriterleri daha makuldur. İlk olarak Pecora ve Carroll tarafından literatüre sunulan[111] kaotik senkronizasyon, ana sistem olarak kabul edilen kaotik bir sistem ve köle sistem olarak kabul edilen benzer başka bir sistem göz önüne alındığında amaç köle sistemin tepkisini ana sisteme senkronize etmeye zorlamak olarak tanımlanmıştır.

BHSA'ların senkronizasyonu kullanılarak bilgi işleme, kimyasal reaksiyonlar, güvenli iletişim, kaos jeneratör tasarımı gibi birçok teknolojik alanda çeşitli çalışmalar yapılmıştır[23]-[37].

1.9. KARARLILIK ÇALIŞMALARI

Yapay sinir ağlarının görüntü işleme, sinyal işleme, optimizasyon gibi gelişmiş hesaplama özellikleri, sinir ağlarının dinamik davranışına dayanır. Yapay sinir ağlarının üstel kararlılık ve periyodik osilasyon analizi gibi nitelik analizleri bu ağların dinamiklerini oluşturur. YSA'ların özel bir modeli olan hücresel sinir ağlarının dinamiklerini analiz etmede kararlılık birincil derecede öneme sahiptir. İstenen HSA performansını garantilemek için denge noktası ve bu denge noktasının kararlılığını incelemek son derece önemlidir. HSA'nın kararlılık analizinde kullanılacak kararlılık analizi türü HSA'nın uygulanacağı problemin yapısına göre belirlenir. Örneğin HSA optimizasyon probleminde kullanılacaksa bu HSA'nın başlangıç koşullarından bağımsız tek bir denge noktasına yakınsaması ve sistemin global asimptotik kararlı olması gerekmektedir.

Hücresel sinir ağlarının bir türü olan bulanık hücresel sinir ağlarının dinamikleri ile ilgili son yıllarda birçok çalışma yapılmış ve önemli sonuçlar elde edilmiştir. BHSA'larla ilgili farklı kararlılık teorileri ortaya koyan birçok çalışma mevcuttur.

Bu kapsamda son 20 yılda BHSA modellerinin kararlılığı üzerine birçok çalışma yapılmıştır [43-110]. Bu çalışmalarda çeşitli BHSA modellerinin denge noktasının tam kararlılığı, asimptotik kararlılığı, üstel kararlılığı gibi farklı kararlılık analizleri incelenmiştir.

Bu tez çalışmasının amacı, bulanık hücresel sinir ağlarının dinamik davranış analizini yapmış olan literatürdeki tüm çalışmaların incelenmesidir. Bu amaçla tezin içeriği aşağıdaki şekilde organize edilmiştir.

Tezin Genel Kısımlar bölümünde, bulanık hücresel sinir ağları ile ilgili genel bir bilgi verilecektir.

Tezin Malzeme ve Yöntem bölümünde, tez çalışması kapsamında incelenen yayınlarda kullanılmış olan tüm yöntem ve kurallar verilecektir.

Bulanık Hücresel Sinir Ağlarının Dinamik Davranış Analizi bölümünde, incelenen çalışmalarda ele alınan BHSA modelleri sınıflandırılarak elde edilen model tanımları verilecektir.

Bulgular bölümünde, BHSA'ların dinamik davranışı ile ilgili yapılmış literatür çalışmalarının yıllara göre dağılımı, kullanılan yöntemlere göre dağılımı, ele alınan kararlılık analizi türüne göre dağılımı sonuçları verilecektir.

2. GENEL KISIMLAR

Lineer sinaptik kurallarla karakterize edilen yapay sinir ağıları, çok karmaşık bir lineer eşlemeyi gerçekleştirebilir ve büyük bir bilgi elde etme yeteneğine sahiptir. Uzun bir süredir iki insan yapımı hata vardır ki; bunlardan birinde edinim hızı düşüktür ve birleşmenin nesnel fonksiyonun daha kötü bir yerel optimum noktasında gerçekleşmesi mümkündür, diğerinde ise ağ tam bir "kapalı kutu" halinde olup içerisindeki nöronlar ve sinaptik kanunlar kesin doğrulukta fiziksel çıkarımlar sağlayamaz, buna bağlı olarak da mevcut bilgi ağı yapısı tasarımının iyileştirilmesinde ve daha kötü olan yerel optimum noktadan kaçınmak için edinim hızının artırılmasında eksiksiz olarak uygulanamaz. Bu noktada BHSA yapısı uzman ve klasik HSA arasında bir arayüz olarak kullanılabilir; BHSA, HSA şablonları içinde bulanık kurallar olarak ifade edilen dilsel veya üst düzey ifadeleri çevirmede kullanılır[18]. Bu nedenle BHSA'lar geleneksel hücresel sinir ağlarına kıyasla çok daha fazla amaca hizmet etmektedir. BHSA'lar literatürde önemli bir yer tutmaktadır. BHSA'larla ilgili 1996 yılından bu yana bir çok çalışma yapılmıştır.

Kararlılık ve yakınsaklık BHSA'ların performans gereksinimini garantileyen ön koşullardır. Bu nedenle BHSA'nın dinamiklerini analiz etmede birincil derecede öneme sahiptir.

Bu survey çalışmasında 1996 yılından bu yana BHSA'ların kararlılık analizi ile ilgili literatüre kazandırılmış tüm çalışmalar incelenmiş, çalışmalarda kullanılan modeller sınıflandırılarak, literatürde yer alan tüm bu çalışmaların kullandığı kararlılık yöntemleri incelenmiş ve analiz edilmiştir.

3. MALZEME VE YÖNTEM

Öncelikle bu tezin kapsamında kullanılan bazı sembolik gösterimler ifade edilecektir :

Matrisler büyük harfle gösterilecektir. Örneğin Q ya da P . Herhangi bir Q matrisi için aşağıdaki gösterimler kullanılacaktır:

- Q^T : Q matrisinin transpozu. Bir Q matrisinin transpozu, matrisin satırları ile sütunlarının yer değiştirilmesi ile elde edilir.
- Q^{-1} : Q matrisinin tersini ifade eder.
- $\lambda_i(Q)$: Q matrisine ait i . özdeğeri ifade eder.
- $\lambda_m(Q)$: Simetrik bir Q matrisinin en küçük özdeğerini temsil eder.
- $\lambda_M(Q)$: Simetrik bir Q matrisinin en büyük özdeğerini temsil eder.
- $\det(Q)$: Q matrisinin determinantını ifade eder.
- $P = \text{diag}(p_i) > 0$: Pozitif köşegen bir P matrisini ifade eder.
- $|Q|$: Q matrisinin her bir elemanının mutlak değeri alındıktan sonra oluşturulan matristir.

Vektörler küçük harflerle gösterilecektir. Örneğin u ya da v . n adet elemanı olan ve bu elemanları $v_1, v_2, \dots, v_n$ ile temsil edilen herhangi bir v vektörü için aşağıdaki gösterimler kullanılacaktır:

- v vektörü $v = [v_1 \ v_2 \dots v_n]^T$ şeklinde gösterilir ve bir sütun vektörünü temsil eder.
- v^T ise v vektörünün transpozunu gösterir ve bir satır vektördür.
- $|v| = (|v_1|, |v_2|, \dots, |v_n|)^T$ olarak kullanılacaktır.

3.1. NORMLAR

3.1.1. Öklit Uzayı

Tüm n -boyutlu vektörlerin kümesi $v = [v_1, v_2, \dots, v_n]^T$ ile gösterilir. Burada $v_1, v_2, \dots, v_n$ gerçel sayıdır ve n -boyutlu Öklid uzayı olarak tanımlanır. R^n şeklinde gösterilirler. Tüm gerçel sayıları içeren tek-boyutlu Öklid uzayı R ile gösterilir.

3.1.2. Vektör ve Matris Normları

Bir $v = [v_1, \dots, v_n]^T$ vektörünün normu $\|v\|$ ile gösterilir ve aşağıdaki özellikleri sağlayan reel-değerli bir fonksiyondur :

- $\forall v \in R^n$ için $\|v\| > 0$ ve sadece $v = 0$ için $\|v\| = 0$.
- $\forall v, u \in R^n$ için $\|v + u\| \leq \|v\| + \|u\|$.
- $\forall \alpha \in R$ ve $\forall v \in R^n$ için $\|\alpha v\| = |\alpha| \|v\|$.

3.2. MATRİS SINIFLARI VE ÖZELLİKLERİ

Bu bölümde bazı matris sınıflarının tanımları verilecektir :

Tanım 3.2.1

$n \times n$ boyutlu simetrik bir Q matrisinin bütün özdeğerleri sıfırdan büyük ise, bu Q matrisi pozitif tanımlıdır ve $Q > 0$ ifadesi ile gösterilir.

Tanım 3.2.2

$n \times n$ boyutlu simetrik bir Q matrisinin bazı özdeğerleri sıfırdan büyük ve bazı özdeğerleri sıfıra eşit ise, bu Q matrisi pozitif yarıtanımlıdır ve $Q \geq 0$ ifadesi ile gösterilir.

Tanım 3.2.3

$n \times n$ boyutlu bir Q matrisinin bütün özdeğerlerinin gerçel kısmı sıfırdan büyük ise, bu Q mat-

risi pozitif kararlıdır. Bu özelliğe sahip matrisler aynı zamanda H -kararlı matris olarak da isimlendirilir ve $Q \in H$ ifadesi ile gösterilir.

Tanım 3.2.4

$n \times n$ boyutlu bir Q matrisinin bazı özdeğerlerinin gerçel kısmı sıfırdan büyük ve bazı özdeğerlerinin gerçel kısmı sıfıra eşit ise, bu Q matrisi pozitif yarıkararlıdır. Bu özelliğe sahip matrisler aynı zamanda H_o -kararlı matris olarak da isimlendirilir ve $Q \in H_o$ ifadesi ile gösterilir.

Tanım 3.2.5

Herhangi bir $Q=(q_{ij})$ matrisinin elemanları $q_{ii} \geq 0$ ve $q_{ij} \leq 0$ olarak seçilmiş olsun. Bu formdaki Q matrisi Z_n kümesinin bir elemanı olarak kabul edilir.

Tanım 3.2.6

Q matrisi Z_n kümesinin bir elemanı olsun. Eğer Q matrisi pozitif kararlı bir matris ise, Q matrisi tekil olmayan M-matris olarak isimlendirilir ve $Q \in K$ ifadesi ile gösterilir.

Tanım 3.2.7

Q matrisi Z_n kümesinin bir elemanı olsun. Eğer Q matrisi pozitif yarıkararlı bir matris ise, Q matrisi M-matris olarak isimlendirilir ve $Q \in K_o$ ifadesi ile gösterilir.

Q tekil olmayan M-matris ise aşağıdaki ifadeler eşdeğerdir.

Kural 3.2.1 [41]

$Q\Psi > 0$ eşitsizliğini sağlayan pozitif bir $\Psi > 0$ vektörü bulunabilir.

Kural 3.2.2 [41]

Aşağıdaki eşitsizliği sağlayan pozitif köşegen bir $D = \text{diag}(d_i > 0)$ matrisi vardır.

$$q_{ii}d_i > \sum_{\substack{j=1 \\ j \neq n}} d_j |q_{ij}|, \quad i = 1, \dots, n.$$

Tanım 3.2.8

$n \times n$ boyutlu herhangi bir Q matrisinin kıyas matrisi $C = \{c_{ij}\}$ ile gösterilir ve $c_{ii} = q_{ii}$, $c_{ij} = -|q_{ij}|$ olarak tanımlanır.

Tanım 3.2.9

Herhangi bir Q matrisi için köşegen elemanları $q_{ii} > 0$ olarak verilmiş olsun. Eğer Q matrisinin kıyas matrisi C , tekil olmayan M-matris ise, bu durumda Q matrisi tekil olmayan H -matris olarak isimlendirilir ve $Q \in C$ ifadesi ile gösterilir.

Tanım 3.2.10

Herhangi bir Q matrisi için köşegen elemanları $q_{ii} \geq 0$ olarak verilmiş olsun. Eğer Q matrisinin kıyas matrisi C , M-matris ise bu durumda Q matrisi H -matris olarak isimlendirilir ve $Q \in C_o$ ifadesi ile gösterilir.

Tanım 3.2.11

Q , $n \times n$ boyutlu bir matris olsun. Eğer Q matrisinin elemanları aşağıdaki eşitsizliği sağlıyorsa :

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

bu Q matrisi, kesin köşegen satır baskın bir matristir.

Tanım 3.2.12

Q , $n \times n$ boyutlu bir matris olsun. Eğer Q matrisinin elemanları aşağıdaki eşitsizliği sağlıyorsa :

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

bu Q matrisi, köşegen satır baskın bir matristir.

Tanım 3.2.13

Q , $n \times n$ boyutlu bir matris olsun. Eğer Q matrisinin elemanları aşağıdaki eşitsizliği sağlıyorsa :

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

bu Q matrisi, kesin köşegen sütun baskın bir matristir.

Tanım 3.2.14

Q $n \times n$ boyutlu bir matris olsun. Eğer Q matrisinin elemanları aşağıdaki eşitsizliği sağlıyorsa :

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

bu Q matrisi, köşegen sütun baskın bir matristir.

3.3. DOĞRUSAL OLMAYAN SİSTEMLERDE KARARLILIK ANALİZİ

Bu kısımda, tez çalışması kapsamında incelenen yayınlarda kullanılmış olan tüm kararlılık analizi yöntemleri verilecektir.

3.3.1. Lyapunov Kararlılık Teoremi

$\dot{x}(t) = f(x(t))$ sisteminin denge noktası $x^* = 0$ olsun. Bu durumda $f(0) = 0$ olacaktır. $V(x(t)) : R^n \rightarrow R$ pozitif tanımlı, sürekli ve türevi alınabilir bir fonksiyon olsun. $V(x(t))$ fonksiyonunun zamana göre türevi aşağıdaki şekilde yazılabilir:[42]

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

$V(0) = 0$, $V(x(t)) > 0$, $\forall x(t) \neq 0$ iken

(i) $\dot{V}(x(t)) \leq 0, \forall x(t) \in R^n$ ise denge noktası $x^* = 0$ kararlıdır.

(ii) $\dot{V}(x(t)) < 0, \forall x(t) \neq 0$ ise denge noktası $x^* = 0$ asimtotik kararlıdır.

(iii) $\dot{V}(x(t)) > 0, \forall x(t) \neq 0$ ise denge noktası $x^* = 0$ kararsızdır.

Bu teorem Lyapunov'un Direkt Metodu olarak adlandırılır. Bu metodun üstünlüklerinden biri denge noktasının kararlılık özelliklerini, sisteme ait diferansiyel denklemleri çözmeden belirlememizi sağlamasıdır. Ancak Lyapunov fonksiyonunun bulunması için bir yöntem bulunmamaktadır. Uygun bir Lyapunov fonksiyonu bulunabilirse, sistemin kararlılığı belirlenebilir. Bununla birlikte, herhangi bir Lyapunov fonksiyonu bulunamazsa, bu sistemin kararsız olduğu anlamına gelmemektedir.

3.3.2. M-Matris Teoremi

A $n \times n$ gerçekte Z matrisi olsun. Yani $A = (a_{ij})$ burada tüm $i \neq j, 1 \leq i, j \leq n$ için $a_{ij} \leq 0$ dır. A formdaki gibi $A = sI - B$ ifade edilebilirse aynı zamanda bir M-matristir; burada $B = (b_{ij})$, tüm $1 \leq i, j \leq n$ için $b_{ij} \geq 0$ s, B özdeğer modülünün maksimumundan daha büyüktür ve I bir birim matrisdir.

3.3.3. Young Eşitsizliği

$a > 0, b > 0, p > 1, \frac{1}{p} + \frac{1}{q} = 1$ varsayarsak aşağıdaki eşitsizlik sağlanır.

$$ab \leq \frac{1}{p}a^p + \frac{1}{q}b^q$$

bu eşitsizlik Young eşizliği olarak adlandırılır.

3.3.4. Lineer Matris Eşitsizliği

Lineer matris eşitsizliği aşağıdaki formun bir ifadesidir;

$F(x) = F_0 + \sum_{i=1}^m x_i F_i > 0$, burada (2.1) $x \in R^m$ değişken ve simetrik matrisler $F_i = F_i^T \in R^{n \times n}, i = 0, \dots, m$ verilmektedir.

(2.1) deki eşitsizlik sembolü $F(x)$ in pozitif tanımlı olduğu anlamına gelir, yani tüm sıfırdan farklı u lar için $u^T F(x)u > 0$ dir. Şüphesiz LME x de n polinomal eşitsizliklerin bir kümesine denktir yani $F(x)$ in önde gelen başlıca minörleri pozitif olmalıdır.

3.3.5. Brownian Hareketi

$B(0) = 0$, $s < t$ olacak şekilde tüm t, s ler için $B(t) - B(s)$ $t - s$ varyanslı normal dağıtık ve $B(t) - B(s)$ in dağılımı $r \leq s$ için $B(r)$ den bağımsız ise $B(t)$ rastgele değişkenler dizisi bir Brownian hareketidir.

3.3.6. Ito Kuralı

Ito Lemması, bir stokastik sürecin zamana bağlı bir fonksiyonunun türevini belirlemek için kullanılan Ito hesabındaki önemli bir bileşendir. Adi diferansiyel hesabındaki zincir kuralına benzer bir stokastik ortamda zincir kuralı rolünü gerçekleştirir.

$B(t)$ bir Brownian hareketi ve $W(t)$ aşağıdaki stokastik diferansiyel eşitliği sağlayan bir Ito sürüklenme-difüzyon süreci olsun

$$dW(t) = \mu(W(t), t)dt + \sigma(W(t), t)dB(t)$$

Eğer $f(w, t) \in C^2(R^2, R)$ ise $f(W(t), t)$ aşağıdaki diferansiyeli ile verilen bir Ito sürüklenme-difüzyon sürecidir.

$$d(f(W(t), t)) = \frac{\partial f}{\partial t}(W(t), t)dt + f'(W(t), t)dW + \frac{1}{2}f''(W(t), t)dW(t)^2$$

$dW(t)^2, dt^2 = 0, dt dB(t) = 0$ ve $dB(t)^2 = dt$ ile verilmiştir.

3.3.7. Sabit Nokta Teoremi

$\varphi : R^n \rightarrow R^n$ R^n üzerinde $\|\cdot\|$ normuyla donatılmış bir daralma haritalaması olsun bundan dolayı $\varphi(x^*) = x^*$ ı sağlayan tek bir sabit nokta $x^* \in R^n$ vardır.

3.3.8. Jensen İntegral Eşitsizliği

Herhangi bir sabit M matrisi için, a ve b herhangi skalerler $a < b$ ve bir vektör fonksiyonu $\chi(t) : [a, b] \rightarrow R$ öyle ki söz konusu integrallar iyi tanımlıdır ve aşağıdaki eşitsizliklik sağlanır

$$\left(\int_a^b \chi(s) ds\right)^T M \left(\int_a^b \chi(s) ds\right) \leq (b-a) \int_a^b \chi(s)^T M \chi(s) ds$$

3.3.9. Kuadratik Konveks Birleştirme

Herhangi simetrik matrisler Z_0, Z_1 , bir pozitif yarı tanımlı matris $Z_2 \geq 0$, ve uygun boyutlu herhangi bir vektör ϱ için eşitsizlik

$$g(\alpha) = \varrho^T Z_0 \varrho + \alpha \varrho^T Z_1 \varrho + \alpha^2 \varrho^T Z_2 \varrho < 0, \forall \alpha \in [\alpha_1, \alpha_2]$$

sağlanır ancak ve ancak aşağıdaki eşitsizlikler eşzamanlı olarak sağlanırsa

$$g(\alpha_1) < 0, \quad g(\alpha_2) < 0$$

3.3.10. Tesadüf Derecesinin Devamı Teoremi

(A2) Negatif olmayan p_j, q_j sabitleri vardır öyle ki $j = 1, 2, \dots, n, x \in N$ için $|f_j(x)| \leq p_j |x| + q_j$ (A2) nin geçerli olduğunu ve aşağıdaki koşulun sağlandığını varsayalım (A3) $E_n - D$ bir M matris, burada $D = (d_{ij})_{n \times n}$, $d_{ij} = \frac{1}{c_i} (a_{ij}^+ + \alpha_{ij}^+ + \beta_{ij}^+) p_j$, sistemin en az bir w periyodik çözümü vardır.

3.3.11. Homeomorfizma Haritalama Teoremi

Bir $H : R^n \rightarrow R^n$ haritası kendi üzerinde R^n in bir homeomorfizmasıdır. Öyle ki H sürekli ve birebir ve ters haritası H^{-1} de sürekli ise.

3.3.12. M-koni Tanımı

Tekil olmayan bir M -matrisi D için, $\Omega_M(D)$ boş değil ve herhangi $z_1, z_2 \in \Omega_M(D)$ için $k_1 z_1 + k_2 z_2 \in \Omega_M(D)$, $\forall k_1, k_2 > 0$ dir. Dolayısıyla $\Omega_M(D)$ R^n de konik yüzeyi olmayan bir konidir.

Bu bir M koni olarak adlandırılır.

3.3.13. Negatif Olmayan Matrislerin Spektral Yarıçapının Özuzayı

Negatif olmayan bir $A \in R^{n \times n}$ matrisi için $\rho(A)$ A'nın spektral yarıçapı olsun. Bu durumda $\rho(A)$ A'nın bir özdeğeridir ve A'nın özuzayı

$$\Omega_p(A) \triangleq \{z \in R^n \mid Az = p(A)z\}$$

ile gösterilir. Bu negatif olmayan A matrisinin en az bir pozitif özvektörü olmasını sağlayan A'nın tüm pozitif özvektörlerini içerir.

3.3.14. Dürtüsel Başlangıç Koşullu İntegro Diferansiyel Eşitsizliği

$0 < r(t) \leq \tau$, $A = (a_{ij})_{n \times n}$, $P = (p_{ij})_{n \times n}$, $p_{ij} \geq 0$ ($i \neq j$), $Q(t) = (q_{ij}(t))_{n \times n} \geq 0$ parçalı sürekli olsun ve bir λ_1 pozitif sabiti olsun öyle ki $\int_0^\infty e^{\lambda_1 t} q_{ij}(t) dt < \infty$ her $i, j = 1, 2, \dots, n$ için. $Q = (q_{ij})_{n \times n} \triangleq (\int_0^\infty q_{ij}(t) dt)_{n \times n}$ ile ifade edilir ve $D = -(A + P + Q)$ tekil olmayan bir M-matrisi olsun. $b \in [t_0, +\infty)$ için $v(t) = (v_1(t), \dots, v_n(t))^T \in PC([t_0, b), R^n)$, $v_{t_0}(s) \in PC$, $s \in (-\infty, 0]$ başlangıç koşullu aşağıdaki integro diferansiyel eşitsizliğin çözümü olsun.

$$D^+v(t) \leq Av(t) + Pv(t - r(t)) + \int_0^\infty Q(s)v(t - s)ds, t \in [t_0, b)$$

Sonra bir $z = (z_1, z_2, \dots, z_n)^T \in Q_M(D)$ vektörü vardır öyle ki

$$v(t) \leq ze^{-\lambda(t-t_0)}, t \in [t_0, b)$$

başlangıç koşulunu sağlaması koşuluyla

$$v(s) \leq ze^{-\lambda(s-t_0)}, s \in (-\infty, t_0],$$

ve pozitif sabit $\lambda \leq \lambda_1$ aşağıdaki eşitsizliği sağlar.

$$[\lambda E + A + Pe^{\lambda\tau} + \int_0^\infty Q(s)e^{\lambda s}ds]z < 0.$$

3.3.15. Aktivasyon Fonksiyonları

Yapay sinir ağlarının kararlılık analizindeki önemli parametrelerden biri olan aktivasyon fonksiyonu toplama fonksiyonunun çıktısından aldığı değeri bir algoritma ile gerçek bir çıktıya dönüştüren fonksiyonlardır. Genellikle doğrusal olmayan fonksiyonlardır. Bunun nedeni doğrusal fonksiyonlarda çıktının girdi ile orantılı olmasıdır.

Aktivasyon fonksiyonlarının sınıflarına aşağıda yer verilmiştir.

1. Sınırlı Aktivasyon Fonksiyonları:

Eğer $f_i(x)$ aktivasyon fonksiyonu $|f_i(x)| \leq M_i$, ($i = 1, 2, \dots, n$) koşulunu sağlıyor ise bu aktivasyon fonksiyonu sınırlıdır. Burada M_i pozitif bir sabittir. Bu özelliği sağlayan aktivasyon fonksiyonlarının oluşturduğu küme $f \in \mathcal{B}$ ile gösterilir.

Sınırlı aktivasyon fonksiyonlarının kullanımı, yapay sinir ağları için her zaman bir denge noktasının varlığını sağlar. Bu nedenle, sınırlı aktivasyon fonksiyonlarının kullanıldığı yapay sinir ağı modellerinden, sınırsız aktivasyon fonksiyonlarının kullanıldığı yapay sinir ağı modellerine geçildiğinde kararlılık analizi açısından daha zor bir durumla karşı karşıya kalınır. Çünkü, sınırsız aktivasyon fonksiyonlarının kullanıldığı durumda bir denge noktasının varlığı her zaman kesin değildir.

2. Sürekli Artan Aktivasyon Fonksiyonları:

Sürekli artan aktivasyon fonksiyonları aşağıdaki koşulu sağlar :

$$\frac{df(x_i)}{dx_i} > 0, \quad i = 1, 2, \dots, n \quad \forall x_i \in R$$

3. Sürekli Artan Türevi Sınırlı Aktivasyon Fonksiyonları:

Sürekli artan türevi sınırlı aktivasyon fonksiyonları aşağıdaki koşulu sağlar :

$$0 < \frac{f_i(x) - f_i(y)}{x - y} \leq \mu_i, \quad i = 1, 2, \dots, n \quad \forall x, y \in R, x \neq y$$

Burada μ_i pozitif sabitlerdir. Bu özelliği sağlayan aktivasyon fonksiyonlarının oluşturduğu küme $f \in \mathcal{S}$ ile gösterilir.

Yapay sinir ağlarının kararlılık analizinde sigmoid fonksiyonlar olarak da isimlendirilen bu tür aktivasyon fonksiyonlarının kullanıldığı çok sayıda çalışma mevcuttur. Gerçekte aktivasyon fonksiyonları ile ilgili bu varsayım, denge noktasının varlığı, tekliği ve global asimtotik kararlılığını gerçeklemede büyük kolaylıklar sağlamaktadır. Çünkü bu durumda kararlılık analizini yapabilecek uygun Lyapunov fonksiyonları bulmak daha kolaydır. Ayrıca, sigmoid fonksiyonu kullanıldığı zaman sistem parametreleri üzerindeki kısıtlayıcı koşullar daha esnek olmaktadır.

Yukarıdaki karakteristik ile tanımlanan aktivasyon fonksiyonları sürekli artan bir özelliğe sahiptir. Bu koşul oldukça sınırlayıcıdır ve bu varsayım birçok durumda da kullanılan aktivasyon fonksiyonlarının karakteristiğini ifade etmekte yetersiz kalmaktadır. Örneğin hücre sinir ağlarında kullanılan aşağıdaki fonksiyon, $\mathcal{S}$ ile gösterilen aktivasyon fonksiyonları kümesine ait değildir :

$$y(x) = 0.5(|x + 1| - |x - 1|)$$

Bu nedenle yapay sinir ağlarında kullanılacak aktivasyon fonksiyonlarının kümesini daha geniş tutmakta yarar vardır. Çünkü böyle bir seçim yapay sinir ağlarının, kullanıldığı uygulamalar-daki performansını da pozitif yönde etkiler. Bu nedenle daha geniş bir aktivasyon fonksiyonu kümesi aşağıda verilmiştir.

4. Azalmayan Türevi Sınırlı Aktivasyon Fonksiyonları:

Azalmayan türevi sınırlı aktivasyon fonksiyonları aşağıdaki koşulu sağlar:

$$0 \leq \frac{f_i(x) - f_i(y)}{x - y} \leq \mu_i, \quad i = 1, 2, \dots, n, \quad \forall x, y \in R, x \neq y$$

Burada μ_i pozitif sabitlerdir. Bu özelliği sağlayan aktivasyon fonksiyonlarının oluşturduğu küme $f \in \mathcal{K}$ ile gösterilir.

Yukarıda verilen $\mathcal{K}$ sınıfı, $\mathcal{S}$ sınıfına göre daha fazla sayıda aktivasyon fonksiyonu içermesine rağmen yine de monotonik artan bir özelliğe de sahiptir. Bu kümedeki fonksiyonlar kesin artmamakla birlikte azalmayan fonksiyonlardır, yani türevleri sıfır ya da pozitif olabilir.

Literatürde $\mathcal{S}$ ve $\mathcal{K}$ sınıfında olmayan, türevlerinin negatif olabileceği aktivasyon fonksiyonları da sıkça kullanılmıştır. Bu özelliklere sahip aktivasyon fonksiyonları kümesi aşağıda verilmiştir.

5. Lipschitz Aktivasyon Fonksiyonları:

Lipschitz aktivasyon fonksiyonları aşağıdaki koşulu sağlar:

$$|f_i(x) - f_i(y)| \leq \mu_i |x - y|, \quad i = 1, 2, \dots, n, \quad \forall x, y \in R, x \neq y$$

Burada μ_i pozitif sabitlerdir. Bu özelliği sağlayan aktivasyon fonksiyonlarının oluşturduğu küme $f \in \mathcal{L}$ ile gösterilir.

Bir $f(x)$ fonksiyonu, tüm x ve y vektörleri için aşağıdaki eşitsizliği sağlıyorsa, Lipschitz süreklidir :

$$||f(x) - f(y)|| \leq L ||x - y||$$

Yukarıdaki eşitsizlikte, L , pozitif Lipschitz sabiti olarak adlandırılır.

Optimizasyon problemlerinin çözümündeki temel hedef tasarlanan yapay sinir ağı modelinin, kullanılan aktivasyon fonksiyonunun yapısına bağlı olarak, denge noktasının varlığı , tekliği ve global asimtotik kararlılığının sağladığı koşulların elde edilmesidir. Daha önce de bahsettiğimiz gibi sınırlı aktivasyon fonksiyonlarının kullanılması her zaman bir denge noktasının varlığını temin eder.

4. BULGULAR

Bu tez çalışmasında 1996 yılında [106] referanslı çalışma ile literatüre kazandırılan BHSA'ların kararlılık analizi ile ilgili yapılmış çalışmalar analiz edilmiştir. Aşağıda, literatürde bu alanda yapılmış tüm çalışmalar, inceledikleri BHSA modellerine göre sınıflandırılmıştır. Toplamda 40 adet farklı BHSA modeli incelenmiş ve aşağıdaki şekilde sunulmuştur :

4.1. BULANIK HÜCRESEL SİNİR AĞI MODELLERİ

Model Tanımı 1.

[106] referans numaralı çalışma ile literatüre sunulan ilk **bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 C \frac{dx_{ij}}{dt} = & -\frac{1}{R_x} x_{ij} + \sum_{C_{kl} \in N_\gamma(i,j)} A(i, j; k, l) y_{kl} + \sum_{C_{kl} \in N_\gamma(i,j)} B(i, j; k, l) u_{kl} + I \\
 & + \bigwedge_{C_{kl} \in N_\gamma(i,j)} A_{fmin}(i, j; k, l) y_{kl} + \bigvee_{C_{kl} \in N_\gamma(i,j)} A_{fmax}(i, j; k, l) y_{kl} \\
 & + \bigwedge_{C_{kl} \in N_\gamma(i,j)} B_{fmin}(i, j; k, l) u_{kl} + \bigvee_{C_{kl} \in N_\gamma(i,j)} B_{fmax}(i, j; k, l) u_{kl}, \\
 & 1 \leq i \leq M, \quad 1 \leq j \leq N
 \end{aligned}$$

Burada $A_{fmin}(i, j; k, l)$, $A_{fmax}(i, j; k, l)$, $B_{fmin}(i, j; k, l)$ ve $B_{fmax}(i, j; k, l)$ sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $A(i, j; k, l)$ ve $B(i, j; k, l)$ sırasıyla geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_{ij} , y_{ij} , u_{ij} ve I sırasıyla C_{ij} nin durum, çıktı, girdi ve sapmalarını temsil eder.

Model Tanımı 2.

[94] ve [91] referans numaralı çalışmalarda analizi yapılmış **difüzyonlu gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dv_i(t, x)}{dt} = & \sum_{k=1}^m \frac{\partial}{\partial x_k} (c_{ik} \frac{\partial v_i(t, x)}{\partial x_k}) - d_i v_i(t, x) + \sum_{j=1}^n a_{ij} f_j(v_j(t, x)) + \sum_{j=1}^n b_{ij} \mu_j \\ & + \bigwedge_{j=1}^n \alpha_{ij} f_j(v_j(t, x) - \tau_j(t)) + \bigwedge_{j=1}^n T_{ij} \mu_j + I_i \\ & + \bigvee_{j=1}^n \beta_{ij} f_j(v_j(t, x) - \tau_j(t)) + \bigvee_{j=1}^n H_{ij} \mu_j \frac{\partial v_i(t, x)}{\partial n} = 0, \end{aligned}$$

$$0 \leq t, \quad x \in \partial\Omega, \quad v_i(s, x) = \varphi_i(s, x), \quad -\tau \leq s \leq 0,$$

burada $\frac{\partial v_i(t, x)}{\partial n} = (\frac{\partial v_i(t, x)}{\partial x_1}, \dots, \frac{\partial v_i(t, x)}{\partial x_m})^T, i = 1, \dots, n$ ve n bir sinir ağındaki birimlerin sayısına karşılık gelir. $v_i(t, x)$, x uzayında t zamanda i inci birimin durumuna karşılık gelir. $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; μ_i ve I_i sırasıyla i inci nöronun girdi ve sapmalarını temsil eder. f_i aktivasyon fonksiyonudur. $\tau_i(t)$ iletim gecikmesi, $t \in [0, \infty), i = 1, \dots, n$ için $0 \leq \tau_i(t) \leq \tau$ sağlar. τ sabit, Ω bir pürüzsüz sınırlı kompakt set, ve $\Re_m$ uzayı n da $mes\Omega > 0$ dir $\varphi_i(s, x) [-\tau, 0]$ da sınırlı başlangıç sınır değeridir. değeridir.

Model Tanımı 3.

[107] ve [50] referans numaralı çalışmalarda analizi yapılmış **Markovian atlama parametrelili gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}\dot{x}(t) = & -A(\gamma_t)x(t) + B(\gamma_t)f(x(t)) + \bigwedge C(\gamma_t) \circ f(x(t - \tau(t))) \\ & + \bigvee D(\gamma_t) \circ f(x(t - \tau(t)))\end{aligned}$$

$$x(t) = \phi(t), \quad -\tau \leq t \leq 0, 0 \leq \tau(t) \leq \tau.$$

Model Tanımı 4.

[84], [92], [102], [97], [55], [54], [51], [76], [109] referans numaralı çalışmalarda analizi yapılmış **zaman gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}\dot{x}_i(t) = & -d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t - \tau_j(t))) + \sum_{j=1}^n b_{ij} u_j + I_i(t) \\ & + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t - \tau_j(t))) + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t - \tau_j(t))) + \bigwedge_{j=1}^n T_{ij} u_j + \bigvee_{j=1}^n H_{ij} u_j\end{aligned}$$

$\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij}, b_{ij} geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, u_j ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $\tau(t)$ t zamanında iletim gecikmesine karşılık gelir; f_j aktivasyon fonksiyonudur;

Model Tanımı 5.

[104] ve [84] referans numaralı çalışmalarda analizi yapılmış **sabit gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}\dot{x}_i = & -d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} u_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t - \tau)) \\ & + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t - \tau)) + \bigwedge_{j=1}^n T_{ij} u_j + \bigvee_{j=1}^n H_{ij} u_j \quad i = 1, 2, \dots, n\end{aligned}$$

$\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $a_{ij}(t), b_{ij}(t)$ sırasıyla geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. f_i aktivasyon fonksiyonudur;

Model Tanımı 6.

[86] ve [82] referans numaralı çalışmalarda analizi yapılmış **değişken katsayılı ve zamana bağlı gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}\dot{x}_i(t) = & -c_i(t) x_i(t) + \sum_{j=1}^n a_{ij}(t) f_j(x_j(t)) + \sum_{j=1}^n b_{ij}(t) u_j(t) + I_i(t) \\ & + \bigwedge_{j=1}^n \alpha_{ij}(t) f_j(x_j(t - \tau_j(t))) + \bigvee_{j=1}^n \beta_{ij}(t) f_j(x_j(t - \tau_j(t))) \\ & + \bigwedge_{j=1}^n T_{ij}(t) u_j(t) + \bigvee_{j=1}^n H_{ij}(t) u_j(t), \quad i = 1, 2, \dots, n,\end{aligned}$$

$\alpha_{ij}(t), \beta_{ij}(t), T_{ij}(t)$ ve $H_{ij}(t)$ sırasıyla t zamanda bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $a_{ij}(t), b_{ij}(t)$ sırasıyla t zamanda geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; $x_i(t), u_i(t)$ ve $I_i(t)$ sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $\tau_j(t)$ iletim gecikmesi ve $f_j(t)$ aktivasyon fonksiyonudur;

Model Tanımı 7.

[77] referans numaralı çalışma ile literatüre sunulan **zamana bağlı gecikmeli ve dürtü-lü bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i(t)}{dt} = & -\alpha_i(x_i(t))[\beta_i x_i(t) - \sum_{j=1}^n a_{ij} f_j(x_j(t)) - \sum_{j=1}^n \tilde{a}_{ij} u_j \\ & - \bigwedge_{j=1}^n b_{ij} g_j(x_j(t - \tau_{ij}(t))) - \bigvee_{j=1}^n \tilde{b}_{ij} g_j(x_j(t - \tau_{ij}(t))) \\ & - \bigwedge_{j=1}^n T_{ij} u_j - \bigvee_{j=1}^n H_{ij} u_j + J_i] \quad , t \neq t_k \end{aligned}$$

$$x_i(t^+) = x_i(t^-) + I_{ik}(x_i(t^-)), \quad t = t_k, \quad k \in N$$

$i = 1, \dots, n$ için, burada $N \triangleq \{1, 2, \dots\}$; $n \geq 2$ ağdaki nöronların sayısıdır; $x_i(t)$ i inci nöronun t zamandaki durumunu temsil eder; $\alpha_i(\cdot)$ bir amplifikasyon genişletme fonksiyonunu temsil eder; $\beta_i(\cdot)$ uygun davranım fonksiyonu; $f_j(\cdot)$ ve $g_j(\cdot)$ j inci nöronun aktivasyon fonksiyonlarını temsil eder; u_i ve J_i sırasıyla i inci nöronun girdi ve sapmalarını temsil eder; a_{ij} ve $\tilde{a}_{ij}$ sırasıyla geri besleme ve ileri besleme şablonu elemanlarıdır; b_{ij} ve $\tilde{b}_{ij}$ sırasıyla gecikme bulanık geri beslemeli MIN şablonunu , gecikme bulanık geri beslemeli MAX şablonudur; T_{ij} ve H_{ij} sırasıyla bulanık ileri beslemeli MIN şablon ve bulanık ileri beslemeli MAX şablondur. $\tau_{ij}(t)$ ($0 \leq \tau_{ij}(t) \leq \tau_{ij} \leq \tau$) geçiş gecikmesini temsil eder; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; t_k impulsif moment olarak adlandırılır ve $0 \leq t_1 \leq t_2, \dots, \lim_{t \rightarrow +\infty} t_k = +\infty$ sağlar, burada $x_i(t_k^+)$ ve $x_i(t_k^-)$ sırasıyla t_k da sağdan ve soldan limiti temsil eder. I_{ik}, t_k zamanda i inci nöronun dürtüsel pertürbasyonunu gösterir.

Model Tanımı 8.

[89] referans numaralı çalışma ile literatüre sunulan **karma gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\dot{x}_i(t) = & -d_i x(t) + \sum_{j=1}^n a_{ij} f_j(t - \tau_{ij}(t)) + \sum_{j=1}^n b_{ij} u_j + I_i \\
& + \bigwedge_{j=1}^n \alpha_{ij} \int_0^\infty k_{ij}(s) g_j(x_j(t-s)) ds + \bigwedge_{j=1}^n T_{ij} u_j \\
& + \bigvee_{j=1}^n \beta_{ij} \int_0^\infty k_{ij}(s) g_j(x_j(t-s)) ds + \bigvee_{j=1}^n H_{ij} u_j
\end{aligned}$$

$x_i(s) = \phi_i(s)$, $s \in (-\infty, 0]$, $i \in N = \{1, 2, 3, \dots, n\}$ başlangıç değerleriyle burada d_i t zamanda i inci birimin durumuna pasif çürüme oranlarını temsil eder. α_{ij} , β_{ij} , T_{ij} ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij} , b_{ij} geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i , u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $\tau_{ij}(t)$ t zamanda i inci birimden j biriminin akson boyunca iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij} \leq \tau$ i sağlar. f_j ve g_j aktivasyon fonksiyonlarıdır ve Lipschitz süreklidir. Geri besleme kerneli k_{ij} gerçek değerli negatif olmayan sürekli bir fonksiyondur; başlangıç değeri $\phi_i(\cdot)$ $(-\infty, 0]$ da tanımlı gerçek değerli sınırlı sürekli fonksiyondur.

$k_{ij} : (0, \infty) \rightarrow [0, \infty)$ sınırlı, sürekli ve bazı $\lambda > 0$ için $\int_0^\infty k_{ij}(s) ds = 1$, $\int_0^\infty k_{ij}(s) e^{\lambda s} ds < \infty$ 'u sağlar.

Model Tanımı 9.

[101] referans numaralı çalışma ile literatüre sunulan **dağıtık gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{dx_i}{dt} = & -d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} \mu_j + I_i \\
& + \bigwedge_{j=1}^n \alpha_{ij} \int_{t-\tau}^t k_j(t-s) f_j(x_j(s)) ds + \bigwedge_{j=1}^n T_{ij} \mu_j \\
& + \bigvee_{j=1}^n \beta_{ij} \int_{t-\tau}^t k_j(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n H_{ij} \mu_j, \\
& x_i(t) = \varphi_i(t), -\tau \leq t \leq 0;
\end{aligned}$$

burada α_{ij} , β_{ij} , T_{ij} ve H_{ij} sırasıyla sbulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij} ve b_{ij} geri besleme ve ileri besleme şablonunun elemanlarıdır. $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i , μ_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder; f_i aktivasyon fonksiyonudur. $k_i(s) \geq 0$, τ bir pozitif sonlu sayı ise $[0, \tau]$ aralığında, τ sonsuz ise $[0, +\infty)$ aralığında tanımlı geri besleme kernelidir ve aşağıdaki koşulu sağlar;

$$\int_0^\tau k_j(s) ds = 1, \quad i = 1, \dots, n.$$

Model Tanımı 10.

[65] referans numaralı çalışma ile literatüre sunulan **sınırsız dağıtık gecikmeli gecikmiş bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\dot{x}_i(t) = & -d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j((t-h))) + \sum_{j=1}^n c_{ij} u_j + I_i \\
& + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds \\
& + \bigwedge_{j=1}^n \varsigma_{ij} u_j + \bigvee_{j=1}^n \delta_{ij} u_j, \quad i = 1, 2, \dots, n,
\end{aligned}$$

$\alpha_{ij}, \beta_{ij}, \varsigma_{ij}$ ve δ_{ij} sırasıyla t zamanda bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij}, b_{ij} geri besleme şablonunun elemanlarıdır; c_{ij} ileri besleme şablonunun elemanlarıdır. $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder; $f_i(\cdot)$ aktivasyon fonksiyonlarıdır; $h > 0$ sınırlı iletim gecikmesidir. $k_i(s) \geq 0$ geri besleme kernelidir ve aşağıdaki koşulu sağlar;

$$\int_0^\infty k_i(s) ds = 1, \quad i = 1, \dots, n.$$

Model Tanımı 11.

[64] referans numaralı çalışma ile literatüre sunulan **dağıtık gecikmeli ve reaksiyon difüzyon terimli otonom olmayan bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{\partial u_i(t, x)}{\partial t} = & \sum_{k=1}^p \frac{\partial}{\partial x_k} (D_{ik} \frac{\partial u_i(t, x)}{\partial x_k}) - c_i(t) u_i(t, x) + \sum_{j=1}^n a_{ij}(t) f_j(u_j(t, x)) \\
& + \sum_{j=1}^n b_{ij}(t) \mu_j(t) + I_i(t) + \bigwedge_{j=1}^n \alpha_{ij}(t) \int_{-\infty}^t k_{ij}(t-s) g_j(u_j(s, x)) ds \\
& + \bigwedge_{j=1}^n T_{ij}(t) \mu_j(t) + \bigvee_{j=1}^n \beta_{ij}(t) \int_{-\infty}^t k_{ij}(t-s) g_j(u_j(s, x)) ds \\
& + \bigvee_{j=1}^n H_{ij}(t) \mu_j(t),
\end{aligned}$$

burada $i = 1, 2, \dots, n$, $t \in R_+ = [0, +\infty)$, $x = (x_1, x_2, \dots, x_p)^T \in \Omega \subset R^p$. Ω , $\partial\Omega$ pürüzsüz sınırlı bir kompakt kümedir ve $mes\Omega > 0$ R^p uzayında Ω 'nın ölçüsünü gösterir. $u_i(t, x)$, x noktasında t zamanda i inci birimin durumudur; tam sayı n bir sinir ağındaki birimlerin sayısına karşılık gelir. $f_j(\cdot)$ ve $g_j(\cdot)$ j inci birimin sinyal yayma fonksiyonlarını temsil eder; $c_i(t)$ t zamanda i inci nöronun ağlar ve dış girdilerden izole olduğunda dinlenme durumu potansiyelini sıfırlama oranını gösterir. $a_{ij}(t)$ ve $b_{ij}(t)$, t zamanda geri besleme şablonu ve ileri besleme şablonu elemanlarıdır. $\alpha_{ij}(t)$, $\beta_{ij}(t)$, $T_{ij}(t)$ ve $H_{ij}(t)$ sırasıyla t zamanda bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu, bulanık ileri besleme MAX şablonunun elemanlarıdır. $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir. $I_i(t)$ t zamanda i inci nörondaki dış sapmaları gösterir. $\mu_i(t)$ t zamanda i inci nöronun girdisini gösterir. $D_{ik} \geq 0$ i inci nöron boyunca iletim difüzyon katsayısına karşılık gelir.

Model Tanımı 12.

[70] referans numaralı çalışma ile literatüre sunulan **zamana bağlı gecikmeli ve reaksiyon difüzyon terimli kesin olmayan bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{\partial u_i(t)}{\partial t} = & \sum_{k=1}^l \frac{\partial}{\partial x_k} (D_{ik} \frac{\partial u_i(t)}{\partial x_k}) - (d_i + \Delta d_i) u_i(t) + \sum_{j=1}^n (a_{ij} + \Delta a_{ij}) + f_j(u_j(t)) \\
& + \sum_{j=1}^n b_{ij} \mu_j + v_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(u_j(t - \tau_j(t))) + \bigvee_{j=1}^n \beta_{ij} f_j(u_j(t - \tau_j(t))) \\
& + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n H_{ij} \mu_j, \quad t \geq 0,
\end{aligned}$$

$$\frac{\partial u_i}{\partial n} = \left(\frac{\partial u_i}{\partial x_1}, \dots, \frac{\partial u_i}{\partial x_l} \right)^T = 0, \quad t \geq 0 \quad x \in \partial\Omega,$$

$$u_i(s) = \phi_i(s), \quad -\infty < s \leq 0, \quad x \in \Omega, \quad i = 1, 2, \dots, n, \quad t \geq 0.$$

burada $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; a_{ij} ve b_{ij} geri besleme ve ileri besleme şablonunun elemanlarıdır; d_i sabit köşegen elemanlarıdır. $\Delta d_i, \Delta a_{ij}$ zamanla değişen parametre belirsizliklerini temsil eder. $D_{ik} = D_{ik}(t) \geq 0$ i inci nöron boyunca iletim difüzyon operatörünü gösterir. $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir. u_i, μ_i ve v_i sırasıyla i inci nöronların durum, girdi ve sapmalarını gösterir. f_i aktivasyon fonksiyonudur, $\tau(t)$ iletim gecikmesidir ve $0 < \tau(t) \leq \bar{\tau}$, $0 < \dot{\tau}(t) \leq \tau^* < \infty$ i sağlar, burada $\bar{\tau}$ gecikmelerin üst sınırı ve τ^* bir sabittir.

Model Tanımı 13.

[52] ve [59] referans numaralı çalışmalarda analizi yapılmış **sızma teriminde zaman gecikmeli ve sınırsız dağıtık gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\dot{x}_i(t) = & -d_i x_i(t - \sigma) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau(t))) + \sum_{j=1}^n c_{ij} u_j \\
& + I_i + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds \\
& + \bigwedge_{j=1}^n \zeta_{ij} u_j + \bigvee_{j=1}^n \delta_{ij} u_j, \quad i \in \Lambda
\end{aligned}$$

$\alpha_{ij}(t)$, $\beta_{ij}(t)$, ζ_{ij} ve δ_{ij} sırasıyla t zamanda bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij} , b_{ij} geri besleme şablonu elemanları ve c_{ij} ileri besleme şablonunun elemanıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i , u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. d_i bir diyagonal matristir, ağlar ve dış girişlerden bağlantısız olduğunda izole dinlenme durumu potansiyelini sıfırlayacak i inci nöronun oranını temsil eder, f_i aktivasyon fonksiyonudur ve Lipschitz süreklidir; $\tau(t)$ iletim gecikmesidir ve $0 \leq \tau(t) \leq \tau$ 'i sağlar. Burada τ bir pozitif sabittir. σ leakage gecikmesidir ve $\sigma \geq 0$ 'ı sağlar. $k_i(s) \geq 0$ geri besleme kernelidir ve aşağıdaki koşulu sağlar;

$$\int_0^\infty k_i(s) ds = 1, \quad i \in \Lambda$$

Model Tanımı 14.

[43] ve [108] referans numaralı çalışmalarda analizi yapılmış **zamana bağlı sızma gecikmeli ve reaksiyon difüzyon terimli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{\partial u_i(t, x)}{\partial t} = & \sum_{k=1}^m \frac{\partial}{\partial x_k} (D_{ik} \frac{\partial u_i(t, x)}{\partial x_k}) - d_i u_i(t - \delta_i(t), x) + \sum_{j=1}^n a_{ij} f_j(u_j(t, x)) \\
& + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(u_j(t - \tau_{ij}(t), x)) + \bigvee_{j=1}^n \beta_{ij} f_j(u_j(t - \tau_{ij}(t), x)) \\
& + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n H_{ij} \mu_j, \quad (t, x) \in [0, +\infty) \times \Omega,
\end{aligned}$$

burada n sinir ağlarındaki nöronların sayısıdır; $x = (x_1, x_2, \dots, x_m)^T \in \Omega \subset R^m$ ve $\Omega = \{x = (x_1, x_2, \dots, x_m)^T : |x_k| \leq l_k, k = 1, 2, \dots, m\}$ $\partial\Omega$ pürüzsüz sınıra sahip sınırlı kompakt bir kümedir ve R^m uzayında $\text{mes}\Omega > 0$ dır. $u_i(t, x)$ x uzayında, t zamanda i inci sinir birimi ile ilişkili durum değişkenini göstermektedir; $d_i > 0$ i inci birimin ağ ve harici girdilerden izole olduğunda dinlenme durumunu sıfırlama oranını gösterir; a_{ij} ve b_{ij} geri besleme ve ileri besleme şablonunun elemanlarıdır; $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir. μ_j girdiyi gösterir; I_i i inci nöronun sapmalarını gösterir; $f_j(\cdot)$ t zamanda x uzayında j inci nöronların aktivasyon fonksiyonudur; $D_{ik} = D_{ik}(t, x) \geq 0$ i inci nöron boyunca iletim difüzyon operatörünü gösterir; $\delta_i(t) \geq 0$ ve $\tau_{ij}(t) \geq 0$ sırasıyla sızdırma gecikmeleri ve iletim gecikmelerini temsil eder ve $i, j = 1, 2, \dots, n$. dir.

Model Tanımı 15.

[57] referans numaralı çalışma ile literatüre sunulan **sızma teriminde zaman gecikmeli, ayrık ve sınırsız dağıtık gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\dot{x}_i(t) = & -a_i x_i(t - \sigma) + \sum_{j=1}^n b_{0ij} g_j(x_j(t)) + \sum_{j=1}^n b_{1ij} g_j(x_j(t - \tau(t))) \\
& + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_j(t - s) g_j(x_j(s)) ds + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_j(t - s) g_j(x_j(s)) ds, \quad i \in \Lambda,
\end{aligned}$$

$$x_i(s) = u_i(s), \quad s \in (-\infty, 0]$$

burada $u_i(\cdot) \in C((-\infty, 0], R)$; α_{ij} ve β_{ij} sırasıyla bulanık geri besleme MIN şablonu ve bulanık geri besleme MAX şablonunun elemanlarıdır; $b_{0_{ij}}$ ve $b_{1_{ij}}$ geri besleme şablonunun elemanlarıdır; $\bigwedge, \bigvee$ sırasıyla bulanık AND ve bulanık OR operasyonunu gösterir; x_i i inci nöronun durumunu gösterir; a_i bir diyagonal matristir; a_i i inci nöronun harici girdiler ve ağlardan bağlantısı koptuğunda izole dinlenme durumunu sıfırlama oranını gösterir; g_j nöron aktivasyon fonksiyonunu temsil eder; $k_i(s) \geq 0$ geri besleme kernelidir ve

$$\int_0^\infty k_i(s)ds = 1, \quad i \in \Lambda.$$

'yi sağlar. İletim gecikmesi $\tau(t)$ zaman bağlı bir gecikmedir ve τ bir pozitif sabit olmak üzere $0 \leq \tau(t) \leq \tau$ 'i sağlar. Sızma gecikmesi $\sigma, \sigma \geq 0$ 'ı sağlar.

Model Tanımı 16.

[49] referans numaralı çalışmalarda analizi yapılmış **dürtüsel tedirginlikler altında sızma teriminde zaman gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i(t)}{dt} = & -d_i x_i(t - \sigma) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} \mu_j + I_i \\ & + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t - \tau_{ij}(t))) + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t - \tau_{ij}(t))) \\ & + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n H_{ij} \mu_j, \end{aligned}$$

$$x_i(t_k) = p_{ik}(x_1(t^-), \dots, x_n(t^-)) + q_{ik}(x_1((t - \tau_{i1}(t))^-), \dots, x_n((t - \tau_{in}(t))^-)), \quad t = t_k,$$

$$x_i(t) = \phi_i(t), \quad -\varrho \leq t \leq 0,$$

burada $i = 1, 2, \dots, n$, x_i, μ_i, I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını gösterir.

rir. Tamsayı n bir sinir ağındaki nöronların sayısına karşılık gelir. $f_j(\cdot)$ j inci birimin sinyal yayma fonksiyonunu gösterir. $d_i > 0$ i inci nöronun harici girdiler ve ağlardan bağlantısı koptuğunda izole dinlenme durumunu sıfırlama oranını gösterir. a_{ij}, b_{ij} , geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır. $\alpha_{ij}, \beta_{ij}, H_{ij}$ ve T_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonu elemanlarıdır. $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder. $\sigma \geq 0$, sızma gecikmesini gösterir. $\tau_{ij}(t)$ i inci birimden j biriminin akson boyunca iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij}(t) \leq \tau$ 'i sağlar. $\varrho = \max\{\sigma, \tau\}$. $\phi(s) = (\phi_1(s), \dots, \phi_n(s))^T \in PC^1[[-\varrho, 0], R^n]$. $p_{ik}(x_1(t^-), \dots, x_n(t^-))$, t_k zamanda i inci birimin dürtüsel düzensizliklerini temsil eder, $q_{ik}(x_1((t - \tau_{i1}(t))^-), \dots, x_n((t - \tau_{in}(t))^-))$ i inci birimin t_k zamanda iletim gecikmelerinden kaynaklı dürtüsel düzensizliklerini temsil eder, ve sabit impulsif momentler $t_k (k = 1, 2, \dots)$, $\varrho < t_1 < t_2 < \dots$ ve $\lim_{k \rightarrow \infty} t_k = \infty$ 'u sağlar.

Model Tanımı 17.

[103] referans numaralı çalışma ile literatüre sunulan **sınırsız gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i}{dt} = & -d_i x_i(t) + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_{ij}(t-s) f_j(x_j(s)) ds \\ & + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_{ij}(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n H_{ij} \mu_j \end{aligned}$$

$\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla t zamanda bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; b_{ij} ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, μ_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder; f_i aktivasyon fonksiyonudur; $k_{ij}(s) \geq 0$ $[0, \infty)$ aralığında tanımlı geri besleme kernelidir ve aşağıdaki koşulu sağlar;

$$\int_0^\infty k_{ij}(s)ds = 1, \quad \int_0^\infty e^{\tau s} k_{ij}(s)ds = k_{ij}, \quad i = 1, \dots, n.$$

burada τ pozitif bir sabittir. Genelliği kaybetmeden, $\tau \leq \min_{1 \leq i \leq n} d_i$, burada $i = 1, \dots, n$, sistem (1) deki sabitler olduğunu varsayalım; $\int_0^\infty e^{\tau s} k_{ij}(s)ds$ $\tau \geq \min_{1 \leq i \leq n} d_i$ için sonluysa, $\tau < \min_{1 \leq i \leq n} d_i$ ile sınırlandırdığımızda $\int_0^\infty e^{\tau s} k_{ij}(s)ds$ in sonlu olduğu aşikardır.

Model Tanımı 18.

[44] referans numaralı çalışma ile literatüre sunulan **karma gecikmeli ve dürtüsel düzensizlikler altında sızma gecikmeli bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \dot{x}_i(t) = & -d_i x_i(t - \sigma) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} f_j(x_j(t - \tau(t))) + \sum_{j=1}^n c_{ij} \varrho_j \\ & + \chi_i + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_j(t-s) f_j(x_j(s)) ds \\ & + \bigwedge_{j=1}^n \varsigma_{ij} \varrho_j + \bigvee_{j=1}^n \delta_{ij} \varrho_j, \quad t \neq t_k, \end{aligned}$$

$$\Delta x_i(t_k) = x_i(t_k) - x_i(t_k^-) = J_{ik}(x_i(t_k^-)), \quad k \in Z_+,$$

$$x_i(s) = \varphi_i(s), \quad s \in (-\infty, 0], \quad i \in N,$$

burada $\alpha_{ij}, \beta_{ij}, \varsigma_{ij}$ ve δ_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır. a_{ij} ve b_{ij} geri besleme şablonunun elemanları ve c_{ij} ileri besleme şablonunun elemanlarıdır. $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir. $x_i(t), \varrho_j$ ve χ_i sırasıyla i inci nöronun durum, girdi ve sapmalarını gösterir. Sistem (2)nin sağ tarafındaki ilk terim sinir ağındaki sızdırma terimini gösterir, $\sigma \geq 0$ sızdırma gecikmesi veya unutulma

gecikmesini gösterir. $f_i(\cdot)$ aktivasyon fonksiyonudur, $\tau(t)$ iletim gecikmesidir, ve $k_j(s) \geq 0$ geri besleme kernelidir ve

$$\int_0^\infty k_j(s)ds = 1, \quad j \in N, \quad (3)$$

i sağlar. $\varphi_i(s)(i \in N), (-\infty, 0]$ da sürekli ve normu

$$\|\varphi\|_\infty = \max\{\sup_{-\infty \leq s \leq 0} \|\varphi(s)\|, \sup_{-\sigma \leq s \leq 0} \|\dot{\varphi}(s)\|\}$$

ile tanımlanır.

Model Tanımı 19.

[99] referans numaralı çalışma ile literatüre sunulan **dürtülü bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i(t)}{dt} &= -d_i x_i(t) + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t)) + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t)) \\ &\quad + \bigvee_{j=1}^n H_{ij} \mu_j, \quad t \neq t_k, \\ x(t_0^+) &= x_0 \in R^n, \\ \Delta x_i(t_k) &= x_i(t_k^+) - x_i(t_k^-) = -\gamma_{ik} x_i(t_k), \quad i = 1, \dots, n, \quad k = 1, 2, \dots, n \end{aligned}$$

Burada $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MIN şablonunun elemanlarıdır; b_{ij} ileri besleme şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR operasyonlarını gösterir; x_i, μ_i ve I_i sırasıyla i inci nöronların durum, girdi ve sapmalarını gösterir; f_i aktivasyon fonksiyonudur; $\Delta x_i(t_k) = x_i(t_k^+) - x_i(t_k^-)$, $k = 1, 2, \dots, t_k$ anlarındaki dürtülerdir ve $t_1 < t_2 < \dots$ kesin artan dizisi $\lim_{k \rightarrow \infty} t_k = \infty$.

Model Tanımı 20.

[93] referans numaralı çalışma ile literatüre sunulan **dürtülü ve değişken gecikmeli ayrık zamanlı bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 u_i(m+1) = & c_i(m)u_i(m) + \sum_{j=1}^n a_{ij}(m)f_j(u_j(m)) + \sum_{j=1}^n b_{ij}(m)v_j(m) + I_i(m) \\
 & + \bigwedge_{j=1}^n \alpha_{ij}(m)f_j(u_j(m - \tau_{ij}(m))) + \bigvee_{j=1}^n \beta_{ij}(m)f_j(u_j(m - \tau_{ij}(m))) \\
 & + \bigwedge_{j=1}^n T_{ij}(m)v_j(m) + \bigvee_{j=1}^n H_{ij}(m)v_j(m), \quad m \neq m_k,
 \end{aligned}$$

$$\begin{aligned}
 u_i(m) = & p_{ik}(u_1(m^-), \dots, u_n(m^-)) + q_{ik}(u_1((m - \tau_{i1}(m))^-), \dots, \\
 & u_n((m - \tau_{in}(m))^-)) + J_{ik}(m), \quad m = m_k
 \end{aligned}$$

$i = 1, 2, \dots, n$; $k = 1, 2, \dots$. Burada n sinir ağındaki birimlerin sayısına karşılık gelir; $u_i(m)$ m zamanda i inci birimin durumuna karşılık gelir; $\tau_{ij}(m)$ i inci birimden j inci birim boyunca iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij}(m) \leq \tau$ (τ negatif olmayan bir tam sayıdır) i sağlar; α_{ij} ve β_{ij} sırasıyla bulanık geri beslemeli MIN şablon ve bulanık geri beslemeli MAX şablonun elemanlarıdır; T_{ij} ve H_{ij} sırasıyla bulanık ileri beslemeli MIN şablon ve bulanık ileri beslemeli MAX şablonun elemanlarıdır; v_i ve I_i sırasıyla i inci nöronların girdi ve sapmalarını temsil eder; a_{ij} ve b_{ij} sırasıyla geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; $c_i \in (0, 1)$. m_k dürtüsel anlar olarak adlandırılır ve $0 \leq m_1 < m_2 < \dots, \lim_{k \rightarrow +\infty} m_k = +\infty$ 'i sağlar; $p_{ik}(u_1(m^-), \dots, u_n(m^-))$ m_k zamanda i inci birimin dürtüsel düzensizlikleri temsil eder; $q_{ik}(u_1((m - \tau_{i1}(m))^-), \dots, (u_n((m - \tau_{in}(m))^-))$ m_k zamanda i inci birimin iletim gecikmelerinden kaynaklı dürtüsel düzensizlikleri gösterir. J_{ik} m_k zamanda harici dürtü girdisini temsil eder.

Model Tanımı 21.

[96] referans numaralı çalışma ile literatüre sunulan **dağıtık gecikmeli dürtülü bulanık hücre-**

sel sinir ağı modeli aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i(t)}{dt} = & -d_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n \tilde{a}_{ij} u_j(t) + I_i(t) \\ & + \bigwedge_{j=1}^n b_{ij} \int_{-\infty}^t K_{ij}(t-s) f_j(x_j(s)) ds + \bigvee_{j=1}^n \tilde{b}_{ij} \int_{-\infty}^t K_{ij}(t-s) f_j(x_j(s)) ds \\ & + \bigwedge_{j=1}^n T_{ij} u_j(t) + \bigvee_{j=1}^n H_{ij} u_j(t) \quad t \neq t_k, \end{aligned}$$

$$\Delta x_i(t_k) = x_i(t_k^+) - x_i(t_k^-) = \Delta_k(x_i(t_k)), \quad t = t_k,$$

burada t_k sabit zamanları $t_1 < t_2 < \dots, \lim_{k \rightarrow \infty} t_k = \infty$ i sağlar.

İkinci modelin ilk kısmı (sürekli kısım olarak adlandırılır) FCNN nin sürekli süreçlerini tanımlar. n sinir ağındaki birimlerin sayısını temsil eder. x_i durum değişkenine karşılık gelir; $f_j(x_j(t))$ j inci nöronun aktivasyon fonksiyonunu göstermektedir; u_i ve $I_i(t)$ sırasıyla i inci nöronun girdi ve sapmalarını temsil eder. d_i birim ağırlar ve harici girişler bağlantısı kesildiğinde, i inci birimin izolasyon dinlenme durumuna potansiyelini sıfırlama oranını temsil eder. a_{ij} ve $\tilde{a}_{ij}$ geri besleme şablonu ve ileri besleme şablonun elemanlarıdır; b_{ij} , $\tilde{b}_{ij}$ dağıtık gecikme bulanık geri besleme MIN şablonu, dağıtık gecikme bulanık geri besleme MAX şablonunun elemanları, T_{ij} ve H_{ij} sırasıyla bulanık ileri beslemeli MIN şablonu, bulanık ileri beslemeli MAX şablonunun elemanlarıdır, K_{ij} gecikme kernelini temsil eder. $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder. İkinci kısmı (ayrık kısım olarak adlandırılır) t_k (dürtüsel anlar olarak adlandırılan) zaman anında durumların ani değişimlerini deneyimleyen gelişim süreçleri tanımlar. $\Delta x_i(t_k)$, t_k zamanda i inci birimin dürtüsel düzensizliklerini temsil eder ve $\Delta_k, k = 1, 2, \dots$ için t_k zamanda dürtüsel operatörü temsil eder.

Model Tanımı 22.

[79] referans numaralı çalışma ile literatüre sunulan **karma gecikmeli ve reaksiyon difüzyon terimli dürtülü bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{\partial u_i(t, x)}{\partial t} = & \sum_{r=1}^m \frac{\partial}{\partial x_r} (D_{ir} \frac{\partial u_i(t, x)}{\partial x_r} - a_i u_i(t, x) + \sum_{j=1}^n a_{ij} \hat{f}_j(u_j(t, x)) \\
& + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigwedge_{j=1}^n \alpha_{ij} g_j(u_j(t - \tau_{ij}(t), x)) \\
& + \bigwedge_{j=1}^n \gamma_{ij} \int_{-\infty}^t k_{ij}(t - s) f_j(u_j(s, x)) ds + \bigvee_{j=1}^n H_{ij} \mu_j \\
& + \bigvee_{j=1}^n \beta_{ij} g_j(u_j(t - \tau_{ij}(t), x)) + \bigvee_{j=1}^n \theta_{ij} \int_{-\infty}^t k_{ij}(t - s) f_j(u_j(s, x)) ds, \\
& t_0 \leq t \neq t_k, \quad x \in \Omega
\end{aligned}$$

$$\left(\frac{\partial u_i(t, x)}{\partial n} \right) = \left(\frac{\partial u_i(t, x)}{\partial x_1}, \dots, \frac{\partial u_i(t, x)}{\partial x_n} \right)^T = 0, \quad t > t_0, \quad x \in \partial\Omega,$$

$$u_i(t_0 + s, x) = \phi_i(s, x), \quad -\infty < s \leq 0, \quad x \in \Omega,$$

$$\begin{aligned}
u_i(t_k, x) = & w_{ik}(u_1, ((t_k - \tau_{i1}(t_k))^- , x), \dots, u_n((t_k - \tau_{in}(t_k))^- , x)) + h_{ik}(u_1(t_k^-, x), \\
& \dots, u_n(t_k^-, x)) + J_{ik}, \quad x \in \Omega,
\end{aligned}$$

burada $i, j = 1, 2, \dots, n$, $k = 1, 2, \dots$ ve n bir sinir ağı içindeki birimlerin sayısına karşılık gelir; $u_i(t, x)$ (t, x) de i inci birimin durumuna karşılık gelir; $D_{ir} = D_{ir}(t, x) \geq 0$ iletim difüzyon operatörüne karşılık gelir; α_{ij} ve γ_{ij} bulanık geri besleme MIN şablonunun elemanlarıdır; β_{ij} ve θ_{ij} bulanık geri besleme MAX şablonunun elemanlarıdır; T_{ij} ve H_{ij} sırasıyla bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; a_{ij} ve b_{ij} sırasıyla geri besleme ve ileri besleme şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; μ_i ve I_i i inci nöronun sırasıyla girdi ve sapmalarını gösterir; $\tilde{f}_j$, f_j ve g_j aktivasyon fonksiyonlarıdır; $\tau_{ij}(t)$ iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij}(t) \leq \tau$ i sağlar; $k_{ij}(s) \geq 0$ $[0, +\infty)$ aralığında tanımlı geri besleme kernelidir ve $\int_0^\infty e^{\lambda_0 t} k_{ij}(t) dt < \infty$ u sağlar; burada λ_0 pozitif bir sabittir; $h_{ik}(u_1(t_k^-, x), \dots, u_n(t_k^-, x))$ t_k zamanda i inci nöronun dürtüsel düzensizliklerini gösterir ve $w_{ik}(u_1, ((t_k - \tau_{i1}(t_k))^- , x), \dots, u_n((t_k - \tau_{in}(t_k))^- , x))$ t_k

zamanda i inci nöronun iletim gecikmelerinden kaynaklı dürtüsel düzensizliklerini gösterir; J_{ik} sabit darbe girişidir; $\phi_i(s, x) \in PC_\Omega$ başlangıç değeridir; t_k dürtü momenti olarak adlandırılır ve $t_0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty, k = 1, 2, \dots$ yi sağlar.

Model Tanımı 23.

[74] referans numaralı çalışma ile literatüre sunulan **dağıtık gecikmeli ve reaksiyon difüzyon terimli dürtülü bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{\partial u_i(t, x)}{\partial t} = & \mu_i \Delta u_i(t, x) - c_i u_i(t, x) + \sum_{j=1}^n a_{ij} f_j(u_j(t, x)) + \sum_{j=1}^n b_{ij} v_j \\ & + \bigwedge_{j=1}^n \alpha_{ij} \int_0^{+\infty} K_{ij}(s) f_j(u_j(t-s, x)) ds \\ & + \bigvee_{j=1}^n \beta_{ij} \int_0^{+\infty} K_{ij}(s) f_j(u_j(t-s, x)) ds + J_i \\ & + \bigwedge_{j=1}^n T_{ij} v_j + \bigvee_{j=1}^n H_{ij} v_j, \quad t \geq 0, \quad t \neq t_k \quad x \in \Omega \quad (1a) \end{aligned}$$

$$\begin{aligned} u_i(t^+, x) &= u_i(t^-, x) + I_{ik}(u_i(t^-, x)), \quad t = t_k, \quad x \in \Omega, \\ k \in N &\triangleq \{1, 2, \dots\}, \quad (1b) \end{aligned}$$

$$\frac{\partial u_i}{\partial m} = 0, \quad t \geq 0, \quad x \in \partial\Omega, \quad (1c)$$

$$u_i(s, x) = \phi_i(s, x), \quad -\infty \leq s \leq 0, \quad (1d)$$

$i = 1, 2, \dots, n$ için. Buarada $\partial/\partial m$ ile gösterilen dış normal türevi, $\bar{\Omega} = \Omega \cup \partial\Omega$, ve $\Delta u_i = \sum_{k=1}^l \frac{\partial^2 u_i}{\partial x_k^2}$ Laplace operatörünü gösterir, $\mu_i \geq 0$ difüzyon katsayısı; n bir sinir ağındaki birimlerin sayısına karşılık gelir; $u_i(t, x)$ x uzayında t zamanda i inci birimin durumuna karşılık gelir; $f_j(u_j(t, x))$ t zamanda x uzayında j inci birimin aktivasyon fonksiyonunu gösterir; v_i ve J_i sırasıyla i inci nöronun girdi ve sapmalarını gösterir; c_i i inci birimin harici girdiler ve

ağlardan bağlantısı koptuğunda izole dinlenme durumunu sıfırlama oranını gösterir; a_{ij} ve b_{ij} geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; α_{ij}, β_{ij} gecikme bulanık geri besleme MIN şablonu ve gecikme bulanık geri besleme MAX şablonunun elemanlarıdır; T_{ij} ve H_{ij} sırasıyla bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir; gecikme kerneli $K_{ij} : [0, +\infty) \rightarrow [0, +\infty)$ gerçek değerli sürekli bir fonksiyondur ve $\int_0^{+\infty} e^{\lambda s} K_{ij}(s) ds = r_{ij}(\lambda)$ i sağlar, burada $r_{ij}(\lambda)$ $[0, \delta)$ da bir sürekli fonksiyondur, $\delta > 0$ ve $r_{ij}(0) = 1, i, j = 1, 2, \dots, n$. (1b) de t_k dürtüsel moment olarak adlandırılır ve $0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$ u sağlar; $u_i(t_k^-, x)$ ve $u_i(t_k^+, x)$ sırasıyla t_k da soldan ve sağdan limitlerini gösterir; I_{ik} t_k zamanda i inci nöronun dürtüsel düzensizliklerini gösterir. $u_i(t_k^+, x) = u_i(t_k, x), k \in N$ olduğunu varsayıyoruz. (1c) ve (1d) sırasıyla Neumann sınır koşulları ve başlangıç koşullarını temsil eder.

Model Tanımı 24.

[78] ve [87] referans numaralı çalışmalarda analizi yapılmış **gecikmeli stokastik bulanık hücre-sel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} dx_i(t) &= [-c_i x_i(t) + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t - \tau)) + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t - \tau)) + \bigwedge_{j=1}^n T_{ij} u_j \\ &\quad + \bigvee_{j=1}^n H_{ij} u_j + I_i] dt + \sum_{j=1}^n \sigma_{ij}(x_j(t)) dw_j(t), \quad t \geq 0, \\ x_i(t) &= \phi_i(t), \quad -\tau \leq t \leq 0 \end{aligned}$$

$\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $f_i(\cdot)$ aktivasyon fonksiyonudur. $i, j = 1, \dots, n$. $\sigma(\cdot) = (\sigma_{ij}(\cdot))_{n \times n}$ difüzyon katsayı matrisi ve $w(\cdot) = (w_1(\cdot), \dots, w_n(\cdot))^T$ doğal süzümli $\{F_t\}_{t \geq 0}$ bir tam olasılık uzayında (Ω, F, P) tanımlı n boyutlu bir Brownian hareketidir. Başlangıç verisi $\phi_i(t)$ C değerli F_0 ölçülebilir rastgele bir değerdir. $x(t)$ nin $t \geq 0$ sistem (1) in üzerinde tekil global çözümü olduğunu varsayalım. Burada $x(t) = (x_1(t), \dots, x_n(t))^T$ dir.

Model Tanımı 25.

[63] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 dx_i(t) = & [-c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(x_j(t - \tau(t))) \\
 & + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n \beta_{ij} f_j(x_j(t - \tau(t))) + \bigvee_{j=1}^n H_{ij} \mu_j] dt \\
 & + \sum_{j=1}^n \sigma_{ij}(t, x(t), x(t - \tau(t))) dw_j(t), \quad t \geq 0
 \end{aligned}$$

$$x_i(t) = \phi_i(t), \quad -\tau \leq t \leq 0,$$

burada $i = 1, 2, \dots, n$, x_i, μ_i, I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını gösterir. Tamsayı n bir sinir ağlarındaki birimlerin sayısına karşılık gelir. $f_j(\cdot)$ j inci birimin sinyal yayılım fonksiyonunu gösterir. $c_i > 0$ i inci nöronun harici girdiler ve ağlardan bağlantısı koptuğunda izole dinlenme durumunu sıfırlama oranını gösterir. a_{ij}, b_{ij} geri besleme ve ileri besleme şablonunun elemanlarıdır. $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; $\tau(t)$ t zamandaki iletim gecikmesini temsil eder ve $\tau(t) : R_+ \rightarrow [0, \tau]$ sürekli türevlenebilir fonksiyondur öyle ki $\dot{\tau}(t) \leq \kappa < 1$. $\sigma(t, x(t), x(t - \tau(t))) = (\sigma_{ij}(t, x(t), x(t - \tau(t))))_{n \times n}$ difüzyon katsayı matrisidir ve $w(t) = (w_1(t), \dots, w_n(t))^T$, $\{F_t\}_{t \geq 0}$ (yani $F_t = \sigma\{w(s) : 0 \leq s \leq t\}$) doğal filtrasyonlu bir tam olasılık uzayında (Ω, F, P) tanımlı n boyutlu bir Brownian hareketidir. $\phi(t) \in L^p_{F_0}([-\tau, 0], R^n)$ başlangıç fonksiyon vektörüdür, burada $L^p_{F_0}([-\tau, 0], R^n)$ tüm C değerli rastgele süreçlerin $\xi(s)$ ailesini gösterir öyle ki $\xi(s), F_0$ ölçülebilirdir ve $\int_0^{-\tau} E \|\xi(s)\|^p ds < \infty$ dir. Bu araştırma boyunca $f_j(\cdot)$ ve $\sigma_{ij}(t, \cdot, \cdot)$ yerel Lipschitz sürekli olmasının yanı sıra lineer büyüme koşulunu sağladığını varsayıyoruz. Öte yandan sistem (1) $t \geq 0$ da $x(t) = (x_1(t), \dots, x_n(t))^T$ ile temsil edilen tek bir global çözümü vardır.

Model Tanımı 26.

[69] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli ve reaksiyon difüzyon terimli stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 du_i(t, x) = & \left[\sum_{k=1}^l \frac{\partial}{\partial x_k} (D_{ik} \frac{\partial u_i(t, x)}{\partial x_k}) - d_i u_i(t, x) + \sum_{j=1}^n a_{ij} f_j(u_j(t - \tau_{ij}(t), x)) \right. \\
 & + \sum_{j=1}^n b_{ij} \mu_j + I_i + \bigwedge_{j=1}^n \alpha_{ij} f_j(u_j(t - \tau_{ij}(t), x)) + \bigvee_{j=1}^n \beta_{ij} f_j(u_j(t - \tau_{ij}(t), x)) \\
 & \left. + \bigwedge_{j=1}^n T_{ij} \mu_j + \bigvee_{j=1}^n H_{ij} \mu_j \right] dt + \sum_{j=1}^n \sigma_{ij}(u_j(t, x), u_j(t - \tau_{ij}(t), x)) dw_j(t), \\
 & (x, t) \in \Omega \times [0, +\infty)
 \end{aligned}$$

burada $i = 1, \dots, n$ $x = (x_1, x_2, \dots, x_l)^T \in \Omega \subset R^l$ ağlardaki nöronların sayısıdır ve $\Omega = \{x = (x_1, x_2, \dots, x_l)^T \mid |x_k| < m_k, k = 1, 2, \dots, l\}$ R_l uzayında $\partial\Omega$ ve $\text{mes}\Omega > 0$ pürüzsüz sınır ile bağlı kompakt set; $u_i(t, x)$ t zamanda x uzayında i inci nöral birimin durumuna karşılık gelir.

$\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $d_i > 0$ t zamanında i başlangıç durumuna pasif çürüme oranını temsil eder. a_{ij} ve b_{ij} sırasıyla bulanık geri besleme şablonu ve bulanık ileri besleme şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; μ_i ve I_i sırasıyla i inci nöronun girdi ve sapmalarını temsil eder. $f_j(\cdot)$ x uzayında t zamandaki j inci nöronların aktivasyon fonksiyonudur. $D_{ik} = D_{ik}(t, x) \geq 0$ i inci nöron boyunca difüzyon geçiş operatörünü temsil eder. τ_{ij} i biriminden j biriminin akson boyunca iletim gecikmesini temsil eder ve $0 \leq \tau_{ij}(t) \leq \tau$ ve $\dot{\tau}_{ij}(t) \leq \gamma < 1$ i sağlar; stokastik bozukluk $w(t) = [w_1(t), w_2(t), \dots, w_n(t)]^T \in R^n (\Omega, F, P)$ tam bir olasılık uzayında tanımlı Brownian hareketi, ve $E\{dw(t)\} = 0$, $E\{dw_2(t)\} = dt$.

Model Tanımı 27.

[48] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli ve dürtülü sto-**

kastik bulanık hücresel sinir ağı modeli aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 dx_i(t) = & [-c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \bigwedge_{j=1}^n \alpha_{ij} g_j(x_j(t - \tau_j(t))) \\
 & + \bigvee_{j=1}^n \beta_{ij} g_j(x_j(t - \tau_j(t))) + I_i] dt + \sum_{j=1}^n \sigma_{ij}(t, x_i(t), x_i(t - \tau_i(t))) dw_j(t), \\
 & t \neq t_k
 \end{aligned}$$

$$\Delta x_i(t_k) = I_{ik}(x(t_k)) = x_i(t_k) - x_i(t_k^-), \quad k \in \mathbb{Z}^+, \quad i = 1, 2, \dots, n,$$

burada n sinir ağlarındaki birimlerin sayısına karşılık gelir. $i = 1, 2, \dots, n$ için $x_i(t)$ i inci nöronun durumuna karşılık gelir; $f_j(\cdot), g_j(\cdot)$ sinyal geçiş fonksiyonlarıdır. $c_i > 0$ bir i hücresinin girdiler ve diğer hücrelerden izole olduğunda dinlenme durumunu sıfırlama oranını gösterir; $\tau_j(t)$ iletim gecikmesini gösterir; a_{ij} geri besleme şablonunun elemanlarını temsil eder; $I_i = \tilde{I}_i + \bigwedge T_{ij} u_j + \bigvee H_{ij} u_j$, $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonu elemanlarıdır; $\bigwedge$ ve $\bigvee$ bulanık AND ve bulanık OR işlemlerini temsil eder; u_j i inci nöronun harici girdilerini temsil eder. $\tilde{I}_i$ i inci birimin harici sapmalarıdır. $\tau_i(t)$ bir iletim gecikmesidir ve $0 \leq \tau_i(t) \leq \tau$ yi sağlar; $\sigma(t, x, y) = (\sigma_{ij}(t, x_i, y_i))_{n \times n} \in R^{n \times n}$ difüzyon katsayı matrisidir ve $\sigma_i(t, x_i, y_i) = (\sigma_{i1}(t, x_i, y_i), \sigma_{i2}(t, x_i, y_i), \dots, \sigma_{in}(t, x_i, y_i))$ $\sigma(t, x, y)$ nin i inci satır vektörüdür: $w(t) = (w_1(t), w_2(t), \dots, w_n(t))^T$ olağan koşulları sağlayan bir filtrasyonla $\{F_t\}_{t \geq 0}$ bir tam olasılık uzayında $(\Omega, F, \{F_t\}_{t \geq 0}, P)$ tanımlı n boyutlu bir Brownian hareketidir. $\Delta x_i(t_k) = x_i(t_k^+) - x_i(t_k^-)$ t_k anındaki dürtülerdir. t_k zamanın sabit anları $0 = t_0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$; $x_t(s) = x(t + s, s \in [-\tau, 0])$ ı sağlar.

Model Tanımı 28.

[60] referans numaralı çalışma ile literatüre sunulan **dağıtık gecikmeli dürtüsel stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
dx_i(t) = & [-c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \bigwedge_{j=1}^n \alpha_{ij} \int_{-\infty}^t k_{ij}(t-s) g_j(x_j(s)) ds \\
& + \bigwedge_{j=1}^n T_{ij} u_j(t) + \bigvee_{j=1}^n \beta_{ij} \int_{-\infty}^t k_{ij}(t-s) g_j(x_j(s)) ds + \bigvee_{j=1}^n H_{ij} u_j(t) + I_i(t)] dt \\
& + \sum_{j=1}^n \sigma_{ij}(x_j(t)) dw_j(t)
\end{aligned}$$

$$\Delta x_i = x_i(t_k^+) - x_i(t_k^-) = I_{ik}(x_i(t_k^-)) \quad t = t_k,$$

$$x_i(t_0 + s) = \phi_i(s), \quad -\infty < t \leq 0, i, j, k \in N = \{1, 2, \dots, n\},$$

burada $c_i > 0$ pasif çürüme oranlarını temsil eder. $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri beslemeli MIN şablonu, bulanık geri beslemeli MAX şablonu, bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; a_{ij} j inci nöronun i inci nörona bağlantı güçlerini temsil eder; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder; x_i, u_i ve I_i sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $f_j(\cdot)$ ve $g_j(\cdot)$ aktivasyon fonksiyonlarıdır. k_{ij} kernelleri $(0, \infty)$ da tanımlı gerçek değerli negatif olmayan parçalı sürekli fonksiyonlardır ve (i) $\int_0^\infty k_{ij}(s) ds = 1$, pozitif bir λ için (ii) $\int_0^\infty k_{ij}(e^{\lambda s}) ds < \infty$ yi sağlar. Dahası $w(t) = (w_1(t), \dots, w_n(t))^T \{w(t) : 0 \leq s \leq t\}$ doğal bir filtrasyonlu $\{F_t\}_{t \geq 0}$ ve her zamanki şartları sağlayan (Ω, F, P) tam olasılık uzayında tanımlı n boyutlu Brownian hareketidir, burada Ω $w(t)$ tarafından oluşturulmuş kanonik uzay ile ilişkilidir. F, P olasılık ölçüsü ile $\{w(t)\}$ tarafından oluşturulmuş ilişkili σ cebiridir. $\sigma : R^n \rightarrow R^{n \times n}$, yani, $\sigma(x) = (\sigma_{ij}(x))_{n \times n}$ difüzyon katsayı matrisidir. t_k impulsif moment olarak adlandırılır ve $0 \leq t_1 \leq t_2, \dots, \lim_{t \rightarrow +\infty} t_k = +\infty$ sağlar, burada $x_i(t_k^+)$ ve $x_i(t_k^-)$ sırasıyla t_k da sağdan ve soldan limiti temsil eder. I_{ik} t_k zamanda i inci nöronun dürtüsel pertürbasyonunu gösterir. Biz daima tüm $k \in N$ ler için $x_i(t_k^+) = x_i(t_k)$ varsayırız.

Model Tanımı 29.

[58] referans numaralı çalışma ile literatüre sunulan **karma gecikmeli dürtüsel stokastik bu-**

lanık hücresel sinir ağı modeli aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 dx_i(t) = & [-c_i x_i(t) + \sum_{j=1}^n a_{ij} f_j(x_j(t)) + \bigwedge_{j=1}^n \alpha_{ij} g_j(x_j(t - \tau_{ij}(t))) \\
 & + \bigwedge_{j=1}^n \delta_{ij} \int_{-\infty}^t K_{ij}(t-s) h_j(x_j(s)) ds + \bigvee_{j=1}^n \beta_{ij} g_j(x_j(t - \tau_{ij}(t))) \\
 & + I_i + \bigvee_{j=1}^n \eta_{ij} \int_{-\infty}^t K_{ij}(t-s) h_j(x_j(s)) ds] dt + \sum_{j=1}^n \sigma_{ij}(x_j(t), \\
 & x_j(t - \tau_{ij}(t))) dw_j(t), \quad t \neq t_k
 \end{aligned}$$

$$\Delta x_i(t_k) = J_k(x_i(t_k^-)), \quad t = t_k, \quad k = 1, 2, \dots$$

$i = 1, 2, \dots, n$. burada n sinir ağlarındaki nöronların sayısıdır, $c_i > 0$ t zamanda i inci birimin durumuna pasif çürüme oranlarını temsil eder. $f_j(\cdot), g_j(\cdot)$ ve $h_j(\cdot)$ aktivasyon fonksiyonudur.

$$I_i = \sum_{j=1}^n b_{ij} u_j + \tilde{I}_i + \bigwedge_{j=1}^n T_{ij} u_j + \bigvee_{j=1}^n H_{ij} u_j.$$

a_{ij} ve b_{ij} geri besleme ve ileri besleme şablonunun elemanlarıdır. α_{ij} ve δ_{ij} bulanık geri besleme MIN şablonu gecikmesinin bağlantı ağırlıklarını gösterir. β_{ij} ve η_{ij} bulanık geri besleme MAX şablonu gecikmesinin bağlantı ağırlıklarını gösterir. T_{ij} ve H_{ij} bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır. $\wedge$ ve $\vee$ sırasıyla bulanık AND ve bulanık OR işlemlerini temsil eder. x_i, u_j ve $\tilde{I}_i$ sırasıyla i inci nöronun durum, girdi ve sapmalarını temsil eder. $\tau_{ij}(t)$, $0 \leq \tau_{ij}(t) \leq \tau_{ij}$ (τ_{ij} bir sabit) ile iletim gecikmesini temsil eder. $K_{ij}(\cdot)$ gecikme kernel fonksiyonudur; $w(t) = (w_1(t), w_2(t), \dots, w_n(t))^T$, (Ω, F, P) tam olasılık uzayında bir doğal filtrasyonla $\{F_t\}_{t \geq 0}$ (yani $F_t = \sigma\{w(s) : 0 \leq s \leq t\}$) tanımlı n boyutlu Brownian hareketidir. t_k dürtüsel an olarak adlandırılır ve $0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$ i sağlar. $x_i(t_k)^+, x_i(t_k)^- t_k$ da soldan ve sağdan limitleri gösterir. Sistem (1) in başlangıç koşullarını tüm $i \in 1, 2, \dots, n$ için $s \leq 0$ $x_i(t_0 + s) = \phi_i(s)$ varsayalım.

Model Tanımı 30.

[47] referans numaralı çalışma ile literatüre sunulan **karma gecikmeli ve reaksiyon difüzyon terimli dürtüsel stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
du_i(t, x) = & \left[\sum_{l=1}^m \frac{\partial}{\partial x_l} (D_{il} \frac{\partial u_i(t, x)}{\partial x_l}) - a_i(t)u_i(t, x) + \sum_{j=1}^n b_{ij}(t)\mu_j(t) \right. \\
& + \sum_{j=1}^n a_{ij}(t)\hat{f}_j(u_j(t, x)) + \bigwedge_{j=1}^n \alpha_{ij}(t)g_j(u_j(t - \tau_{ij}(t), x)) + \bigvee_{j=1}^n H_{ij}(t)\mu_j(t) \\
& + I_i(t) + \bigwedge_{j=1}^n \gamma_{ij}(t) \int_{-\infty}^t K_{ij}(t - s)f_j(u_j(s, x))ds \\
& + \bigvee_{j=1}^n \theta_{ij}(t) \int_{-\infty}^t K_{ij}(t - s)f_j(u_j(s, x))ds + \bigvee_{j=1}^n \beta_{ij}(t)g_j(u_j(t - \tau_{ij}(t), x)) \\
& \left. + \bigwedge_{j=1}^n T_{ij}(t)\mu_j(x_j(t))\right]dt + \sum_{j=1}^n \sigma_{ij}(u_i(t, x))dw_j(t), \quad t_0 \leq t \neq t_k, \quad x \in \Omega
\end{aligned}$$

$$u_i(s + t_0, x) = \varphi_i(s, x), \quad -\infty < s \leq 0, \quad x \in \Omega,$$

$$u_i(t, x) = 0, \quad x \in \partial\Omega,$$

$$\begin{aligned}
u_i(t_k, x) = & I_{ik}(u_1((t_k - \tau_{i1}(t_k))^-), x), \dots, u_n((t_k - \tau_{in}(t_k))^-), x)) \\
& + h_{ik}(u_1(t_k^-, x), \dots, (u_n(t_k^-, x)) + J_{ik}, \quad x \in \Omega
\end{aligned}$$

burada $i, j = 1, 2, \dots, n$, $k = 1, 2, \dots$ ve n ağdaki nöronların sayısıdır; $u_i(t, x)$ x uzayında t zamandaki i inci nöronla ilişkili durum değişkenini gösterir; $D_{ir} = D_{ir}(u, t, x) \geq 0$ i inci nöron boyunca iletim yayılım operatörüne karşılık gelir. $\alpha_{ij}(t)$ ve $\gamma_{ij}(t)$ bulanık geri besleme MIN şablonun elemanlarıdır; $\beta_{ij}(t)$ ve $\theta_{ij}(t)$ bulanık geri besleme MAX şablonun elemanlarıdır; $T_{ij}(t)$ ve $H_{ij}(t)$ sırasıyla bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonun elemanlarıdır. $a_{ij}(t)$ ve $b_{ij}(t)$ sırasıyla geri besleme ve ileri besleme şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir; $\mu_i(t)$ ve $I_i(t)$

sırasıyla i inci nöronun girdi ve sapmalarını gösterir; $\hat{f}_j, f_j$ ve g_j aktivasyon fonksiyonlarıdır; $\tau_{ij}(t)$ iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij}(t) \leq \tau$ i sağlar; $k_{ij}(t) \geq 0$ $(-\infty, 0)$ aralığında tanımlı geri besleme kernelidir. Gecikme kernelleri $K_{ij} : (0, \infty) \rightarrow R$ gerçekte değerli, sürekli parçalı, ve integrallenebilir ve negatif olmayan k_{ij} sabitleri mevcuttur şöyle ki

$$0 < \int_0^\infty |K_{ij}(s)|ds = 1, \int_0^\infty e^{s\lambda_0} K_{ij}(s)ds < \infty,$$

burada λ_0 pozitif bir sabittir; $h_{ik}(u_1(t_k^-, x), \dots, (u_n(t_k^-, x)))$ t_k zamanda i inci birimin dürtüsel düzensizliklerini temsil eder ve $I_{ik}(u_1((t_k - \tau_{i1}(t_k))^-), \dots, u_n((t_k - \tau_{in}(t_k))^-), x))$ t_k zamanda i inci birimin iletim gecikmelerinden kaynaklı dürtüsel düzensizliklerini temsil eder; J_{ik} sürekli dürtü girdisidir; $w(t) = (w_1(t), w_2(t), \dots, w_n(t))^T$, (Ω, F, P) tam olasılık uzayında $\{w(t) : 0 \leq s \leq t\}$ tarafından oluşturulmuş bir doğal filtrasyonla $\{F_t\}_{t \geq 0}$ (yani $F_t = \sigma\{w(s) : 0 \leq s \leq t\}$) tanımlı n boyutlu Brownian hareketidir ve her zamanki koşulları sağlar (yani sağdan sürekli-dir ve F_0 tüm P -boş kümelerini içerir), burada $\{w(t)\}$ $x(t)$ tarafından oluşturulmuş standart alan ile ilişkilidir ve F olasılık ölçüsü P ile $\{w(t)\}$ tarafından oluşturulmuş ilişkilendirilmiş σ cebirini gösterir. $\sigma : R^n \rightarrow R^{n \times n}$ difüzyon katsayı matrisidir. t_k dürtü momentleri olarak adlandırılır ve $0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$. $u_i(t_k^+, x)$ ve $u_i(t_k^-, x)$ sırasıyla t_k da sağdan ve soldan limitleri gösterir. Biz her zaman tüm $k \in N$ ler için $u_i(t_k^+, x) = u_i(t_k, x)$ varsayıyoruz. Başlangıç değer fonksiyonları $\psi(s, x) \in PC^b_{F_0}((-\infty, 0] \times \Omega; R^n)$ a aittir ki bu tüm sınırlı F_0 ölçülebilir $\|\psi\|_{L^2}^2 = \sup_{-\infty < s \leq 0} E\|\psi\|_2^2 < \infty$ i sağlayan PC değerli rastgele değişkenlerin $((-\infty, 0) \times \Omega, R^n)$ ailesidir. Burada E stokastik süreç beklentilerini ifade eder.

Model Tanımı 31.

[62] referans numaralı çalışma ile literatüre sunulan **sızma gecikmeli Takagi-Sugeno bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

Plant rule l : Eğer $\theta_1(t), \eta_1^l, \dots$, ve $\theta_q(t), \eta_q^l$ ise;

$$\dot{x}(t) = -C_l x(t - \sigma) + A_l f(x(t)) + B_l f(x(t - \tau(t))) + D_l \int_{t-\rho(t)}^t f(x(s))ds + J_l$$

burada $\eta_k^l (k = 1, \dots, q)$ bulanık kümedir, $\theta(t) = [\theta_1(t), \theta_2(t), \dots, \theta_q(t)]^T$ öncül değişken vektörü ve m IF-THEN kurallarının sayısıdır.

$x(\cdot) = [x_1(\cdot), x_2(\cdot), \dots, x_n(\cdot)]^T \in R^n$ nöron durum vektörüdür. $C = \text{diag}\{c_1, \dots, c_n\}$ $c_i > 0$ olmak üzere köşegen matristir. $i = 1, \dots, n$ A, B ve D uygun boyulu sabit matrislerdir. $f(x(\cdot)) = [f_1(x_1(\cdot)), \dots, f_n(x_n(\cdot))]^T \in R^n$ nöron aktivasyon fonksiyonunu gösterir. $J = [J_1, \dots, J_n]^T \in R^n$ sabit bir girdi vektörüdür. İletim gecikmesi $\tau(t)$ zamana bağlı gecikmedir ve $0 \leq \tau(t) \leq \bar{\tau}$ sağlar burada $\bar{\tau}$ bir pozitif sabittir. $\rho(t)$ dağıtık zamana bağlı bir gecikmedir, $0 \leq \rho(t) \leq \bar{\rho}$ sağlar ve $\bar{\rho}$ bir pozitif sabittir. Sızma gecikmesi $\sigma \geq 0$ bir sabittir. **Model Tanımı 32.**

[95] referans numaralı çalışma ile literatüre sunulan **zamana bağlı gecikmeli Takagi-Sugeno bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \dot{x}(t) &= \sum_{k=1}^m w_k(\theta(t)) \cdot \{-C_k x(t) + A_k f(x(t)) + B_k f(x(t - \tau(t))) + J_k\} / \sum_{k=1}^m w_k(\theta(t)) \\ &= \sum_{k=1}^m \eta_k(x(t)) \cdot \{-C_k x(t) + A_k f(x(t)) + B_k f(x(t - \tau(t))) + J_k\} \quad (4a) \end{aligned}$$

$$x(t) = \sum_{k=1}^m \eta_k(\theta(t)) \cdot \psi_k(t), \quad t \in [-\tau_M, 0] \quad (4b)$$

burada $C_k = \text{diag}\{c_{k1}, c_{k2}, \dots, c_{kn}\}$ matrisi bir pozitif köşegen matrisidir. $A_k, B_k \in \mathbb{R}^{n \times n}$ uygun boyulu bilinen sabit matrislerdir. Her bulanık kuralın ağırlık ve ortalama ağırlığı sırasıyla $w_k(\theta(t)) \prod_{l=1}^r M_{kl}(\theta_l(t))$ ve $\eta_k(\theta(t)) = w_k(\theta(t)) / \sum_{k=1}^m w_k(\theta(t))$ ile gösterilmektedir. $M_{kl}(\theta_l(t))$ terimi M_{kl} de $\theta_l(t)$ nin üyelik derecesidir. $w_k(\theta(t)) \geq 0, k \in \{1, 2, \dots, m\}$ ve $\sum_{k=1}^m w_k(\theta(t)) > 0$ olduğunu varsayıyoruz. Öte yandan tüm $t \geq 0$ ler için $\eta_k(\theta(t)) \geq 0, k \in \{1, 2, \dots, m\}$ ve $\sum_{k=1}^m \eta_k(\theta(t)) = 1$ dir.

Model Tanımı 33.

[72] referans numaralı çalışma ile literatüre sunulan **çoklu zaman değişken gecikmeli Takagi-Sugeno bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

Plant rule l :

Eğer $\{\theta_1(t), \eta_1^l\}$, ve...ve $\{\theta_\gamma(t), \eta_\gamma^l\}$, ise

$$\dot{x}(t) = -D_l x(t) + A_l f(x(t)) + \sum_{k=1}^r W_{l_k} f(x(t - \tau_k(t))),$$

burada $\eta_i^l (i = 1, 2, \dots, \gamma, l = 1, 2, \dots, s)$ bulanık kümeler, $(\theta_1(t), \theta_2(t), \dots, \theta_\gamma(t))^T$ öncül değişken vektörüdür, $x(t)$ durum değişkenidir ve s IF-THEN kurallarının sayısıdır. $\lambda_l(\zeta(t))$, $\beta_l(\zeta(t))$ türetilmiş bulanık kümesinin normalize edilmiş üyelik fonksiyonu olsun.

$$\dot{x}(t) = \sum_{l=1}^s \lambda_l(\zeta(t)) - D_l x(t) + A_l f(x(t)) + \sum_{k=1}^r W_{l_k} f(x(t - \tau_k(t))), (2)$$

burada

$$\lambda_l(\zeta(t)) = \frac{\beta_l(\zeta(t))}{\sum_{l=1}^s \beta_l(\zeta(t))}, \beta_l(\zeta(t)) = \prod_{n=1}^{\gamma} \eta_n^l(z_l(t)),$$

ve η_n^l , η_n^l de $z_n(t)$ nin üyelik fonksiyonunun derecesidir. Herhangi $\zeta(t)$ için

$$\beta_l(\zeta(t)) \geq 0, \quad l = 1, 2, \dots, s, \quad \sum_{l=1}^s \beta_l(\zeta(t)) > 0,$$

varsayalım. Bunun sonucu olarak $\lambda_l(\zeta(t))$, herhangi $\zeta(t)$ için

$$\lambda_l(\zeta(t)) \geq 0, \quad l = 1, 2, \dots, s, \quad \sum_{l=1}^s \lambda_l(\zeta(t)) = 1$$

i sağlar.

Model Tanımı 34.

[73] referans numaralı çalışma ile literatüre sunulan **belirsiz stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

Plan rule k :

Eğer $\theta_1(t), \eta_1^k, \dots$, ve $\theta_p(t), \eta_p^k$ ise;

$$\begin{aligned}
dx(t) = & [-(C_k + \Delta C_k(t))x(t) + (A_k + \Delta A_k(t))f(x(t)) \\
& + (B_k + \Delta B_k(t))f(x(t - \tau(t)))]dt \\
& + [(M_k + \Delta M_k(t))x(t) + (N_k + \Delta N_k(t))x(t - \tau(t))]dw(t),
\end{aligned}$$

$$x(t) = \phi(t), \quad t \in [-\tau, 0], \quad k = 1, 2, \dots, r,$$

burada $\eta_i^k (i = 1, 2, \dots, p)$ bulanık kümedir, $\theta(t) = [\theta_1(t), \theta_2(t), \dots, \theta_p(t)]^T$ öncül değişken vektörüdür. r , IF-THEN kurallarının sayısıdır. $w(t) = [w_1(t), \dots, w_m(t)]^T \in R^m$, $(\Omega, F, \{F_t\}_{t \geq 0}, P)$ 'de tanımlı m boyutlu Brownian hareketidir. $\phi \in L^2_{F_0}$ (3) ün başlangıç değeridir. $\Delta C_k(t)$, $\Delta A_k(t)$, $\Delta B_k(t)$, $\Delta M_k(t)$ ve $\Delta N_k(t)$ zamanla değişen parametre belirsizliklerini ifade eder.

Model Tanımı 35.

[53] referans numaralı çalışma ile literatüre sunulan **çoklu ayırık ve dağıtık zamanla değişen gecikmeli stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

Plant rule l :

Eğer $\{\theta_1(t), \eta_1^l\}$, ve...ve $\{\theta_\gamma(t), \eta_\gamma^l\}$, ise

$$\begin{aligned}
dx(t) = & [-D_l x(t) + A_l f(x(t)) + \sum_{k=1}^r W_{l_k} f(x(t - \tau_k(t))) \\
& + \sum_{k=1}^r C_{l_k} \int_{t-\rho_k(t)}^t f(x(s))ds]dt \\
& + \sigma_1(t, x(t), x(t - \tau_1(t)), x(t - \tau_2(t)), \dots, x(t - \tau_r(t)))dw(t),
\end{aligned}$$

burada $\eta_i^l (i = 1, 2, \dots, \gamma, j = 1, 2, \dots, s)$ bulanık kümeler, $(\theta_1(t), \theta_2(t), \dots, \theta_\gamma(t))^T$ öncül değişken vektörüdür, $x(t)$ durum değişkenidir ve s IF-THEN kurallarının sayısıdır.

$\lambda_l(\zeta(t))$, $\beta_l(\zeta(t))$ türetilmiş bulanık kümesinin normalize edilmiş üyelik fonksiyonu olsun. Türetilmiş

sistem aşağıdaki gibidir:

$$\begin{aligned} d(t) = & \sum_{l=1}^s \lambda_l(\zeta(t)) [-D_l x(t) + A_l f(x(t)) + \sum_{k=1}^r W_{l_k} f(x(t - \tau_k(t))) \\ & + \sum_{k=1}^r C_{l_k} \int_{t-\rho_k(t)}^t f(x(s)) ds] dt \\ & + \sigma_l(t, x(t), x(t - \tau_1(t)), x(t - \tau_2(t)), \dots, x(t - \tau_r(t))) dw(t), \end{aligned}$$

burada

$$\lambda_l(\zeta(t)) = \frac{\beta_l(\zeta(t))}{\sum_{l=1}^s \beta_l(\zeta(t))}, \beta_l(\zeta(t)) = \prod_{n=1}^{\gamma} \eta_n^l(z_l(t)),$$

ve η_n^l , η_n^l de $z_n(t)$ nin üyelik fonksiyonunun derecesidir. Herhangi $\zeta(t)$ için

$$\beta_l(\zeta(t)) \geq 0, \quad l = 1, 2, \dots, s, \quad \sum_{l=1}^s \beta_l(\zeta(t)) > 0,$$

varsayalım.

Bunun sonucu olarak $\lambda_l(\zeta(t))$, herhangi $\zeta(t)$ için

$$\lambda_l(\zeta(t)) \geq 0, \quad l = 1, 2, \dots, s, \quad \sum_{l=1}^s \lambda_l(\zeta(t)) = 1$$

eşitliği sağlanır.

Model Tanımı 36.

[67] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli ve reaksiyon difüzyon terimli dürtüsel stokastik bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel

denklemler ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
du_i(t, x) = & \left[\sum_{r=1}^m \frac{\partial}{\partial x_r} (D_{ir} \frac{\partial u_i(t, x)}{\partial x_r}) - a_i u_i(t, x) + \sum_{j=1}^n a_{ij} f_j(u_j(t, x)) \right. \\
& + \bigwedge_{j=1}^n \alpha_{ij} g_j(u_j(t - \tau_{ij}(t), x)) + \bigvee_{j=1}^n \beta_{ij} g_j(u_j(t - \tau_{ij}(t), x)) + I_i \bigg] dt \\
& + \sum_{j=1}^n \sigma_{ij}(u_j(t, x), u_j(t - \tau_{ij}(t), x)) dw_j(t), \\
& t \geq 0, \quad t \neq t_k, \quad x \in G
\end{aligned}$$

$$u_i(t_k^+, x) = u_i(t_k^-, x) + J_{ik}(u_i(t_k^-, x)), \quad k \in N \triangleq \{1, 2, \dots\},$$

$$u_i(s, x) = \phi_i(s, x) \quad -\tau < s \leq 0, \quad x \in G, \quad u_i(t, x) = 0, \quad t \geq 0, \quad x \in \partial G$$

$i \in g \triangleq \{1, 2, \dots, n\}$ için, burada $x = (x_1, x_2, \dots, x_m)^T \in G \subset R^m, |x_r| < l_r, r = 1, 2, \dots, m$ ve $mesG > 0$; $u = (u_1, u_2, \dots, u_n)^T \in R^n$; $u_i(t, x)$ x uzayında t zamanda i inci nöronun durumudur; $D_{ir} \geq 0$ i inci nöron boyunca iletim difüzyon katsayısına karşılık gelir. f_i ve g_i x uzayında t zamanda sinyal fonksiyonlarını gösterir; $I_i = \sum_{j=1}^n b_{ij} v_j + \tilde{I}_i + \bigwedge_{j=1}^n T_{ij} v_j + \bigvee_{j=1}^n H_{ij} v_j$ ve $v_j, \tilde{I}_i$ sırasıyla i inci nöronun girdi ve sapmalarını gösterir. $a_i > 0, a_{ij}, \alpha_{ij}, \beta_{ij}$ sabitlerdir. a_i i inci birimin harici girdiler ve ağlardan bağlantısı koptuğunda izole dinlenme durumunu sıfırlama oranını gösterir. a_{ij} ve b_{ij} sırasıyla geri besleme şablonu ve ileri besleme şablonunun elemanlarıdır; α_{ij}, β_{ij} sırasıyla bulanık geri besleme MIN şablonunun gecikmelerinin ve bulanık geri besleme MAX şablonunun bağlantı ağırlıklarını gösterir. T_{ij} ve H_{ij} sırasıyla bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir; $\tau_{ij}(t) (0 \leq \tau_{ij}(t) \leq \tau_{ij} \tau \leq \tau, \tau_{ij}$ sabitler, $\tau = \max_{1 \leq i, j \leq n} \{\tau_{ij}\})$ t zamandaki iletim gecikmelerine karşılık gelir; $\sigma_i(u, v) = (\sigma_{i1}(u, v), \sigma_{i2}(u, v), \dots, \sigma_{iN}(u, v))^T$, burada $\sigma_i(u, v)$ rastgele düzensizliklerin ağırlık fonksiyonunu gösterir; $w(t) = (w_1(t), w_2(t), \dots, w_n(t))^T$, herzamanki koşulları sağlayan bir $\{F_t\}_{t \geq 0}$ filtrasyonlu $(\Omega, F, \{F_t\}_{t \geq 0}, P)$ tam olasılık uzayında tanımlı n boyutlu Brownian hareketidir. t_k dürtü momenti olarak adlandırılır ve $0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$ 'u sağlar; $u_i(t_k^-, x)$ ve $u_i(t_k^+, x)$ sırasıyla t_k daki sağdan ve soldan limitlerini gösterir. J_{ik}, t_k zamanda i inci nöro-

nun dürtü düzensizliklerini gösterir. Daima $u_i(t_k^+, x) = u_i(t_k, x)$, $k \in N$ olduğu varsayılır.

Model Tanımı 37.

[45] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli ve dürtülü stokastik otonom olmayan Takagi-Sugeno bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$dx(t) = F(t, x(t), x(t - \tau(t)))dt + \sigma(t, x(t), x(t - \tau(t)))dw(t)$$

Model Tanımı 38.

[65] referans numaralı çalışma ile literatüre sunulan **zamanla değişen gecikmeli BAM bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned} \frac{dx_i(t)}{dt} = & -a_i x_i(t) + \sum_{j=1}^m a_{ij} g_j(y_j(t)) + \sum_{j=1}^m \tilde{a}_{ij} w_j + \bigwedge_{j=1}^m \alpha_{ij} g_j(y_j(t - \tau_{ij}(t))) \\ & + \bigvee_{j=1}^m \tilde{\alpha}_{ij} g_j(y_j(t - \tau_{ij}(t))) + \bigwedge_{j=1}^m T_{ij} w_j + \bigvee_{j=1}^m H_{ij} w_j + I_i, \quad t \geq 0, \quad t \neq t_k, \end{aligned}$$

$$x_i(t^+) = x_i(t^-) + P_{ik}(x_i(t^-)), \quad t = t_k, \quad k \in N \triangleq \{1, 2, \dots\},$$

$$\begin{aligned} \frac{dy_j(t)}{dt} = & -b_j y_j(t) + \sum_{i=1}^n b_{ji} f_i(x_i(t)) + \sum_{i=1}^n \tilde{b}_{ji} \tilde{w}_i + \bigwedge_{i=1}^n \beta_{ji} f_i(x_i(t - \sigma_{ji}(t))) \\ & + \bigvee_{i=1}^n \tilde{\beta}_{ji} f_i(x_i(t - \sigma_{ji}(t))) + \bigwedge_{i=1}^n \tilde{T}_{ji} \tilde{w}_i + \bigvee_{i=1}^n \tilde{H}_{ji} \tilde{w}_i + J_j, \quad t \geq 0, \quad t \neq t_k, \end{aligned}$$

$$y_j(t^+) = y_j(t^-) + Q_{jk}(y_j(t^-)), \quad t = t_k, \quad k \in N \triangleq \{1, 2, \dots\}$$

burada $x_i(t)$ ve $y_j(t)$ sırasıyla t zamanda i inci nöronun ve j inci nöronun durumlarıdır; f_i ve g_j sırasıyla t zamanda i inci nöron ve j inci nöronun sinyal fonksiyonlarıdır; $\tilde{w}_i$ ve w_j sırasıyla t zamanda i inci nöronun ve j inci nöronun girdilerini gösterir; ve I_i ve J_j sırasıyla t zamanda i inci nöronun ve j inci nöronun sapmalarını gösterir; $a_i > 0, b_j > 0, a_{ij}, \tilde{a}_{ij}, \alpha_{ij}, \tilde{\alpha}_{ij}, b_{ji}, \tilde{b}_{ji}, \beta_{ji}, \tilde{\beta}_{ji}$ sabitlerdir; a_i ve b_j harici girdiler ve ağlarından bağlantısı koptuğunda sırasıyla i inci ve j inci nöronun izolasyon dinlenme durumuna sıfırlama potansiyellerinin oranını gösterir. a_{ij}, b_{ji} ve $\tilde{a}_{ij}, \tilde{b}_{ji}$ sırasıyla geri besleme şablonu ve ileri besleme şablonunun bağlantı ağırlıklarını gösterir; α_{ij}, β_{ji} ve $\tilde{\alpha}_{ij}, \tilde{\beta}_{ji}$ sırasıyla bulanık geri besleme MIN şablonu gecikmeleri ve bulanık geri besleme MAX şablonu gecikmeleri bağlantı ağırlıklarını gösterir; T_{ij}, H_{ji} ve $\tilde{T}_{ij}, \tilde{H}_{ji}$ sırasıyla bulanık ileri besleme MIN şablonu gecikmeleri ve bulanık ileri besleme MAX şablonu gecikmeleri bağlantı ağırlıklarını gösterir; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir; $\tau_{ij}(t)(0 \leq \tau_{ij}(t) \leq \tau_{ij})$ ve $\sigma_{ji}(t)(0 \leq \sigma_{ji}(t) \leq \sigma_{ji})$ sırasıyla t zamandaki iletim gecikmelerine karşılık gelir; t_k dürtü momenti olarak adlandırılır ve $0 < t_1 < t_2 < \dots, \lim_{k \rightarrow +\infty} t_k = +\infty$ i sağlar; $x_i(t_k^-)$ ve $x_i(t_k^+)$ sırasıyla t_k daki soldan ve sağdan limitleri gösterir. P_{ik} ve Q_{jk} sırasıyla t_k zamanda i inci nöronun ve j inci nöronun dürtüsel düzensizliklerini gösterir. Daima $x_i(t_k^+) = x_i(t_k)$ ve $y_j(t_k^+) = y_j(t_k)$, $k \in N$ olduğunu varsayıyoruz.

Model Tanımı 39.

[61] referans numaralı çalışma ile literatüre sunulan **sızma teriminde zaman gecikmeli,ayrık ve sınırsız dağıtık gecikmeli BAM bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
 \dot{x}_i(t) = & -d_i x_i(t - \sigma_1) + \sum_{j=1}^m a_{ij} \tilde{f}_j(y_j(t)) + \sum_{j=1}^m b_{ij} \tilde{f}_j y_j(t - \tau(t)) + \sum_{j=1}^m c_{ij} w_j \\
 & + \bigwedge_{j=1}^m \alpha_{ij} \int_{-\infty}^t k_j(t-s) \tilde{f}_j(y_j(s)) ds + \bigvee_{j=1}^m \beta_{ij} \int_{-\infty}^t k_j(t-s) \tilde{f}_j(y_j(s)) ds \\
 & + \bigwedge_{j=1}^m T_{ij} w_j + \bigvee_{j=1}^m H_{ij} w_j + J_i, \quad t \geq 0, \quad i \in \ell,
 \end{aligned}$$

$$\begin{aligned}
\dot{y}_i(t) = & -\tilde{d}_j y_j(t - \sigma_2) + \sum_{i=1}^n \tilde{a}_{ji} \tilde{g}_i(x_i(t)) + \sum_{i=1}^n \tilde{b}_{ji} \tilde{g}_i x_i(t - \rho(t)) + \sum_{i=1}^n \tilde{c}_{ji} \tilde{w}_i \\
& + \bigwedge_{i=1}^n \tilde{\alpha}_{ji} \int_{-\infty}^t k_i(t-s) \tilde{g}_i(x_i(s)) ds + \bigvee_{i=1}^n \tilde{\beta}_{ji} \int_{-\infty}^t k_i(t-s) \tilde{g}_i(x_i(s)) ds \\
& + \bigwedge_{i=1}^n \tilde{T}_{ji} \tilde{w}_i + \bigvee_{i=1}^n \tilde{H}_{ji} \tilde{w}_i + \tilde{J}_j, \quad t \geq 0, \quad j \in J
\end{aligned}$$

burada $x_i(t)$ ve $y_j(t)$ sırasıyla i inci ve j inci nöronun t zamandaki durumlarıdır. $\tilde{g}_i$ ve $\tilde{f}_j$ sırasıyla i inci ve j inci nöronun t zamanda sinyal fonksiyonlarını gösterir; $\tilde{w}_i$ ve w_j sırasıyla i inci ve j inci nöronun girdilerini gösterir; J_i ve J_j sırasıyla i inci ve j inci nöronun t zamanda sapmalarını gösterir; d_i ve $\tilde{d}_j$ diyagonal matrisler, d_i ve $\tilde{d}_j$ harici girdiler ve ağlarından bağlantısı koptuğunda sırasıyla i inci ve j inci nöronun izolasyon dinlenme durumuna sıfırlama potansiyellerinin oranını gösterir. a_{ij} , b_{ij} , $\tilde{a}_{ji}$, $\tilde{b}_{ji}$ geri besleme şablonunun bağlantı ağırlıklarını gösterir ve c_{ij} , $\tilde{c}_{ji}$ ileri beslemeli şablonun bağlantı ağırlıklarını gösterir; α_{ij} , $\tilde{\alpha}_{ji}$ ve β_{ij} , $\tilde{\beta}_{ji}$ sırasıyla bulanık geri beslemeli MIN şablon gecikmeleri ve bulanık geri beslemeli MAX şablon gecikmelerinin bağlantı ağırlıklarını gösterir; T_{ij} , $\tilde{T}_{ji}$ ve H_{ij} , $\tilde{H}_{ji}$ sırasıyla bulanık ileri beslemeli MIN şablonu ve bulanık ileri beslemeli MAX şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir; $0 \leq \tau(t) \leq \tau$ ve $0 \leq \rho(t) \leq \rho$ sırasıyla t zamanda iletim gecikmelerine karşılık gelir; $\tilde{g}_i(\cdot)$ ve $\tilde{f}_j(\cdot)$ aktivasyon fonksiyonlarıdır; $k_i(s) \geq 0$ ve $k_j(s) \geq 0$ geri besleme kernelleridir ve aşağıdaki koşulları sağlar;

$$\int_0^\infty k_i(s) ds = 1, \quad i = 1, 2, \dots, n, \quad \int_0^\infty k_j(s) ds = 1, \quad j = 1, 2, \dots, m,$$

Model Tanımı 40.

[68] referans numaralı çalışma ile literatüre sunulan **Dirichlet sınır koşullu ve reaksiyon difüzyon terimli otonom olmayan bulanık hücresel sinir ağı modeli** aşağıdaki diferansiyel denklem ile aşağıdaki gibi tanımlanmıştır.

$$\begin{aligned}
\frac{\partial u_i(t, x)}{\partial t} = & \sum_{k=1}^m \frac{\partial}{\partial x_k} (D_{ik} \frac{\partial u_i(t, x)}{\partial x_k}) - d_i(t) u_i(t, x) + \sum_{j=1}^n a_{ij}(t) f_j(u_j(t, x)) \\
& + \sum_{j=1}^n b_{ij}(t) u_j + I_i(t) + \bigwedge_{j=1}^n \alpha_{ij}(t) f_j(u_j(t - \tau_{ij}, x)) \\
& + \bigvee_{j=1}^n \beta_{ij}(t) f_j(u_j(t - \tau_{ij}, x)) + \bigwedge_{j=1}^n T_{ij}(t) u_j + \bigvee_{j=1}^n H_{ij}(t) u_j, \\
& (t, x) \in [0, +\infty) \times \Omega, \quad (1)
\end{aligned}$$

$$u_i(t, x) = 0, \quad (t, x) \in [-\tau, +\infty) \times \partial\Omega,$$

$$u_i(s, x) = \phi_i(s, x), \quad (s, x) \in [-\tau, 0] \times \Omega, \quad i = 1, 2, \dots, n,$$

burada n sinir ağlarındaki nöronların sayısıdır; $x = (x_1, x_2, \dots, x_m)^T \in \Omega \subset R^m$ ve $\Omega = \{x = (x_1, x_2, \dots, x_m)^T : |x_k| \leq \Omega_k, k = 1, 2, \dots, m\}$ $\partial\Omega$ pürüzsüz sınıra sahip sınırlı kompakt bir kümedir ve R^m uzayında $\text{mes}\Omega > 0$ dır. $u_i(t, x)$ x uzayında, t zamanda i inci sinir birimi ile ilişkili durum değişkenini göstermektedir; $d_i > 0$ i inci birimin ağ ve harici girdilerden izole olduğunda dinlenme durumunu sıfırlama oranını gösterir; $a_{ij}(t)$ ve $b_{ij}(t)$ sırasıyla t zamanda bulanık geri besleme ve bulanık ileri besleme şablonunun elemanlarıdır; $\alpha_{ij}, \beta_{ij}, T_{ij}$ ve H_{ij} sırasıyla bulanık geri besleme MIN şablonu, bulanık geri besleme MAX şablonu, bulanık ileri besleme MIN şablonu ve bulanık ileri besleme MAX şablonunun elemanlarıdır; $\bigwedge$ ve $\bigvee$ sırasıyla bulanık AND ve bulanık OR işlemlerini gösterir. μ_j girdiyi gösterir; $I_i(t)$ t zamanda i inci nöronun sapmalarını gösterir; $f_j(\cdot)$ t zamanda x uzayında j inci nöronların aktivasyon fonksiyonudur; $D_{ik} = D_{ik}(t, x) \geq 0$ pürüzsüz fonksiyonu i inci nöronlar boyunca iletim yayılım operatörüne karşılık gelir; τ_{ij} i inci birimden j inci birimin akson boyunca iletim gecikmesine karşılık gelir ve $0 \leq \tau_{ij} \leq \tau$ i sağlar. $\phi_i(s, x)$ ($i = 1, 2, \dots, n$), $[-\tau, 0] \times \Omega$ da sürekli ve sınırlıdır.

4.2. BULANIK HÜCRESEL SİNİR AĞLARININ KARARLILIK ANALİZİ ÇALIŞMALARINDA KULLANILAN YÖNTEMLERİN ANALİZİ

Yukarıda verilen modeller için kullanılmış olan kararlılık analizi yöntemleri aşağıdaki şekilde incelenmiştir:

Model 1 - için kullanmış olan kararlılık yönetimleri şunlardır:

- Lyapunov Kararlılık Teoremi, T. Yang, L. B. Yang, 1996 [106]

Model 2 - için kullanmış olan kararlılık yönetimleri şunlardır:

- Lyapunov Kararlılık Teoremi, T. Huang, 2007 [94], J. Wang, J. G. Lu - Chaos, 2008 [91]

Model 3 - için kullanmış olan kararlılık yönetimleri şunlardır:

- Lyapunov Kararlılık Teoremi, W. Han, Y. Liu, L. Wang, 2012 [50], Y. Kao, L. Shi, L. Xie, H. R. Karimi, 2015 [107]

Model 4 - için kullanmış olan kararlılık yönetimleri şunlardır:

- Lyapunov kararlılık teoremi, Z. Liu, H. Zhang, Z. Wang, 2009 [76], C. Zhu, G. Bao, 2011 [54], J. Zhang, D. Ren, W. Zhang, 2006 [109]
- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, K. Yuan, J. Cao, J. Deng, 2006 [97], M. Tan, 2010 [71]
- Lyapunov kararlılık teoremi ve Young Eşitsizliği, Q. Zhang, W. Luo, 2009 [84]
- Lyapunov kararlılık teoremi, topolojik derece teorisi ve M-matris teoremi, Q. Zhang, R. Xiang, 2008 [92]
- Değişken parametreler yöntemi ve eşitsizlik analizi telniği, S. Zhong, Y. Long, X. Liu, 2006 [102]
- Tesadüf derecesinin devamı teoremi ve eşitsizlik tekniği, Q. Zhang, L. Yang, D. Liao, 2011 [55], Q. Zhang, L. Yang, D. Liao, 2012 [51]

Model 5 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, Y. Liu, W. Tang, 2004 [104], W. Ding, M. Han, 2008 [90]
- Lyapunov kararlılık teoremi ve Young Eşitsizliği, Q. Zhang, W. Luo, 2009 [84]

Model 6 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve Young eşitsizliği, S. Niu, H. Jiang, Z. Teng, 2008 [86]

Model 7 - kararlılık için kullanmış olan yöntemler şunlardır:

- Dürtü başlangıç koşullu gecikme diferansiyel eşitsizliği ve M- matris teorimi, J. Liang, K. Li 2009 [77]

Model 8 - kararlılık için kullanmış olan yöntemler şunlardır:

- Sabit nokta teoremi ve M- matris teorimi R. Wu, L. Chen, 2008 [89]

Model 9 - kararlılık için kullanmış olan yöntemler şunlardır:

- M-matris teoremi, T. Huang, 2006 [101]

Model 10 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, M. Tan, 2010 [65]

Model 11 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, S. Niu, H. Jiang, Z. Teng, 2010 [64]

Model 12 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, P. Balasubramaniam, M. S. Ali, 2010 [70]

Model 13 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, homeomorfizma haritalama prensibi ve lineer matris eşitsizliği, P. Balasubramaniam, M. Kalpana, R. Rakkiyappan, 2011 [52]

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, X. Li, R. Rakkiyappan, P. Balasubramaniam, 2011 [59]

Model 14 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve eşitsizlik tekniği, K Jing, 2014 [43]
- Gecikme diferansiyel eşitsizliği ve M-matris teorisi, G. Yang, Y. Kao, C. Wang, 2012 [108]

Model 15 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, P. Balasubramaniam, M. Kalpana, R. Rakkiyappan, 2011 [57]

Model 16 - kararlılık için kullanmış olan yöntemler şunlardır:

- M-matris teoremi, bulanık mantık operatörünün özellikleri, negatif olmayan matrislerin spektral yarıçapının özuzayı, gecikme diferansiyel eşitsizliği kullanılmıştır, S Long, Q Song, X Wang, D Li, 2012 [49]

Model 17 - kararlılık için kullanmış olan yöntemler şunlardır:

- M-matris teoremi, negatif olmayan matrislerin spektral yarıçapının özuzayı, sabit nokta teoremi, 2005 [103]

Model 18 - kararlılık için kullanmış olan yöntemler şunlardır:

- Kuadratik dış bükey birleştirme yöntemi, karşılıklı dış bükey yaklaşımı , Jensen integral eşitsizliği, lineer dışbükey kombinasyon tekniği ,C. Zheng, Y. Wang, Z. Wang 2014 [44]

Model 19 - kararlılık için kullanılmış olan yöntemler şunlardır:

- Lyapunov Kararlılık Teoremi, T. Huang, M. R. Sol, 2006 [99]

Model 20 - kararlılık için kullanmış olan yöntemler şunlardır:

- M-matris teoremi, Q. Song, J. Cao, 2008 [93]

Model 21 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, topolojik derece teorimi, M-matris teoremi, K. Li, Z. Li, Q. Song, 2007 [96]

Model 22 - kararlılık için kullanmış olan yöntemler şunlardır:

- Dörtüsel başlangıç koşullu bir integro diferansiyel eşitsizliği, M-koni ve negatif olmayan matrislerin spektral yarıçapının özuzayı, X. Wang, D. Xu, 2009 [79]

Model 23 - kararlılık için kullanmış olan yöntemler şunlardır:

- Dörtüsel başlangıç koşullu gecikme diferansiyel eşitsizliği ve M matris teoremi Z. Li, K. Li, 2009 [74]

Model 24 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, L Chen, H Zhao, 2008 [87], H. Zhao, N. Ding, L. Chen - Chaos, 2009 [78]

Model 25 - kararlılık için kullanmış olan yöntemler şunlardır:

- Difüzyon katsayı matrisinin daha rahatlatıcı koşul altında yeni bir L operatör eşitsizliği, ve M- matris teoremi, S.Long, D. Xu, 2011 [63]

Model 26 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve stokastik analiz tekniği, Q. Gan, R. Xu, P. Yang, 2010 [69]

Model 27 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, stokastik analiz ve diferansiyel eşitsizlik tekniği, P. Xiong, L. Huang, 2013 [48]

Model 28 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve Itô's formülü, L. Chen, R. Wu, D. Pan, 2011 [60]

Model 29 - kararlılık için kullanmış olan yöntemler şunlardır:

- M- matris teoremi, Q. Zhang, L. Yang, 2011 [58]

Model 30 - kararlılık için kullanmış olan yöntemler şunlardır:

- M-konisi özellikleri, negatif olmayan matrislerin spektral yarıçap özuzayı, Lyapunov kararlılık teoremi, Itô's formülü, 2013 [47]

Model 31 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, P. Balasubramaniam, V. Vembarasan, R. Rakkiyappan, 2011 [62]

Model 32 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, Y. Hou, T. Liao 2007 [95]

Model 33 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, P. Balasubramaniam, M. Syed Ali, S. Arik, 2010 [72]

Model 34 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, H. Yang, L. Sheng, 2009 [73]

Model 35 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve lineer matris eşitsizliği, M. Syed Ali, P. Balasubramaniam 2011 [53]

Model 36 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ve eşitsizlik tekniği, X. Zhang, K. Li, 2010 [67]

Model 37 - kararlılık için kullanmış olan yöntemler şunlardır:

- M- matrisin özelliği kullanılarak yeni bir L operatör eşitsizliği ve diferansiyel eşitsizlik, S. Long, D. Xu, 2014 [45]

Model 38 - kararlılık için kullanmış olan yöntemler şunlardır:

- Gecikme diferansiyel eşitsizliği ve M-matris teorisi, K. Li, 2010 [65]

Model 39 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi, P. Balasubramaniam, M. Kalpana, R. Rakkiyappan, 2011 [61]

Model 40 - kararlılık için kullanmış olan yöntemler şunlardır:

- Lyapunov kararlılık teoremi ,A Wu, C Fu, 2010 [68]

4.3. BULANIK HÜCRESEL SİNİR AĞLARININ KARARLILIK ANALİZİNDE LYAPUNOV TEOREMİ KULLANILAN ÇALIŞMALARIN ANALİZİ

Literatürde BHSAlar için yapılmış olan kararlılık analizi çalışmalarında Lyapunov Teoremin-den faydalanan çalışmalar ve her bir çalışmada kullanılan Lyapunov Teoremleri aşağıdaki gibidir :

Model 1 için kullanılan Lyapunov Fonksiyonları:

(T Yang, L Yang, 1996)[106]

$$V(x) = \frac{1}{C} \sum_{j=1}^{MN} p_j |x_j - x_j^*| > 0$$

Model 2 için kullanılan Lyapunov Fonksiyonları:

(T. Huang, 2007)[94]

$$\begin{aligned} V(y(t)) = & \sum_{i=1}^n r_i |y_i(t)| e^{\lambda t} + \sum_{i=1}^n \int_{t-\tau}^t \left[\left| \bigwedge_{j=1}^n \alpha_{ij} f_j(y_j(s) + x_j^* - \bigwedge_{j=1}^n \alpha_{ij} f_j x_j^* \right| \right. \\ & \left. + \left| \bigvee_{j=1}^n \beta_{ij} f_j(y_j(s) + x_j^* - \bigvee_{j=1}^n \beta_{ij} f_j x_j^* \right| \right] e^{\lambda(s+\tau)} ds \end{aligned}$$

(J Wang, JG Lu - Chaos,2008)[91]

$$\begin{aligned} V(t) = & \int_{\Omega} \sum_{i=1}^n \lambda_i |\nu_i(t, x)|^2 e^{2\epsilon t} \sum_{j=1}^n (|\alpha_{ij}| + |\beta_{ij}|) F_j^2 \int_{t-\tau_{ij}}^t |u_j(s, x) - u_j^*|^2 \\ & e^{2\epsilon(s+\tau_{ij})} ds dx \end{aligned}$$

Model 3 için kullanılan Lyapunov Fonksiyonları:

(W Han, Y Liu, L Wang, 2012)[50]

$$V(x(t), t, i) = e^{\beta t} x^T(t) P_i x(t) + \int_{t-\tau(t)}^t e^{\beta s} f^T(x(s)) Q f(x(s)) ds,$$

$$\begin{aligned} V(x(t), t, i) &= e^{\beta t} x^T(t) P_i x(t) + 2e^{\beta t} \sum_{k=1}^n \int_0^{x_k(t)} s_{ik} f_k(s) ds \\ &\quad + \int_{t-\tau(t)}^t e^{\beta s} f^T(x(s)) Q f(x(s)) ds \end{aligned}$$

(Y Kao, L Shi, L Xie, H R Karimi, 2015) [107]

$$\begin{aligned} V(x(t), t, i) &= e^{\beta t} x^T(t) P_i x(t) + \int_{t-\tau(t)}^t e^{\beta s} f^T(x(s)) Q f(x(s)) ds \\ &\quad + \int_{-d}^0 \int_{t+\theta}^t e^{\beta s} x^T(s) R x(s) ds d\theta \end{aligned}$$

Model 4 için kullanılan Lyapunov Fonksiyonları:

(K Yuan, J Cao, J Deng , 2006)[97]

$$V(y(t)) = e^{2kt} \sum_{i=1}^n p_i y_i^2(t) + \int_{t-\tau(t)}^t e^{2ks} g^T(y(s)) Q g(y(s)) ds$$

(Q Zhang, R Xiang, 2008)[92]

$$V(t, z) = \sum_{i=1}^n [|z_i(t)| + \sum_{j=1}^n (|a_{ij}| k_j + |\alpha_{ij}| l_j + |\beta_{ij}| l_j) \int_{t-\tau_j(t)}^t |z_j(s)| ds]$$

(M Tan, 2010)[71]

$$V(t, z_t) = \sum_{i=1}^n w_i z_i^2(t) + \sum_{i=1}^n \frac{q_i}{1 - \mu_i} \int_{t-\tau_i(t)}^t \psi_i^2(z_i(s)) ds.$$

(Q Zhang, W Luo, 2009) [84]

$$\begin{aligned}
V(t) &= \sum_{i=1}^n l_i [|x_i(t, \phi) - x_i(t, \varphi)|^r e^{\lambda t} + \sum_{j=1}^n |a_{ij}| \int_{t-\tau_j(t)}^t |f_j(x_j(s, \phi)) - f_j(x_j(s, \varphi))|^r \\
&\quad \times e^{\lambda(s+\tau_j(s))} ds + \sum_{j=1}^n |a_{ij}| + |b_{ij}|) \\
&\quad \times \int_{t-\tau_j(t)}^t |g_j(x_j(s, \phi)) - g_j(x_j(s, \varphi))|^r e^{\lambda(s+\tau_j(s))} ds]
\end{aligned}$$

(C Zhu, G Bao, 2011) [54]

$$V(t) = \max_{1 \leq i \leq n} \{|x_i(t)|\}$$

(Z Liu, H Zhang, Z Wang, 2009) [76]

$$V(x(t)) = V_1(x(t)) + V_2(x(t)) + V_3(x(t)) + V_4(x(t))$$

$$V_1(x(t)) = e^{2kt} \sum_{i=1}^n p_i x_i^2(t)$$

$$V_2(x(t)) = \int_{t-\tau(t)}^t e^{2ks} x^T(s) Q_1 x(s) ds + \int_{t-h(t)}^t e^{2ks} g^T(x(s)) Q_2 g(x(s)) ds$$

$$V_3(x(t)) = \tau \int_{-\tau}^0 \int_{t+\theta}^t e^{2ks} \dot{x}^T(s) Z_1 \dot{x}(s) ds d\theta$$

$$V_4(x(t)) = h \int_{-h}^0 \int_{t+\theta}^t e^{2ks} \dot{x}^T(s) Z_2 \dot{x}(s) ds d\theta$$

(J Zhang, D Ren, W Zhang, 2006) [109]

$$V(y(t)) = \sum_{i=1}^n r_i |y_i(t)| e^{lt} + \sum_{j=1}^n \int_{t-\tau_{ij}(t)}^t (|\alpha_{ij}| + |\beta_{ij}|) k_j |y_j(s)| e^{ls} ds$$

Model 5 için kullanılan Lyapunov Fonksiyonları:

(Y Liu, W Tang, 2004)[104]

$$\begin{aligned}
V(y(t)) = & \sum_{i=1}^n r_i |y_i(t)| e^{\lambda t} + \sum_{i=1}^n \int_{t-\tau}^t \left[\left| \bigwedge_{j=1}^n \alpha_{ij} f_j(y_j(s) + x_j^* - \bigwedge_{j=1}^n \alpha_{ij} f_j x_j^* \right| \right. \\
& \left. + \left| \bigvee_{j=1}^n \beta_{ij} f_j(y_j(s) + x_j^* - \bigvee_{j=1}^n \beta_{ij} f_j x_j^* \right| \right] e^{\lambda(s+\tau)} ds
\end{aligned}$$

(W Ding, M Han, 2008) [90]

$$\begin{aligned}
V(t) = & \frac{1}{2} \sum_{i=1}^n p_i \{ e_i^2(t) \exp(\mu t) + \frac{1}{\gamma_i} (\bar{c}_i - c_i)^2 + \sum_{j=1}^n \frac{1}{\eta_{ij}} (\bar{c}_{ij} - c_{ij})^2 \\
& + \frac{1}{\delta_i} (\varepsilon_i + l_i)^2 + \sum_{j=1}^n \frac{1}{\rho_{ij}} \operatorname{sgn}[(\bar{\alpha}_{ij} - \alpha_{ij}) e_i(t) f_j(y_j(t - \tau_{ij}))] (\bar{\alpha}_{ij} - \alpha_{ij})^2 \\
& + \sum_{j=1}^n \frac{1}{\sigma_{ij}} \operatorname{sgn}[(\bar{\beta}_{ij} - \beta_{ij}) e_i(t) f_j(y_j(t - \tau_{ij}))] (\bar{\beta}_{ij} - \beta_{ij})^2 \\
& + \sum_{j=1}^n (|\alpha_{ij}| + |\beta_{ij}|) k_j^{2(1-r_2)} \int_{t-\tau_{ij}}^t e_j^2(s) \exp(\mu(s + \tau_{ij})) ds \}
\end{aligned}$$

(Q Zhang, W Luo, 2009) [84]

$$\begin{aligned}
V(t) = & \sum_{i=1}^n l_i [|x_i(t) - x_i^*|^r e^{\lambda t} + \sum_{j=1}^n |a_{ij}| \int_{t-\tau_j}^t x |f_j(x_j(s)) - f_j(x_j^*)|^r e^{\lambda(s+\tau_j)} ds \\
& + \sum_{j=1}^n |a_{ij}| + |b_{ij}| \int_{t-\tau_j}^t x |g_j(x_j(s)) - g_j(x_j^*)|^r e^{\lambda(s+\tau_j)} ds]
\end{aligned}$$

Model 6 için kullanılan Lyapunov Fonksiyonları:

(S Niu, H Jiang, Z Teng, 2008)[86]

$$\begin{aligned}
V(t, x_t) = & \frac{1}{r} \sum_{i=1}^n \omega_i [|x_i(t)|^r \\
& + \sum_{j=1}^n \mu_j \int_{t-\tau_j(t)}^t X \frac{|\alpha_{ij}(\varphi_j^{-1}(s))| + |\beta_{ij}(\varphi_j^{-1}(s))|}{1 - \dot{\tau}_j(\varphi_j^{-1}(s))} |x_j(s)|^r ds]
\end{aligned}$$

Model 10 için kullanılan Lyapunov Fonksiyonları:

(M Tan, 2010)[65]

$$V = \sum_{i=1}^3 V_i.$$

$$V_1 = y^T(t)Py(t) = \sum_{i=1}^n p_i y_i^2(t),$$

$$V_2 = \int_{t-h}^t g^T(y(s))Qg(y(s))ds,$$

$$V_3 = \sum_{j=1}^n r_j \int_0^\infty k_j(\theta) \int_{t-\theta}^t g_j^2(y_j(s))dsd\theta$$

Model 11 için kullanılan Lyapunov Fonksiyonları:

(S Niu, H Jiang, Z Teng, 2010) [64]

$$V(t, u_t(., x)) = \frac{1}{2l} \int_{\Omega} \sum_{i=1}^n \omega_i [u_i^{2l}(t, x) \sum_{j=1}^n \int_{-\infty}^t \int_{t-s}^\infty k_{ij}(\theta) (|\alpha_{ij}(\theta + s)| + |\beta_{ij}(\theta + s)|)^{l_{ij}} \lambda_j^{h_{ij}} u_j^{2l}(s, x) d\theta ds] dx$$

Model 12 için kullanılan Lyapunov Fonksiyonları:

(P Balasubramaniam, MS Ali, 2010) [70]

$$V(t) = V_1(t) + V_2(t) + V_3(t) + V_4(t) + V_5(t)$$

$$V_1(t) = \int_{\Omega} \sum_{i=1}^n p_i z_i^2(t) dx,$$

$$V_2(t) = \int_{\Omega} \left[\int_{t-\tau(t)}^t z^T(s) R_1 z(s) ds + \int_{-\bar{\tau}}^0 \int_{t+\theta}^t z^T(s) U \dot{z}(s) ds d\theta \right] dx,$$

$$V_3(t) = \int_{\Omega} \left[\int_{t-h(t)}^t z^T(s) R_2 z(s) ds + \int_{-\bar{h}}^0 \int_{t+\theta}^t z^T(s) W \dot{z}(s) ds d\theta \right] dx,$$

$$V_4(t) = \int_{\Omega} \int_{t-\tau(t)}^t g^T(z(s)) Q_1 g(z(s)) ds dx,$$

$$V_5(t) = \int_{\Omega} \int_{t-h(t)}^t g^T(z(s)) Q_2 g(z(s)) ds dx.$$

Model 13 için kullanılan Lyapunov Fonksiyonları:

(P. Balasubramaniam, M. Kalpana, R. Rakkiyappan, 2011) [52]

$$V(t) = \sum_{i=1}^8 V_i(t)$$

$$\begin{aligned} V_1(t) &= [y(t) - D \int_{t-\sigma}^t y(s) ds]^T P [y(t) - D \int_{t-\sigma}^t y(s) ds] \\ &= \sum_{i=1}^n p_i (y_i(t) - d_i \int_{t-\sigma}^t y_i(s) ds)^2 \end{aligned}$$

$$V_2(t) = \int_{t-\tau}^t y^T(s) Q_1 y(s) ds + \int_{t-\sigma}^t y^T(s) Q_2 y(s) ds,$$

$$V_3(t) = \tau \int_{-\tau}^0 \int_{t+\theta}^t \dot{y}^T(s) Z_1 \dot{y}(s) ds d\theta,$$

$$V_4(t) = \sigma \int_{-\sigma}^0 \int_{t+\theta}^t \dot{y}^T(s) Z_2 \dot{y}(s) ds d\theta,$$

$$V_5(t) = \sum_{i=1}^n r_j \int_0^\infty k_j(\theta) \int_{t-\theta}^t g_j^2(y_j(s)) ds d\theta,$$

$$V_6(t) = \sigma \int_{t-\sigma}^t \int_\theta^t y^T(s) N y(s) ds d\theta,$$

$$V_7(t) = \int_0^t \int_{u-\tau(u)}^u \begin{bmatrix} y(u-\tau(u)) \\ \dot{y}(s) \end{bmatrix}^T \begin{bmatrix} T_{11} & T_{12} \\ * & T_{22} \end{bmatrix} \begin{bmatrix} y(u-\tau(u)) \\ \dot{y}(s) \end{bmatrix} ds du,$$

$$V_8(t) = \int_{-\tau}^0 \int_{t+u}^t \dot{y}^T(s) T_{22} \dot{y}(s) ds du.$$

(X Li, R Rakkiyappan, P Balasubramaniam, 2011 [59])

$$V(t) = V_1(t) + V_2(t) + V_3(t) + V_4(t)$$

$$\begin{aligned} V_1(t) &= [y(t) - D \int_{t-\sigma}^t y(s) ds]^T P [y(t) - D \int_{t-\sigma}^t y(s) ds] \\ &= \sum_{i=1}^n p_i (y_i(t) - d_i \int_{t-\sigma}^t y_i(s) ds), \end{aligned}$$

$$\begin{aligned} V_2(t) &= \int_{t-h_1}^t y^T(s) Q_1 y(s) ds + \int_{t-h_2}^t y^T(s) Q_2 y(s) ds + \int_{t-\tau(t)}^t y^T(s) Q_3 y(s) ds \\ &\quad + \int_{t-t-\sigma}^t y^T(s) Q_4 y(s) ds + \int_{t-\tau(t)}^t y^T(s) Q_5 y(s) ds, \end{aligned}$$

$$\begin{aligned} V_3(t) &= \sigma \int_{-\sigma}^0 \int_{t+\theta}^t y^T(s) Z_1 y(s) ds d\theta + h_2 \int_{-h_2}^0 \int_{t+\theta}^t \dot{y}^T(s) Z_2 \dot{y}(s) ds d\theta \\ &\quad + (h_2 - h_1) \int_{-h_2}^{-h_1} \int_{t+\theta}^t \dot{y}^T(s) Z_3 \dot{y}(s) ds d\theta + \sigma \int_{-\sigma}^0 \int_{t+\theta}^t \dot{y}^T(s) Z_4 \dot{y}(s) ds d\theta, \end{aligned}$$

$$V_4(t) = \sum_{i=1}^n r_j \int_0^\infty k_j(\theta) \int_{t-\theta}^t g_j^2(y_j(s)) ds d\theta.$$

Model 14 için kullanılan Lyapunov Fonksiyonları:

(K Jing, 2014)[43]

$$\begin{aligned}
 V(t) = & \int_{\Omega} \sum_{i=1}^n \lambda_i [|z_i(t, x)|^2 e^{2\varepsilon t} + (1 - \gamma)^{-1} \int_{t-\delta_i(t)}^t d_i e^{2\varepsilon(s+\delta)} |z_i(s, x)|^2 ds \\
 & + (1 - K)^{-1} \frac{1}{T^2} \sum_{j=1}^n \int_{t-\tau_{ij}(t)}^t (|\zeta_{ij} \alpha_{ij}| + |\eta_{ij} \beta_{ij}|) e^{2\varepsilon(s+\tau)} |f_j(u_j(s, x)) \\
 & - f_j(v_j(s, x))|^2 ds] dx
 \end{aligned}$$

Model 15 için kullanılan Lyapunov Fonksiyonları:

(P. Balasubramaniam, M Kalpana, R Rakkiyappan, 2011)[57]

$$V(t) = \sum_1^7 V_i(t),$$

$$\begin{aligned}
 V_1(t) &= [e(t) - A \int_{t-\sigma}^t e(s) ds]^T P [e(t) - A \int_{t-\sigma}^t e(s) ds] \\
 &= \sum_{i=1}^n p_i (e_i(t) - a_i \int_{t-\sigma}^t e(s) ds)^2,
 \end{aligned}$$

$$V_2(t) = \int_{t-\sigma}^t e^T(s) W e(s) ds,$$

$$V_3(t) = \sigma \int_{t-\sigma}^t \int_{\theta}^t e^T(s) N e(s) ds d\theta,$$

$$V_4(t) = \sum_{j=1}^n q_j \sigma \int_0^{\infty} k_j(\theta) \int_{t-\theta}^t \phi_j^2(s) ds d\theta,$$

$$V_5(t) = \int_0^t \int_{\theta-\tau(\theta)}^\theta \begin{bmatrix} e(\theta - \tau(\theta)) \\ \dot{e}(s) \end{bmatrix}^T \begin{bmatrix} T_{11} & T_{12} \\ * & T_{22} \end{bmatrix} \begin{bmatrix} e(\theta - \tau(\theta)) \\ \dot{e}(s) \end{bmatrix} ds d\theta,$$

$$V_6(t) = \int_{-\tau}^0 k_j(\theta) \int_{t+\theta}^t \dot{e}^T(s) T_{22} \dot{e}(s) ds d\theta,$$

$$V_7(t) = \int_{-\tau}^0 k_j(\theta) \int_\theta^0 \int_{t+\lambda}^t \dot{e}^T(s) M \dot{e}(s) ds d\lambda d\theta$$

Model 18 için kullanılan Lyapunov Fonksiyonları:

(C Zheng, Y Wang, Z Wang 2014)[44]

$$V(t, y(t)) = \sum_{i=1}^5 V_i(t, y(t))$$

$$V_1(t, y(t)) = [y(t) - D \int_{t-\sigma}^t y(s) ds]^T P [y(t) - D \int_{t-\sigma}^t y(s) ds]$$

$$\begin{aligned} V_2(t, y(t)) &= \int_{t-\tau_1}^t y(s)^T Q_1 y(s) ds + \int_{t-\tau_2}^t y(s)^T Q_2 y(s) ds \\ &+ \int_{t-\tau(t)}^t y(s)^T Q_3 y(s) ds + \int_{t-\tau(t)}^t g(y(s))^T Q_4 g(y(s)) ds \end{aligned}$$

$$\begin{aligned} V_3(t, y(t)) &= \tau_2 \int_{-\tau_2}^0 \int_{t+\theta}^t (y(s)^T Q_5 y(s) \dot{y}(s)^T Q_6 \dot{y}(s)) ds d\theta \\ &+ (\tau_2 - \tau_1) \int_{-\tau_2}^{-\tau_1} \int_{t+\theta}^t (y(s)^T Q_7 y(s) \dot{y}(s)^T Q_8 \dot{y}(s)) ds d\theta \end{aligned}$$

$$\begin{aligned}
V_4(t, y(t)) &= \int_{t-\tau_2}^t \int_{\theta}^t \int_{\beta}^t \dot{y}(s)^T Q_9 \dot{y}(s) ds d\beta d\theta \\
&+ \int_{t-\tau_2}^{t-\tau_1} \int_{\theta}^t \int_{\beta}^t \dot{y}(s)^T Q_{10} \dot{y}(s) ds d\beta d\theta \\
&+ \sigma \int_{-\sigma}^0 \int_{t+\theta}^t (y(s)^T Q_{11} y(s) + \dot{y}^T Q_{12} \dot{y}(s)) ds d\theta \\
&+ \int_{t-\sigma}^t y(s)^T Q_{13} y(s) ds,
\end{aligned}$$

$$V_5(t, y(t)) = \sum_{j=1}^n r_{1j} \int_0^{\infty} k_j(\theta) \int_{t-\theta}^t g_j^2(y_j(s)) ds d\theta$$

Model 19 için kullanılan Lyapunov Fonksiyonları:

(T Huang, M R Sol, 2006)[99]

$$V(t) = V(x_1, x_2, \dots, x_m)(t) = \sum_{i=1}^n |x_i(t) - x_i^*|,$$

Model 21 için kullanılan Lyapunov Fonksiyonları:

(K Li, Z Li, Q Song, 2007)[96]

$$V(t) = \sum_{i=1}^n l_i [y_i(t) + \sum_{j=1}^n F_j(|b_{ij}| + |\tilde{b}_{ij}|) \int_0^{+\infty} e^{\alpha s} K_{ij}(s) (\int_{t-s}^t y_j(r) dr) ds]$$

Model 24 için kullanılan Lyapunov Fonksiyonları:

(L Chen, H Zhao, 2008)[87]

$$V(y(t), t) = e^{\lambda t} \max_{1 \leq i \leq n} \{p_i |y_i(t)|\}$$

(H Zhao, N Ding, L Chen, 2009)[78]

$$V(y(t), t) = e^{\lambda t} \max_{1 \leq i \leq n} y_i^2(t)$$

Model 26 için kullanılan Lyapunov Fonksiyonları:

(Q Gan, R Xu, P Yang, 2010)[69]

$$V(t, v(t, x)) = \int_{\Omega} (\bar{V}_1(t, v(x, t)) + \bar{V}_2(t, v(x, t)) + \bar{V}_3(t, v(x, t))) dx$$

$$\bar{V}_1(t, v(t, x)) = \sum_{i=1}^n e^{2\varepsilon t} v_i^2(t, x),$$

$$\bar{V}_2(t, v(t, x)) = \sum_{i=1}^n \sum_{j=1}^n \int_{t-\tau_{ij}(t)}^t e^{2\varepsilon s} (f_j(u_j(s, x)) - f_j(u_j^*))^2 ds,$$

$$\begin{aligned} \bar{V}_3(t, v(t, x)) = & (1 - \gamma)^{-1} e^{2\varepsilon \tau} \sum_{i=1}^n \sum_{j=1}^n \int_{t-\tau_{ij}(t)}^t e^{2\varepsilon s} (|\alpha_{ij}| L_j^2 + |\beta_{ij}| L_j^2 + \eta_{ij}) \\ & v_i^2(s, x) ds. \end{aligned}$$

Model 27 için kullanılan Lyapunov Fonksiyonları:

(P Xiong, L Huang, 2013)[48]

$$V(t, y(t)) = \sum_{i=1}^n |y_i(t)|^p$$

Model 31 için kullanılan Lyapunov Fonksiyonları:

(P. Balasubramaniam, V. Vembarasan, R. Rakkiyappan, 2011) [62]

$$\begin{aligned} V(t, u_\tau) &= V_1(t, u_\tau) + V_2(t, u_\tau) + V_3(t, u_\tau) + V_4(t, u_\tau) + V_5(t, u_\tau) + V_6(t, u_\tau) \\ &\quad + V_7(t, u_\tau) \end{aligned}$$

$$V_1(t, u_\tau) = \begin{bmatrix} u(t) \\ \int_t^{t-\sigma} u(s)ds \\ u(t - \tau(t)) \end{bmatrix}^T \begin{bmatrix} P_{11} & P_{12} & P_{13} \\ P_{12}^T & P_{22} & P_{23} \\ P_{31}^T & P_{32}^T & P_{33} \end{bmatrix} \begin{bmatrix} u(t) \\ \int_t^{t-\sigma} u(s)ds \\ u(t - \tau(t)) \end{bmatrix}$$

$$V_2(t, u_\tau) = \int_{t-h}^t \begin{bmatrix} u(s) \\ u(s-h) \\ \cdot \\ \cdot \\ \cdot \\ u(s - (v-1)h) \end{bmatrix}^T \begin{bmatrix} Q_{11} & Q_{12} & \dots & Q_{1v} \\ Q_{12}^T & Q_{22} & \dots & Q_{2v} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ Q_{1v}^T & Q_{1v-1}^T & \dots & Q_{vv} \end{bmatrix} \begin{bmatrix} u(s) \\ u(s-h) \\ \cdot \\ \cdot \\ \cdot \\ u(s - (v-1)h) \end{bmatrix} ds$$

$$V_3(t, u_\tau) = \int_{t-\tau(t)}^t \begin{bmatrix} u(s) \\ g((u(s))) \\ \dot{u}(s) \end{bmatrix}^T \begin{bmatrix} R_{11} & R_{12} & R_{13} \\ R_{12}^T & R_{22} & R_{23} \\ R_{31}^T & R_{32}^T & R_{33} \end{bmatrix} \begin{bmatrix} u(s) \\ g((u(s))) \\ \dot{u}(s) \end{bmatrix} ds$$

$$V_4(t, u_\tau) = 2 \sum_{i=1}^n \left\{ \int_0^{u_i(t)} e_i(g_i(s) - \gamma_i(s))ds + \int_0^{u_i(t)} \lambda_i(\sigma_i(s) - g_i(s))ds \right\}$$

$$V_5(t, u_\tau) = h \sum_{i=1}^v \int_{t-ih}^{t-(i-1)h} \int_{\theta}^t \dot{u}^T(s) S_i \dot{u}(s) ds d\theta$$

$$V_6(t, u_\tau) = \bar{\rho} \int_{t-\bar{\rho}}^t \int_{\theta}^t g^T(u(s)) T g(u(s)) ds d\theta$$

$$V_7(t, u_\tau) = \sigma \int_{t-\sigma}^t \int_{\theta}^t u^T(s) U_1 u(s) ds d\theta + \int_{t-\sigma}^t u^T(s) U_2 u(s) ds$$

Model 32 için kullanılan Lyapunov Fonksiyonları:

(Y Hou, T Liao 2007)[95]

$$V(\hat{z}_t) = V_1(\hat{z}_t) + V_2(\hat{z}_t) + V_3(\hat{z}_t)$$

$$V_1(\hat{z}_t) = \hat{z}^T(t) P_0 \hat{z}(t)$$

$$V_2(\hat{z}_t) = \int_{t-\tau(t)}^t \hat{z}^T(s) \hat{z}^T(s) ds$$

$$V_3(\hat{z}_t) = \tau_M \int_{t-\tau_M}^t (s - (t - \tau_M)) \dot{\hat{z}}^T(s) P_2 \dot{\hat{z}}(s) ds$$

Model 33 için kullanılan Lyapunov Fonksiyonları:

(P. Balasubramaniam, M. Syed Ali, Sabri Arik, 2010) [72]

$$V(t, x(t)) = V_1(t, x(t)) + V_2(t, x(t)) + V_3(t, x(t)) + V_4(t, x(t))$$

$$V_1(t, x(t)) = x^T(t) P x(t),$$

$$V_2(t, x(t)) = \sum_{k=1}^r \int_{t-\tau_k(t)}^t x^T(s) Q_k x(s) ds,$$

$$V_3(t, x(t)) = \sum_{k=1}^r \int_{t-\tau_k(t)}^t f^T(x(s)) R_k f(x(s)) ds,$$

$$V_4(t, x(t)) = \sum_{k=1}^r \tau_k \int_{-\tau_k}^0 \int_{t+\theta}^t \dot{x}^T(s) S_k \dot{x}(s) ds d\theta$$

Model 34 için kullanılan Lyapunov Fonksiyonları:

(H Yang, L Sheng, 2009)[73]

$$V(x(t), t) = x^T(t) P x(t) + \int_{t-\tau(t)}^t x^T(s) Q x(s) ds + \int_{t-\tau(t)}^t f^T(x(s)) R f(x(s)) ds.$$

Model 35 için kullanılan Lyapunov Fonksiyonları:

(M. Syed Ali, P. Balasubramaniam 2011)[53]

$$V(t, x(t)) = V_1(t, x(t)) + V_2(t, x(t)) + V_3(t, x(t)) + V_4(t, x(t))$$

$$V_1(t, x(t)) = x^T(t) P x(t),$$

$$V_2(t, x(t)) = \sum_{k=1}^r \frac{1}{1 - \tau_k^*} \int_{t-\tau_k(t)}^t x^T(s) Q_k x(s) ds,$$

$$V_3(t, x(t)) = \sum_{k=1}^r \frac{1}{1 - \tau_k^*} \int_{t-\tau_k(t)}^t f^T(x(s)) R_k f(x(s)) ds,$$

$$V_4(t, x(t)) = \sum_{k=1}^r \bar{\rho}_k \int_{\bar{\rho}_k}^0 \int_{t+\theta}^t f^T(x(s)) T_k f(x(s)) ds d\theta.$$

Model 36 için kullanılan Lyapunov Fonksiyonları:

(X Zhang, K Li, 2010)[67]

$$V_i(t) = \int_G v_i^2(t, x) dx$$

Model 39 için kullanılan Lyapunov Fonksiyonları:

(P Balasubramanian, M Kalpana, R Rakkiyappan, 2011)[61]

$$V(t) = \sum_{i=1}^7 V_i(t),$$

$$\begin{aligned} V_1(t) = & [u(t) - D \int_{t-\sigma_1}^t u(s) ds]^T P_1 [u(t) - D \int_{t-\sigma_1}^t u(s) ds] \\ & + [v(t) - \tilde{D} \int_{t-\sigma_2}^t v(s) ds]^T P_2 [v(t) - \tilde{D} \int_{t-\sigma_2}^t v(s) ds], \end{aligned}$$

$$\begin{aligned} V_2(t) = & \int_{t-\tau}^t v^T(s) N_1 v(s) ds + \int_{t-\sigma_1}^t u^T(s) N_2 u(s) ds \\ & + \int_{t-\rho}^t u^T(s) M_1 u(s) ds + \int_{t-\sigma_2}^t v^T(s) M_2 v(s) ds, \end{aligned}$$

$$V_3(t) = \tau \int_{-\tau}^0 \int_{t+\theta}^t \dot{v}^T(s) E_1 \dot{v}(s) ds d\theta + \rho \int_{-\rho}^0 \int_{t+\theta}^t \dot{u}^T(s) E_2 \dot{u}(s) ds d\theta,$$

$$\begin{aligned} V_4(t) = & \sum_{j=1}^m (h_1)_j \int_0^\infty k_j(\theta) \int_{t-\theta}^t f_j^2(v_j(s)) ds d\theta \\ & + \sum_{i=1}^n (h_2)_i \int_0^\infty k_i(\theta) \int_{t-\theta}^t g_i^2(u_i(s)) ds d\theta, \end{aligned}$$

$$\begin{aligned}
V_5(t) = & \int_0^t \int_{\theta-\rho(\theta)}^\theta \begin{bmatrix} u(\theta - \rho(\theta)) \\ \dot{u}(s) \end{bmatrix}^T \begin{bmatrix} Q_{11} & Q_{12} \\ * & Q_{22} \end{bmatrix} \begin{bmatrix} u(\theta - \rho(\theta)) \\ \dot{u}(s) \end{bmatrix} ds d\theta \\
& + \int_0^t \int_{\theta-\tau(\theta)}^\theta \begin{bmatrix} v(\theta - \tau(\theta)) \\ \dot{v}(s) \end{bmatrix}^T \begin{bmatrix} R_{11} & R_{12} \\ * & R_{22} \end{bmatrix} \begin{bmatrix} v(\theta - \tau(\theta)) \\ \dot{v}(s) \end{bmatrix} ds d\theta
\end{aligned}$$

$$V_6(t) = \int_{-\rho}^0 \int_{t+\theta}^t \dot{u}^T(s) Q_{22} \dot{u}(s) ds d\theta + \int_{-\tau}^0 \int_{t+\theta}^t \dot{v}^T(s) R_{22} \dot{v}(s) ds d\theta,$$

$$V_7(t) = \sigma_1 \int_{t-\sigma_1}^t \int_\theta^t u^T(s) T_1 u(s) ds d\theta + \sigma_2 \int_{t-\sigma_2}^t \int_\theta^t v^T(s) T_2 v(s) ds d\theta.$$

Model 40 için kullanılan Lyapunov Fonksiyonları:

(A Wu, C Fu, 2010)[68]

$$\begin{aligned}
V(t) = & \int_\Omega \sum_{i=1}^n \lambda_i [|v_i(t, x)|^2 e^{2\varepsilon t} \\
& + \sum_{j=1}^n (|\alpha_{ij}(t)| + |\beta_{ij}(t)|) p_j^2 \int_{t-\tau_{ij}}^t |u_j(s, x) - u_j^*|^2 e^{2\varepsilon(s+\tau_{ij})} ds] dx
\end{aligned}$$

5. TARTIŞMA VE SONUÇ

Bu bölümde, elde edilen verilerden faydalanarak çeşitli analizler yapılacaktır. BHSA'ların kararlılık analizi ile ilgili yapılmış tüm çalışmaların yıllara göre dağılımı, ele alınan kararlılık analizi türüne göre dağılımı, analizlerde kullanılan yöntemlere göre dağılımı tablolar halinde verilecektir.

İlk tabloda bulanık hücreli sinir ağlarının kararlılık analizi ile ilgili 1996-2015 yılları arasında yapılmış tüm çalışmaların yıllara göre dağılımı verilmiştir. Bu alanda en yoğun çalışmanın yapıldığı yıllar 2006-2011 yılları olup, 14 çalışma ile 2009 yılı en çok çalışmanın yapıldığı yıl olmuştur.

İkinci tabloda bulanık hücreli sinir ağlarının kararlılığı alanında yapılmış çalışmalar kararlılık türlerine göre sınıflandırılmıştır. Tablodan görüleceği gibi bu alanda en çok üstel kararlılıkla ilgili çalışmalar yapılmıştır.

Kararlılık analizinde en çok kullanılan yöntem Lyapunov kararlılık teoremi olmuştur. Lyapunov kararlılık teoremi sonrasında en çok kullanılan diğer yöntem M-matris teoremi olmuştur.

Yıl	Yapılan çalışma sayısı
1996	1
1997	0
1998	1
1999	0
2000	0
2001	0
2002	0
2003	0
2004	2
2005	1
2006	7
2007	3
2008	8
2009	14
2010	9
2011	12
2012	3
2013	4
2014	3
2015	1

Tablo 5.1: Yıllara göre yapılan çalışma sayısı.

Kararlılık Türü	Referans
Global Kararlılık	[106], [110]
Global Asimptotik Kararlılık	[44], [46], [52], [53], [54], [56], [57], [59], [61], [62], [65], [72], [92], [108]
Global Üstel Kararlılık	[43], [47], [48], [49], [50], [51], [55], [64], [66], [67], [68], [69], [71], [74], [75], [76], [77], [79], [81], [82], [83], [84], [85], [86], [88], [89], [91], [93], [94], [95], [96], [97], [98], [99], [100], [101], [102], [103], [104], [105], [107], [109]
Üstel p-Kararlılık	[45], [58]
Ortalama Kare Üstel Kararlılık	[60], [80]
Robust Kararlılık	[70], [73]
Hemen Hemen Kesin Üstel Kararlılık	[63], [78], [80], [87]

Tablo 5.2: Kararlılık türüne göre yapılan çalışmalar.

Kararlılık Analizi Yöntemi	Referans
Lyapunov fonksiyonu	[106], [49], [94], [107], [76], [71], [90], [97], [92], [84], [76], [104], [109], [86], [65], [64], [91], [70], [52], [43], [57], [59], [44], [99], [96], [87], [78], [48], [60], [62], [95], [72], [73], [53], [67], [61], [68], [47], [54]
Lyapunov fonksiyonu ve Linner matris eşitsizliği	[71], [97], [65], [70], [52], [57], [59], [62], [95], [53]
M-matris Teoremi	[77], [89], [101], [108], [49], [93], [74], [63], [58], [65], [45], [103]
Diğer	[102], [55], [51], [44], [79]

Tablo 5.3: Kararlılık analizinde kullanılan yöntemler.

Bu tez çalışmasında bulanık hücresel sinir ağlarının kararlılığı ile ilgili literatürde ilk çalışmanın yapıldığı 1996 yılından 2015 yılına kadar yapılmış tüm çalışmalar incelenmiştir. Çalışmalarda kullanılmış bulanık yapay sinir ağı modelleri sınıflandırılarak, toplamda 40 farklı model çıkarılmıştır. Daha sonra her bir model için kararlılık analizinde kullanılmış yöntemler sunulmuştur. Buradan bulanık hücresel sinir ağlarının kararlılık analizinde en çok kullanılan yöntemin Lyapunov kararlılık teoremi olduğu, Lyapunov fonksiyonları ile beraber farklı yöntemler de kullanılarak ve Lyapunov kararlılık dışında farklı yöntemler kullanılarak da bir çok çalışma yapıldığı sonucu çıkarılmıştır. Çalışmada ayrıca Lyapunov kararlılık teoremi kapsamında kullanılan Lyapunov fonksiyonları model bazlı sunulmuştur. Dolayısıyla bu çalışma bugüne kadar bulanık hücresel sinir ağlarının kararlılık analizinde kullanılmış tüm Lyapunov fonksiyonlarını içermesi bakımından bu alanda yapılacak yeni çalışmalar için fayda sağlayacak nitelikte bilgiler sunmaktadır. Ayrıca bulanık hücresel sinir ağlarının kararlılık analizi ile ilgili günümüze kadar yapılmış tüm çalışmaların yıllara göre sayılarını ve yapılan çalışmalar kararlılık analizi tiplerine göre dağılımını sunması bakımından detaylı bir survey çalışması olmuştur.

KAYNAKLAR

- [1]. Benitez, J.M., Castro J.L., Requena I., 1997, Are artificial neural networks black boxes?, *IEEE Trans Neural Netw.*, 8(5), 1156-1164.
- [2]. Zadeh L.A., 1965, Fuzzy sets, *Information and Control*, 8, 338–353.
- [3]. Abbasbandy S., Otandi M., 2006, Numerical solution of fuzzy polynomials by fuzzy neural networks, *Applied Mathematics and Computations*, 181, 1084–1089.
- [4]. Abbasbandy S., Neirto J.J., Amirfagharian M., 2007, Best approximation of fuzzy functions, *Nonlinear Studies*, 14, 87–102.
- [5]. Fukuda S., Hiramatsu K., Mori M., 2006, Fuzzy neural network model for habitat prediction and HEP for habitat quality estimation focusing on Japanese medaka (*Oryzias latipes*) in agricultural canals, *Paddy and Water Environ* , 4, 119–124.
- [6]. Kuo R.J., Wu P., Wang C.P., 2002, An intelligent sales forecasting system through integration of artificial intelligence and fuzzy neural networks with fuzzy weight elimination, *Neural Networks*, 15, 909–925.
- [7]. Liu P., 1965, Representation of digital image by fuzzy neural network, *Fuzzy Sets and Systems*, 130, 109–123.
- [8]. Huang M.J., Tsou Y.L., Lee S.C., 2006, Integrating fuzzy data mining and fuzzy artificial neural networks for discovering implicit knowledge, *Knowledge-Based Systems*, 19, 396–403.
- [9]. Cao J., 2000, Representation of digital image by fuzzy neural network, *Physics Letters A*, 270, 157–163.
- [10]. Chua L.O. and Yang L., 1988, Cellular neural networks: Theory, *IEEE Trans. Circuits Systems*, 35, 1257-1272.
- [11]. Liao X., Chen G., and Sanchez E.N., 2002, LMI-based approach for asymptotically stability analysis of delayed neural networks, *IEEE Trans Circuits Syst. I, Fundam. Theory Appl.*, 49(10), 1033–1039.
- [12]. Yang T., Yang L.B., Wu C.W., Chua L.O., 1996, Representation of digital image by fuzzy neural network, *In Proc. of IEEE International Workshop on Cellular Neural networks and Applications*, 181-186.
- [13]. Yang T., Yang L.B., Wu C.W., Chua L.O., 1996, A New Detection Algorithm (NDA) Based on Fuzzy Cellular Neural Networks for White Blood Cell Detection, *IEEE Transactions on Information Technology in Biomedicine*, 225-230.

- [14]. Wang S. and Min W., 2006, A New Detection Algorithm (NDA) Based on Fuzzy Cellular Neural Networks for White Blood Cell Detection, *IEEE Trans. Circuits Systems*, 10(1), 5-10.
- [15]. Lin C.T., Chang C.L. and Cheng W.C., 2004, A Recurrent Fuzzy Cellular Neural Network System With Automatic Structure and Template Learning, *IEEE Transactions on Circuits and Systems I: Regular Papers*, 51(5), 1024 - 1035.
- [16]. Wang S., Fu D., Xu M., Hu D., 2007, Advanced fuzzy cellular neural - network: Application to CT liver images, *Artificial Intelligence in Medicine*, 39, 65—77.
- [17]. Wang S., Fu D., Xu M., Hu D., 2005, Applying Advanced Fuzzy Cellular Neural Network AFCNN to Segmentation of Serial CT (computed tomography) Liver Images, *Advances in Natural Computation*, 3612, 1128-1131.
- [18]. Senthilkumar S., Piah A.R.M., 2012, An improved fuzzy cellular neural network (IFCNN) for an edge detection based on parallel RK(5,6) approach, *Int. J. Computational Systems Engineering*, 1(1).
- [19]. Yang T., Yang L.B., 1997, Application Of Fuzzy Cellular Neural Network To Morphological Grey-Scale Reconstruction, *International Journal of Circuit Theory and Applications*, 25(3), 153-165.
- [20]. Nishizono K., Nishio Y., 2006, Image Processing of Gray Scale Images by Fuzzy Cellular Neural Network, *RISP International Workshop on Nonlinear Circuits and Signal Processing*.
- [21]. Yang T., Yang L.B., 1997, Fuzzy Cellular Neural Network: a new paradigm for image processing, *International Journal of Circuit Theory and Applications*, 25(6), 469-481.
- [22]. Yang T., Yang L.B., 1997, Application of Fuzzy Cellular Neural Networks to Euclidean Distance Transformation, *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 44(3), 242 - 246.
- [23]. Feng X., Zhang F., Wang W., 2011, Global exponential synchronization of delayed fuzzy cellular neural networks with impulsive effects, *Chaos, Solitons and Fractals*, 44, 9–16.
- [24]. Yan P., Lv T., 2012, Exponential synchronization of fuzzy cellular neural networks with mixed delays and general boundary conditions, *Commun Nonlinear Sci Numer Simulat*, 17(2), 1003–1011.
- [25]. Gan Q., 2013, Exponential Synchronization of Stochastic Fuzzy Cellular Neural Networks with Reaction-Diffusion Terms via Periodically Intermittent Control, *Neural Processing Letters*, 37(3), 393-410.
- [26]. Kalpana M., Balasubramaniam P., Ratnavelu K., 2015, Direct delay decomposition approach to synchronization of chaotic fuzzy cellular neural networks with discrete, unbounded distributed delays and Markovian jumping parameters, *Applied Mathematics and Computation*, 254, 291–304.

- [27]. Yu F., Jiang H., 2011, Global exponential synchronization of fuzzy cellular neural networks with delays and reaction–diffusion terms, unbounded distributed delays and Markovian jumping parameters, *Neurocomputing*, 74(4), 509–515.
- [28]. Balasubramaniam P., Kalpana M., Rakkiyappan M., 2012, Linear matrix inequality approach for synchronization control of fuzzy cellular neural networks with mixed time delays, unbounded distributed delays and Markovian jumping parameters, *Chinese Physics B*, 21(4).
- [29]. Yu J., Hu C., Jiang H., Teng Z., 2012, Exponential lag synchronization for delayed fuzzy cellular neural networks via periodically intermittent control, *Mathematics and Computers in Simulation*, 82, 895–908.
- [30]. Xing Z., Peng J., 2012, Exponential lag synchronization of fuzzy cellular neural networks with time-varying delays, *Journal of the Franklin Institute*, 349, 1074–1086.
- [31]. Kalpana M., Balasubramaniam P., 2013, Stochastic asymptotical synchronization of chaotic Markovian jumping fuzzy cellular neural networks with mixed delays and the Wiener process based on sampled-data control, *Chinese Physics B*, 22(7).
- [32]. Yang T., Fang J.A., 2009, Robust synchronization in an array of fuzzy delayed cellular neural networks with stochastically hybrid coupling, *Neurocomputing*, 72, 3253–3262.
- [33]. Wang L., Ding W., 2012, Synchronization for delayed non-autonomous reaction–diffusion fuzzy cellular neural networks, *Commun Nonlinear Sci Numer Simulat*, 17, 170–182.
- [34]. Ding W., Han M., 2008, Synchronization of delayed fuzzy cellular neural networks based on adaptive control, *Physics Letters A*, 372, 4674–4681.
- [35]. Gan Q., Xu R., Yang P., 2012, Synchronization of non-identical chaotic delayed fuzzy cellular neural networks based on sliding mode control, *Commun Nonlinear Sci Numer Simulat*, 17, 433–443.
- [36]. Xia Y., Yang Z., Han M., 2009, Synchronization schemes for coupled identical Yang–Yang type fuzzy cellular neural Networks, *Commun Nonlinear Sci Numer Simulat*, 14, 3645–3659.
- [37]. Wang L., Ding W., Chen D., 2010, Synchronization schemes of a class of fuzzy cellular neural networks based on adaptive control, *Physics Letters A*, 374, 1440–1449.
- [38]. Rakkiyappan R., Sakthivel N., Park J.H., Kwon O.M., 2013, Sampled-data state estimation for Markovian jumping fuzzy cellular neural networks with mode-dependent probabilistic time-varying delays, *Applied Mathematics and Computation*, 221, 741–769.
- [39]. Balasubramaniam P., Kalpana M., Rakkiyappan R., 2013, Stationary oscillation of interval fuzzy cellular neural networks with mixed delays under impulsive perturbations, *Neural Comput and Applic*, 22, 1645–1654.

- [40]. Huang Y. Zhu W. Xu D., 2009, Invariant and attracting set of fuzzy cellular neural networks with variable delays, *Applied Mathematics Letters*, 22, 478-483.
- [41]. Horn, R. A., Johnson, C. R., 1991, Topics in Matrix Analysis, *Cambridge University Press*.
- [42]. Khalil, H.K., 1996, Nonlinear Systems, Prentice Hall, New Jersey, 0-13-228024 8.
- [43]. Jing K., 2014, Exponential stability of FCNNs with time-varying leakage delays and reaction diffusion terms, *Neurocomputing*, 145, 363-368.
- [44]. Zheng C., Wang Y., Wang Z., 2014, Global Stability of fuzzy cellular neural Networks with mixed delays and leakage delay under impulsive perturbations, *Circuits, System and Signal Processing* , 33, 1067-1094.
- [45]. Long S., Xu D., 2014, Global Exponential p-stability of stochastic non-autonomous Takagi-Sugeno fuzzy cellular neural Networks with time varying delays and impulses, *Fuzzy Sets and Systems* , 253, 82-100.
- [46]. Rakkiyappan R., Sakthivel N., Park J.H., Known O.M., 2013, Sampled – data state estimation for Markovian jumping fuzzy cellular neural Networks with mode dependent probabilistic time varying delays, *Applied Mathematics and Computation* , 221, 741-769.
- [47]. Yang G., Kao Y., Li W., 2013, Exponential stability of impulsive stochastic fuzzy cellular neural Networks with mixed delays and reaction diffusion terms, *Neural Computing and Applications* , 23, 1109-1121.
- [48]. Xiong P., Huang L., 2013, On p-th moment of exponential stability of stochastic fuzzy cellular neural Networks with time varying delays and impulses, *Advances in Differential Equations* , 172.
- [49]. Long S., Song Q., Wang X., Li D., 2012, Stability analysis of fuzzy cellular neural Networks with time delay in leakage term and impulsive perturbations, *Journal of Franklin Institue* , 349, 2461-2479.
- [50]. Han W., Liu Y., Whan L., 2012, Global exponential stability of delayed fuzzy cellular neural Networks with Markovian jumping parameters, *Neural Computing and Applications* , 21, 67-72.
- [51]. Zhang Q., Yang L., Liao D., 2012, Dynamical analysis of fuzzy cellular neural Networks with time varying delays, *Journal of Computers* , 7(4), 934-940.
- [52]. Balasubramaniam P., Kalpana M., Rakkiyappan R., 2011, Existence and Global Asymptotic Stability of Fuzzy Cellular Neural Networks with Time Delay in the Leakage Term and Unbounded Distributed Delays, *Circuits Systems and Signal Processing* , 30(6), 1595-1616.
- [53]. Ali M.S., Balasubramaniam P., 2011, Global asymptotic stability of stochastic fuzzy cellular neural networks with multiple discrete and distributed time-varying delays, *Communications in Nonlinear Science and Numerical Simulation* , 16(7), 2907–2916.

- [54]. Zhu C., Bao G., 2011, Global asymptotic stability of fuzzy cellular neural networks with unbounded time-varying delays, *International Conference on Information Science and Technology (ICIST)* , 964 – 967.
- [55]. Zhang Q., Yang L., Liao D., 2011, Existence and exponential stability of a periodic solution for fuzzy cellular neural Networks with time varying delays, *International Journal of Applied Mathematics and Computer Science* , 21(4), 649-658.
- [56]. Ali M.S., Balasubramaniam P., 2011, Global asymptotic stability of stochastic fuzzy cellular neural with multiple discrete and distributed time-varying delays, *Communications in Nonlinear Science and Numerical Simulation* , 16(7), 2907–2916.
- [57]. Balasubramaniam P., Kalpana M., Rakkiyappan R., 2011, State estimation for fuzzy cellular neural Networks with time delay in the leakage term, discrete and unbounded distributed delays, *Computers and Mathematics with applications* , 62, 3959-3972.
- [58]. Zhang Q., Yang L., 2011, Exponential p-stability of impulsive stochastic fuzzy cellular neural Networks with mixed delays, *WSFAS transactions on mathematics* , 10(12), 490-499.
- [59]. Lia X., Rakkiyappan R., Balasubramaniam P., 2011, Existence and global stability analysis of equilibrium of fuzzy cellular neural networks with time delay in the leakage term under impulsive perturbations, *Journal of the Franklin Institute* , 348(2), 135–155.
- [60]. Chen L., Wu R., Pan D., 2011, Mean square exponential stability of impulsive stochastic fuzzy cellular neural networks with distributed delays, *Expert Systems with Applications* , 38(5), 6294–6299.
- [61]. Balasubramaniam P., Kalpana M., Rakkiyappan R., 2011, Global asymptotic stability of BAM fuzzy cellular neural Networks with time delay in the leakage term, discrete and unbounded distributed delays, *Mathematical and Computer Modelling* , 53, 839-853.
- [62]. Balasubramaniam P., Vembarasan V., Rakkiyappan R., 2011, Leakage Delays in T-S Fuzzy Cellular Neural Networks, *Neural Processing Letters* , 33, 111-136.
- [63]. Long S., Xua D., 2011, Stability analysis of stochastic fuzzy cellular neural networks with time-varying delays, *Neurocomputing* , 74(14-15), 2385–2391.
- [64]. Niu S., Jianga H., Tenga Z., 2010, Boundedness and exponential stability for nonautonomous FCNNs with distributed delays and reaction–diffusion terms, *Neurocomputing* , 73(16-18), 2913–2919.
- [65]. Tan M.C., 2010, Global Asymptotic Stability of Fuzzy Cellular Neural Networks with Unbounded Distributed Delays, *Neural Processing Letters* , 31(2), 147-157.
- [66]. Li K., 2010, Impulsive effect on global exponential stability of BAM fuzzy cellular neural Networks with time varying delays, *International Journal of System Science* , 41(2), 131-142.

- [67]. Zhang X., Li K., 2010, Stability analysis of impulsive stochastic fuzzy cellular neural Networks with time varying delays and reaction diffusion terms, *World Academy of Science, Engineering and Tachnology International Journal of Mathematical, Computational, Physical, Electrical and Computer Engineering* , 4(1), 74-81.
- [68]. Wu A., Fu C., 2010, Global exponential stability of non-autonomous FCNNs with Dirichlet boundary conditions and reactions diffusion terms, *Applied Mathematical Modelling* , 34, 3022-3029.
- [69]. Gan Q., Xu R., Yang P., 2010, Stability Analysis of Stochastic Fuzzy Cellular Neural Networks With Time-Varying Delays and Reaction-Diffusion Terms, *Neural Processing Letters* , 32(1), 45-57.
- [70]. Balasubramaniam P., Ali M.S., 2010, Robust stability of uncertain fuzzy cellular neural networks with time-varying delays and reaction diffusion terms, *Neurocomputing* , 74(1-3), 439–446.
- [71]. Tan M.C., 2010, Global exponential stability of delayed fuzzy cellular neural networks, *International Journal of Fuzzy Systems* , 12(3).
- [72]. Balasubramaniam P., Ali M.S., Arik S., 2010, Global asymptotic stability of stochastic fuzzy cellular neural networks with multiple time-varying delays, *Expert Systems with Applications* , 37(12), 7737–7744.
- [73]. Yang H., Sheng L., 2009, Robust Stability of uncertain stochastic fuzzy cellular neural Networks, *Neurocomputing* , 73, 133-138.
- [74]. Li Z., Li K., 2009, Stability analysis of impulsive fuzzy cellular neural Networks with distributed delays and reaction diffusion terms, *Chaoesi Solitons and Fractals* , 42, 492-499.
- [75]. Jiang H., Guo B., Tang Z., 2009, Exponential stability high-order fuzzy cellular neural Networks with time varying delays, *Advanced in Neural Networks* , 5551, 413-422.
- [76]. Liu Z., Zhang H., Wang Z., 2009, Novel stability criterions of a new fuzzy cellular neural networks with time-varying delays, *Neurocomputing* , 72(4-6), 1056-1064.
- [77]. Liang J., Li K., 2009, Exponential Stability of Fuzzy Cellular Neural Networks with Time-varying Delays and Impulses, *Computer Science and Information Engineering* , 5, 637 – 644.
- [78]. Zhao H., Ding N., Chen L., 2009, Almost sure exponential stability of stochastic fuzzy cellular neural networks with delays, *Chaos, Solitons and Fractals* , 40(4), 1653–1659.
- [79]. Wang X., Xu D., 2009, Global Exponenetial Stability of impulsive fuzzy cellular nural Networks with mixed delays and reaction –diffusion terms, *Chaos, Solitons and Fractals* , 42, 2713-2721.
- [80]. Chen L., Wu R., 2009, Exponential stability of stochastic fuzzy cellular neural Networks with distributed delays, *Internal Journal of Bifurcation and Chaos* , 19, 3387.

- [81]. Li K., 2009, Global exponential stability of impulsive fuzzy cellular neural Networks with delays and diffusion, *International Journal of Bifurcation and Chaos* , 19, 245.
- [82]. Tan M.C., 2009, Dynamic analysis of delayed fuzzy cellular neural Networks with time varying coefficients, *Advanced in Neural Networks* , 5551, 433-439.
- [83]. Tan M.C., 2009, Exponential Convergence behaviour of fuzzy cellular neural Networks with distributed delays and time varying coefficients, *International Journal of Bifurcation and Chaos* , 19, 2455.
- [84]. Zhang Q., Luo W., 2009, Global Exponential Stability and Periodic Solutions of FCNNs with Constant Delays and Time-Varying Delays, *Computational Sciences and Optimization* , 2, 659–662.
- [85]. Song Q., Wang Z., 2009, Dynamical behaviours of fuzzy reaction- diffusion periodic cellular neural Networks with variable coefficients and delays, *Applied Mathematical Modelling* , 33, 3533-3545.
- [86]. Niu S., Jiang H., Teng Z., 2008, Exponential stability and periodic solutions of FCNNs with variable coefficients and time-varying delays, *Neurocomputing*, 71(13-15), 2929-2936.
- [87]. Chena L., Zhao H., 2008, Stability analysis of stochastic fuzzy cellular neural networks with delays, *Neurocomputing* , 72(1-3), 436–444.
- [88]. Wu Y., Zhang Q., 2008, Global Exponential Stability of Fuzzy Cellular Neural Networks with Variable Delays and Distributed Delays, *Proceedings of The 6th Conference of Biomathematics, Vols I and II: Advances on Biomathematics* , 695-699.
- [89]. Wu R., Chen L., 2008, Global exponential stability of fuzzy cellular neural networks with mixed delays, *International Conference on Computer Science and Software Engineering* , 4, 867–870.
- [90]. Ding W., Han W., 2008, Synchronization of delayed Fuzzy cellular neural Networks based on adaptive control, *Physics Letter A* , 372, 4674-4681.
- [91]. Wang J., Lu J.G., 2008, Global exponential stability of fuzzy cellular neural networks with delays and reaction–diffusion terms, *Chaos, Solitons and Fractals* , 38(3), 878–885.
- [92]. Zhanga Q., Xiangc R., 2008, Global asymptotic stability of fuzzy cellular neural networks with time-varying delays, *Physics Letters A* , 372(22-26), 3971–3977.
- [93]. Song Q., Cao J., 2008, Dynamical behaviors of discrete-time fuzzy cellular neural networks with variable delays and impulses, *Journal of the Franklin Institue* , 345, 39-59.
- [94]. Huang T., 2007, Exponential stability of delayed fuzzy cellular neural networks with diffusion, *Chaos, Solitons and Fractals* , 31(3), 658–664.
- [95]. Liao T.L., Yan J.J., Jou Y.Y., 2007, Stability Analysis of Takagi–Sugeno Fuzzy Cellular Neural Networks With Time-Varying Delays, *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions* , 37(3), 720-726.

- [96]. Li K., Li Z., Song Q., 2007, Behaviour of impulsive fuzzy cellular neural Networks with distributed delays, *Electronic Journal of Diferantial Equations* , 50, 1-16.
- [97]. Yuana K., Caoa J., Dengb J., 2006, Exponential stability and periodic solutions of fuzzy cellular neural networks with time-varying delays, *Neurocomputing* , 69(13-15), 1619–1627.
- [98]. Zhang J., Ren D., Zhang W., 2006, Global exponential stability of fuzzy cellular neural Networks with variable delays, *Advances in Neural Networks* , 3971, 236-242.
- [99]. Huang T., Sol M.R., 2006, Stability of fuzzy cellular neural Networks with impulses, *Advances in Neural Networks* , 243-248.
- [100]. Hong X., Wang J., Hau J., 2006, Exponential stability and periodic solutions of fuzzy cellular neural Networks with transmission delays and variable coefficients, *Fuzzy Systems and Mathematics* , 6.
- [101]. Huang T., 2006, Exponential stability of fuzzy cellular neural networks with distributed delay, *Physics Letters A* , 351(1-2), 48-52.
- [102]. Zhong S.M., Long Y.H., Liu X.W., 2006, Exponential Stability Criteria of Fuzzy Cellular Neural Networks with Time-Varying Delays, *Machine Learning and Cybernetics* , 4144–4148.
- [103]. Huang T., Zhang L., 2005, Exponential Stability of Fuzzy cellular neural Networks with unbounded delay, *Advances in Neural Networks* , 168-173.
- [104]. Liu Y., Tang W., 2004, Exponential stability of fuzzy cellular neural networks with constant and time-varying delays, *Physics Letters A* , 323(3-4), 224–233.
- [105]. Chen Y., Liao X., 2004, Novel Exponential stability criteria for fuzzy cellular neural Networks with time varying delay, *Advances in Neural network* , 3173, 120-125.
- [106]. Yang T., Yang L.B., 1996, The global stability of fuzzy cellular neural network, *IEEE transactions on circuits and systems. 1, Fundamental theory and applications* , 43(10), 880-883.
- [107]. Kaoa Y., Shi L., Xie J., Karimi H.R., 2015, Global exponential stability of delayed Markovian jump fuzzy cellular neural networks with generally incomplete transition probability, *Neural Networks* , 63, 18-30.
- [108]. Yang G., Kao Y., Wang C., 2013, Exponential Stability and Periodicity of Fuzzy Delayed Reaction-Diffusion Cellular Neural Networks with Impulsive Effect, *Abstract and Applied Analysis* , 2013.
- [109]. Zhang J., Ren D., Zhang W., 2006, Global Exponential Stability of Fuzzy Cellular Neural Networks with Variable Delays, *Advances in Neural Networks-ISNN* .

- [110]. Yang T., Yang L.B., Yang C.M., Yang X.P., 1998, Linguistic flow in fuzzy discrete-time cellular neural networks and its stability, *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications* , 45(9), 869-878.
- [111]. Pecora L.M., Carroll T.L., 1990, Synchronization in chaotic systems, *Phys. Rev. Lett.*, 64(821).
- [112]. Chua L.O., Yang L., 1988, Cellular Neural Networks: Theory, *IEEE Transactions on Circuits and Systems*, 35(10), 1273-1290.
- [113]. Cao J., 2000, Periodic oscillation and exponential stability of delayed CNNs, *Physics Letters A* , 270(2000), 157-163.
- [114]. Cao J., 2000, Global Exponential Stability and Periodic Solutions of Delayed Cellular Neural Networks, *Journal of Computer and Systems Sciences*, 60, 38-46.
- [115]. Yi Z., Heng P.A., Leung K.S., 2001, Convergence Analysis of Cellular Neural Networks with Unbounded Delay, *IEEE Transactions on Circuits and Systems—I: Fundamental Theory and Applications*, 48(6), 680-687.
- [116]. Xu S., Lam J., Ho D.W.C, Zou Y., 2005, Novel Global Asymptotic Stability Criteria for Delayed Cellular Neural Networks, *IEEE Transactions on Circuits and Systems—II: Express Briefs*, 52(6), 349-353 .
- [117]. Zhou D., Cao J., 2002, Globally exponential stability conditions for cellular neural networks with time-varying delays, *Applied Mathematics and Computation*, 131(2-3), 487-496.
- [118]. Li X.M., Huang L.H., Zhu H., 2003, Synchronization in chaotic systems, *Nonlinear Analysis*, 53, 319-333.
- [119]. Zhang G., Patuwo B.E., Hu M.Y., 1998, Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, 14, 35-62.
- [120]. Jain A.K., Mao J., Mohiuddin K.M., 1996, Artificial Neural Networks: A Tutorial, *IEEE Computer Society*, 29(3), 31-44.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı	Nilay Salt
Uyruğu	T.C.
Doğum yılı, Yeri	1988, K.Maraş
Telefon	0554 910 05 20
E-mail	saltnilay@gmail.com

Eğitim

Derece	Kurum/Anabilim Dalı/Programı	Yılı
Lisans	İstanbul Üniversitesi Matematik Bölümü	2011
Lise	Çağrıbey Anadolu Lisesi	2006