Eurasian Academy of Sciences
Eurasian Econometrics, Statistics & Emprical Economics Journal
2019 Volume:14 S: 121- 131
Published Online September 2019 (http://econstat.eurasianacademy.org)
http://dx.doi.org/10.17740/eas.stat.2019-V14-08

Hybrid Models Using Artificial Neural Networks and Fuzzy Logic and Applications

Muhammet ATALAY*

*Sorumlu Yazar: Dr. Öğr. Üyesi, Kırklareli Üniversitesi, İ.İ.B.F. İşletme Bölümü

E-mail: atalay@klu.edu.tr

Copyright © 2019 Muhammet ATALAY. This is an open access article distributed under the Eurasian Academy of Sciences License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT

Each of the artificial intelligence techniques has unique abilities. Artificial neural networks perform computer learning by imitating human nervous system. Fuzzy logic is very close to human thinking. It can also use verbal variables. However, these techniques have their own disadvantages. The most important disadvantage of fuzzy design is that these systems do not have the ability to learn. In parallel with the advances in artificial intelligence technologies, the disadvantages of these methods have been tried to be eliminated by using these techniques together. In this study, hybrid method approaches using artificial intelligence techniques are discussed. Examples of the studies conducted in the field of social sciences using these hybrid methods are presented. Fuzzy neural networks and neural fuzzy network models are the methods that the study focuses on. It is seen that these studies have been carried out for many years. In recent years, when the variety, size and speed of data have increased, models have been proposed that give good results in different areas.

Keywords: multivariate statistics, welfare economics, principal components analysis, regional development ranking, market institutionalization.

Yapay Sinir Ağları ve Bulanık Mantığın Birlikte Kullanıldığı Hibrit Modeller ve Uygulamaları[1]

ÖZET

Yapay zekâ tekniklerinden her birinin kendine özgü yetenekleri bulunmaktadır. Yapay sinir ağları insanın sinir sistemini taklit ederek bilgisayar öğrenmesini gerçekleştirir. Bulanık mantık ise insanın düşünüş tarzına çok yakındır. Aynı zamanda sözel değişkenleri de kullanabilmektedir. Yalnız bu tekniklerinin kendine özgü dezavantajları da bulunmaktadır. Bulanık tasarımlı sistemlerin en önemli dezavantajı bu sistemlerin öğrenme yeteneğinin olmamasıdır. Yapay zekâ teknolojilerindeki ilerlemelere paralel olarak bu tekniklerin birlikte kullanımı ile bu yöntemlerin dezavantajları ortadan kaldırılmaya çalışılmıştır. Bu çalışmada, birer yapay zeka tekniği olan bu iki yöntemin bir arada kullanıldığı hibrit (melez) yöntem yaklaşımları tartışılmış ve bu hibrit yöntemlerin kullanılarak özellikle sosyal bilimler alanında yapılmış çalışmalardan örnekler sunulmuştur. Bulanık sinir ağları ve sinirsel bulanık ağ modelleri yaklaşımları çalışmanın odaklandığı yöntemlerdir. Görülmektedir ki bu çalışmalar uzun yıllardır yapılagelmekte olup, verinin çeşitliliğinin, boyutunun ve hızının arttığı son yıllarda da farklı alanlarda iyi sonuçlar veren modeller önerilmektedir.

Anahtar Kelimeler: fuzzy logic, artificial neural networks, neural fuzzy systems, fuzzy neural networks, hybrid models, social sciences

[1] Bu çalışma, Dr. Muhammet Atalay'ın Prof. Dr. Erdal Balaban danışmanlığında tamamladığı "Zaman Serilerinde Yapay Sinir Ağları ve Bulanık Mantığa Dayalı Tahmin ve Bir Uygulama" başlıklı doktora tez çalışmasına (Atalay, 2015) dayanmaktadır.

1.GİRİŞ

Yapay sinir ağı ve bulanık mantık tekniklerinin her ikisi de temel olarak insan beyninin çalışma mantığına dayanmaktadır; bulanık mantık insan beyninin sonuç çıkarma mekanizmasını taklit ederken, yapay sinir ağları beynin fiziksel yapısı temel alınarak oluşturulmuştur (Zhang v.d., 2004). Her iki teknik de kontrol edilecek sistemin matematik modeline ihtiyaç duymazlar, bu sayede karmaşık ve doğrusal olmayan sistemler ile doğrusal sistemleri modelleyebilirler (Nauck ve Kruse, 1994).

Bulanık mantığın çıkış noktası klasik küme kuramına getirilen eleştiriler olmuştur. Klasik küme kuramında bir eleman için tam üyelik söz konusu olup bir eleman herhangi bir kümeye ya aittir ya da değildir. Bulanık mantıkta ise üyelik fonksiyonları aracılığıyla bir eleman birden fazla kümeye belirli oranlarda üye olabilmektedir. Başka bir deyişle, bulanık kümeler, bir elemanın bir kümeye kısmi üyeliğine olanak sağlar. Bulanık mantık, girdileri çıktılara, bir bulanık kümeyi bir başkasına dönüştüren "A ise B' dir" şeklindeki kurallara dayanmaktadır (Kosko ve Isaka, 1993).

Bulanık mantık kontrolü, sağduyuya dayalı kurallar kullanarak sistemleri tanımlar ve kontrol eder. Bu kurallar, "X İSE Y" – X giriş, Y çıkış – formunda kurallardır. Bulanık mantıkta matematik değişkenler yerine insanın karar verme mekanizmasını taklit edecek şekilde kelimelerle ifade edilen değişkenler kullanılır. Geleneksel mantıkta bir değişkenin gerçeklik değeri ya '1' ya da '0' olabilir. Ancak bulanık mantıkta bu değer 0 ile 1 aralığı içindeki tüm değerleri alabilir. Bu değerlere üyelik değeri adı verilir. Bir girdinin hangi üyelik değerini alacağını belirleyen eğriler, üyelik fonksiyonları olarak adlandırılır. Kullanılan matematiğin basit olması, doğrusal olmayan sistemleri modelleyebilme yeteneği, günlük dile dayalı olması, esnek olması (kesin sınırlardan oluşmaması) ve kesin olmayan bilgiye karşı toleranslı olması bulanık mantığa dayalı sistemlerin kullanımının getirdiği en önemli avantajları arasındadır.

Yapay sinir ağları ise beynin fizyolojik yapısı temel alınarak tasarlanan sistemler olup birbirleriyle paralel çalışan çok sayıda basit işlemciden oluşurlar. Bir sinir ağının davranış biçimini büyük oranda nöronlar arasındaki bağlantılar belirler; öğrenilen tüm bilgi bu bağlantılarda saklıdır. Yapay sinir ağları belirli bir işlevi yerine getirmek için eğitilebilirler ve bu eğitim bağlantıların değerlerini değiştirmekle sağlanır. Yapay sinir ağlarını geleneksel sistemlerden ayıran en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışma özellikleridir. Bu özellikler yapay sinir ağlarına hız, hataya karşı tolerans ve verimlilik gibi avantajlar kazandırmaktadır (Durmuş, 2005: 48,49).

Sinir ağlarının iki önemli özelliği bulunmaktadır. Bunların ilki, nümerik verilerden doğrusal olmayan haritalama yapabilme özelliği, ikincisi ise, paralel çalışma özelliğidir. Tüm bunların yanı sıra, sinir ağlarının; çok katmanlı ağ yapısında, sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması gibi dezavantajları da bulunmaktadır (Bernard, 1992).

Bulanık bir sistem, sistem bilgisini açıklamak için insan düşüncesine benzer şekilde sözel ifadeler kullanır. Bu sayede, sistem ve insan arasındaki kapalı bir etkileşimi mümkün kılar ki bulanık mantığın önemli avantajlarından biri budur (Tortum ve Çodur, 2007). Bulanık mantığın en önemli eksiği ise öğrenme yeteneği olmamasıdır.

Yapay sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilir. Sinir ağları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın sözel terimleri ve eğer–o halde kuralları ile ortadan kaldırılarak anlaşır çıktılar elde edilebilir. Hibrit sistemlerin amacı her iki yaklaşımın da faydalarını toplayıp, bir araya getirmektir.

Genel olarak bulanık mantık ile yapay sinir ağlarının birleşmesi üç şekilde olmaktadır:

1. Bulanık Sinir Ağları

2. Sinirsel Bulanık Sistemler

3. Bulanık-Sinirsel Hibrit Sistemler

Bulanık sinir ağı ile bulanık bilgi işleme yeteneğine sahip bir yapay sinir ağı ifade edilmek istenirken; sinirsel bulanık sistemler ile de bulanık çıkarım sistemleri sinir ağı yetenekleri ile zenginleştirilmektedir (Baykal ve Beyan, 2004: 426). Sinirsel bulanık sistemlerde esneklik, hız ve uyarlanabilirlik gibi özelliklerin sinir ağları ile bulanık sisteme eklenme durumu söz konusudur (Jang, 1993). Bulanık-sinirsel hibrit sistemlerde ise sistem performansını geliştirmek için bulanık sistemler ile sinir ağlarının beraberce kullanılması söz konusudur.

Başka bir sınıflamaya göre genel olarak sinir ağları ve bulanık mantık denetimi iki grupta toplanabilir:

1. Ortak çalışan sistemler: Sistemlerin her biri birbirinden bağımsız ve bileşkesi de bir bulanık sistemin bazı parametrelerinin yapay sinir ağı şeklinde belirlenmesi biçiminde olan sistemlerdir.

2. Tamamen hibrit sistemler: Burada bir yapay sinir ağlı bulanık sistemin çalıştırılması söz konusudur. Bu yapı birbirinden ayrı iki homojen kısma ayrılamamaktadır (Baykal ve Beyan, 2004: 425-427).

2. BULANIK SİNİR AĞLARI

Bulanık sinir ağlarında bulanık mantık ile klasik sinir ağlarının bilgi sunum yetenekleri zenginleştirilmektedir. Bulanık-sinir ağlarında ağın eğitim sürecinin bulanıklaştırılması, sinir ağı çıktılarının bulanık küme ile ifade edilmesi ve sinir hücrelerinin standart çarpım ve toplam işlemleri yerine bulanık küme teorisinde kullanılan birleşim, kesişim gibi çeşitli işlemlerin kullanılması adımları mevcuttur (Şekil 1). Genel olarak bulanık sinir ağlarında sinirsel ağlarla bulanık kavramların dört farklı şekilde sentezi yapılabilmektedir (Baykal ve Beyan, 2004: 427-437):

1. Bulanıklığı sinir ağı çatısına sokmak: Girdi verisini bulandırma, öğretim örneklerine bulanık etiketler atama, öğretim işlemelerini olabildiğince bulandırma ve sinir ağı çıktılarını bulanık küme terimleri ile sunma gibi.

2. Sinir hücrelerinin temel özelliklerini değiştirme: Sinir hücrelerinin standart çarpım ve toplam işlemcileri yerine bulanık küme teorisinde kullanılan çeşitli işlemcilerle (bulanık birleşim, kesişim ve bileşke) tasarlanması.

3. Bir ağın kararsızlığı ya da hatası olarak bulanıklık ölçümünün kullanımı: Bir bulanık kümenin bulanıklık ya da belirsizliğinin ölçümünün sinir ağına dayalı sistemlerde enerji fonksiyonu, hata ya da kararsızlığın modellenmesi için kullanılması.

4. Her bir sinir hücresini bulanık yapmak: Sinir hücrelerinin girdi ve çıktıları bulanık kümedir ve bulanık sinir hücreleri içeren ağların aktivitesi de bulanık bir işlem olacaktır.

Şekil 1. Bulanık sinir ağı modeli (Baykal ve Beyan, 2004: 428)

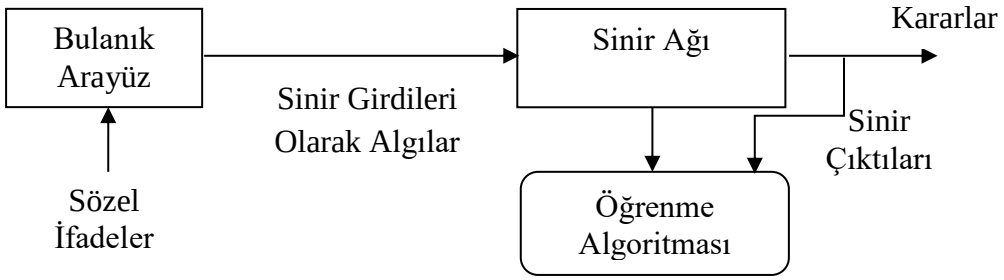

Basit bir sinir hücresinde tüm sinyal ve ağırlıklar gerçel sayılardır. $i = 1,2,\dots,n$ olmak üzere, x_i sinyali w_i ağırlığı ile;

$$p_i = w_i x_i$$

olur. p_i girdi bilgisi girdi oluşturmak için toplandığında;

$$(net) = p_1 + p_2 + \cdots + p_n = w_1x_1 + w_2x_2 + \cdots + w_nx_n$$

elde edilir. Sinir çıktıyı hesaplamak için f aktivasyon fonksiyonunu kullanır:

$$y = f(net) = f(w_1x_1 + w_2x_2 + \cdots + w_nx_n)$$

Bu sinir hücresinde kesin sinyal ve ağırlıklar ve kesin aktivasyon fonksiyonu (sigmoidal fonksiyonu gibi) yerine girdiler, ağırlıklar ve toplam girdinin hesaplanmasında t-norm, t-conorm yada diğer sürekli işlemci ve fonksiyonlar kullanılırsa bir hibrit sinir ağı elde edilmiş olur. Bu hibrit sinir ağının tüm girdi, çıktı ve ağırlıkları [0, 1] aralığından gerçel sayı olarak alınabilir. Bir hibrit sinir ağının işleme birimine bulanık sinir hücresi denir. Bulanık sinir hücresine "Ve" (EB-EK), "Veya" (EB-EK), "Veya" (EB-Çarpım), İçerme-"Veya", Kwan ve Cai'nin Bulanık Hücresi olarak yaklaşımlar mevcuttur (Baykal ve Beyan, 2004: 428-432).Bulanık sinir ağları (BSA) girdilerin gerçel sayı, ağırlıkların bulanık olduğu (BSA1), girdilerin bulanık, ağırlıkların gerçel sayı olduğu (BSA2) ve girdilerin ve ağırlıkların bulanık olduğu (BSA3) tiplere ayrılmaktadır (Baykal ve Beyan, 2004: 434).

3. SİNİRSEL BULANIK AĞ MODELİ

Sinirsel bulanık ağ, yapay sinir ağları ve bulanık sistemlerin sentezlenmesinden meydana gelen yapay zeka tekniklerinden birisidir. Bulanık mantığın belirsiz bilgileri işleme yeteneğinden ve yapay sinir ağının öğrenme yeteneğinden yararlanabilmek için bu iki teknoloji değişik yöntemlerle birleştirilmektedir (Jacek, 2003). Burada kastedilen, bulanık mantık biçimselliği ile sinir ağı tasarlamadır. Bulanık mantık ve karar vermeyi uygulamak ve bulanık kümeleri sunan üyelik fonksiyonu gerçekleştirmek için sinir ağları tasarlanacaktır. (Baykal ve Beyan, 2004: 426) Sinirsel bulanık ağların eğitimi ve özelliklerinin anlaşılması kolaydır. Sinirsel bulanık ağlar sözel değişkenleri kullanarak öğrenebilirler. Bu durum sinirsel bulanık ağların diğer doğrusal olmayan yapay zekâ teknolojileriyle (yapay sinir ağı gibi) kıyaslandığında en önemli avantajıdır (Abonyi, 2002: 92).Sıradan sinir ağlarında, düğümler aynı işlevselliğe sahiptir ve komşu katmanlardaki düğümler birbirine tamamen bağlıdır. Fakat sinirsel bulanık sistemlerde düğümler farklı işlevselliklere sahip olup, komşu katmanlardaki düğümler tamamen birbirlerine bağlı değildir. Bu farklılıklar genellikle bulanık sistemdeki özel bir bölümle uyumludur. Yani, bazı düğümler girdi değişkenlerinin sözel terimlerini ifade eder, bazı düğümler çıktı değişkenleri içindir ve bazı düğümler ve bağlantılar bulanık kuralları temsil etmek için kullanılır (Baykal ve Beyan, 2004: 439).Bilindiği gibi bulanık küme tabanlı sistemler genel olarak; bulanıklaştırma, bulanık kural tabanı ve çıkarım ünitesi ve berraklaştırma birimlerinden oluşur (Şekil 2).

Şekil 2. Bulanık küme tabanlı bir sistemin genel yapısı

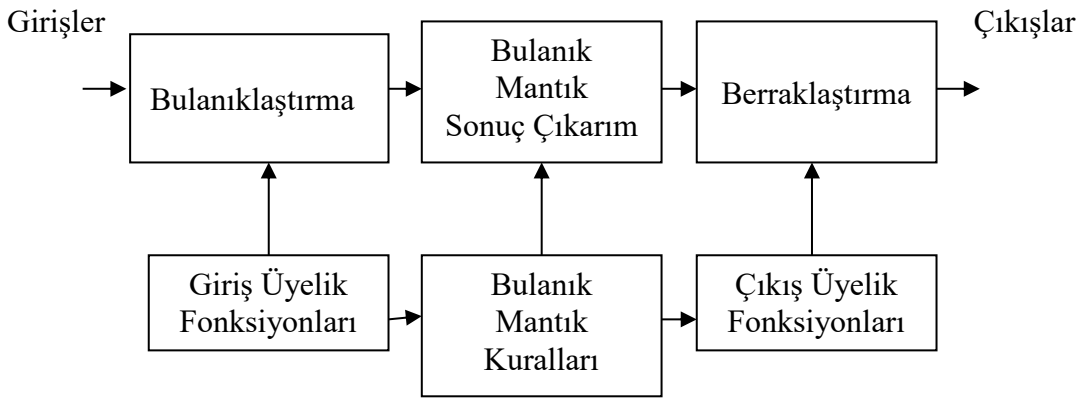

Bulanıklaştırma birimi, giriş bilgilerini önceden belirlenmiş üyelik fonksiyonlarını kullanarak uygun sözel değerlerden oluşan bulanık ifadelere dönüştürür. Kural tabanı, uzman kişinin kontrol yöntemini "Eğer-İse" (If-Then) kuralları şeklinde ifade eden, bulanık kurallar kümesinden oluşur. Çıkarım ünitesi, bulanıklaştırıcı çıkışını kural tabanındaki bulanık kurallar ile eşleştirir ve bulanık uygulamayı gerçekleştirecek uygun bir yorumlama yaptıktan sonra bulanık bir kontrol davranışına karar verir. Berraklaştırıcı, kontrol edilen sisteme uygulayabilmek için sayısal kontrol işaretine çevirir. Bulanık mantık kontrolörünün tasarımındaki en önemli sorun, bulanık mantık kuralları ve uygun üyelik fonksiyonlarının tanımlanmasıdır (Lin ve Lee, 1994). Yapay sinir ağı giriş ve çıkış eğitim çiftleri verilen bir statik fonksiyonu öğrenebilmektedir. Öğrenme işlemi, ağ içerisindeki ağırlıkların belirlenmesiyle gerçekleşmekte ve verilen fonksiyona optimal yaklaşım sağlanmaktadır. İşte sinirsel bulanık sistemlerde yapay sinir ağı, bulanık sistemin parametrelerini belirlemek için kullanılmaktadır. Öğrenme aşamasından sonra bulanık sistem yapay sinir ağına ihtiyaç duymadan çalışmaktadır. Sistem eğitim yaparken yapay sinir ağını, karar verme işleminde de bulanık mantığı kullanmaktadır. Bulanık sinir ağı, dört katmandan oluşmaktadır. Bulanıklaştırma katmanı, iki saklı katman, fonksiyon katmanı ve berraklaştırma katmanı (Memmedova, 2012):

- Bulanıklaştırma katmanının girişleri, bulanık çalışma bölgelerini tanımlamak için kullanılan sistem değişkenleridir. Bu katmanda üç tip işlem birimi aktivasyon fonksiyonu kullanılmaktadır. Bunlar; sigmoid, gauss ve ters sigmoid fonksiyonlarıdır.
- Kural katmanı bulanık çıkarım gerçekleştirmektedir. Bu katmandaki işlem birimleri sigmoid fonksiyonu kullanmaktadır. Kural katmanının ilk katmanındaki işlem birimleri girişlerinin her biri bir bulanık kümeye karşılık gelmektedir. Son katmandaki her bir işlem biriminin çıkışı ise çalışma bölgelerinin üyelik fonksiyonları olmaktadır.
- Fonksiyon katmanındaki işlem birimleri, bulanık çalışma bölgeleri için azaltılmış dereceli modelleri gerçekleştirmektedir. Her bir işlem birimi bir çalışma bölgesine karşılık gelmektedir. İşlem birimlerinin çıkışları, ağırlıklandırılmış sistem değişkenlerinin toplamıdır. - Fonksiyon katmanındaki ağırlıklar, çalışma bölgelerindeki doğrusal modellerin parametreleridir.
- Berraklaştırma işlem biriminin girişi, çalışma bölgeleri ve bu bölgelere ait üyelik fonksiyonlarıdır. Berraklaştırma katmanı, ağırlık yöntemi ile berraklaştırma işlemini gerçekleştirmekte ve ağ çıkışını oluşturmaktadır.

Sinirsel bulanık mantık modelinin özellikleri şu şekilde özetlenebilir (Jang v.d., 1997:7-9):

- Sinirsel bulanık modelleme, eğer ise bulanık kurallarını kullanarak insan tecrübesinin problem alanına uygulanmasını sağlar.
- Doğrusal olmayan sistem modellemede ve sınıflandırma problemlerinde, biyolojik sinir hücresinden esinlenerek oluşturulan yapay sinir ağlarının geniş bir şe-kilde uygulanmasına imkân tanır.
- Bu sistemler esnek yapıları sayesinde karmaşık problemlerin çözümünde kullanılabilir.
- Yapay sinir ağları ve bulanık çıkarım sistemleri, sadece örnek verilerin sisteme girilmesi ile model kurma yeteneğine sahiptir.
- Sistemde meydana gelebilecek olan hata durumlarında, sistem tamamen etkisiz hale gelmez, bu sistemler hata toleransına sahiptir.

Sinirsel bulanık ağlar verilerin sisteme girilmesi ve üyelik fonksiyonlarının tanımlanması ile en iyi öğrenmeyi gerçekleştirebilmek için uygun parametreleri kendisi atar. Öğrenme sürecinde bulanık kurallar kullanılır. Eğer x çok küçük ise y grup 1'e aittir şeklinde kurallar üyelik fonksiyonları göz önünde bulundurularak oluşturulur. Sinirsel bulanık ağ üyelik fonksiyonlarına göre oluşturulmuş kuralları kullanarak eğitim faaliyetini gerçekleştirir. Sorun alanına uygun çözümün geliştirilmesinde kuralların oluşturulması ve parametrelerin atanması sistem tarafından gerçekleştirildiği için belki de sinirsel bulanık ağlar, yapay sinir ağlarına

oranla daha hızlı öğrenme gerçekleştirebilirler. Sinirsel bulanık ağ modelini yapay sinir ağ modelinden ayıran ve bu çalışma açısından sinirsel bulanık ağ modelinin en önemli özelliği, elde edilen modelin "Eğer…ise…" gibi kurallar şeklinde ortaya konabilecek olmasıdır (Yıldız ve Akkoç, 2009).Sıradan sinir ağlarına sinirsel bulanık sistemlerin bir üstünlüğü de öğrenmeden önce uzman bilginin kolayca eklenebilmesidir. Sinirsel bulanık sistemlere başlangıçta bilgi yerleştirilir. Bu nedenle, lokal en küçüğe yakınsama, sıradan sinir ağlarındaki kadar ciddi olmayabilir.

Modern bulanık sistemler genel olarak ileri beslemeli ve çok katmanlıdır. Son yıllarda ANFIS, FALCON, FuNe, RuleNet, GARIC, NEFCLASS, NEFCON, NEF PROX adlı sinirsel bulanık sistemler ortaya konulmuştur. ANFIS modeli Sugeno benzeri bulanık sistem içerir ve geri yayılımlı algoritma kullanır. GARIC, NEFCON, NEFCLASS ve NEFPROX modelleri de Mamdani tip bulanık sistemleri kullanmaktadır (Baykal ve Beyan, 2004: 439).

4. YAPILAN ÇALIŞMALAR

Yapay sinir ağları ve bulanık mantıkla yapılan çalışmalar literatürde zengin bir içerik sunmaktadır. Bu sistemlerin melez olarak kullanıldığı çalışmalar ise bunlara göre nispeten daha az olmakla birlikte pek çok çalışma mevcuttur. Bu çalışmada ise bulanık sinir ağları ve sinirsel bulanık sistemler kullanılarak sosyal bilimler alanında yapılan çalışmalara değinilecektir.

4.1. Bulanık Sinir Ağları İle Yapılan Çalışmalar

Bu bölümde, sosyal bilimler alanında bulanık sinir ağları (fuzzy neural network) modelleri kullanılarak yapılan çalışmalara değinilecektir. Bulanık sinir ağları, yapay sinir ağının girdileri, çıktıları, katsayıları, ağırlıkları gibi elemanlarının bir ya da birkaçının bulanıklaştırılması ile elde edilmektedir.

Elektrik yükü tahmini, hem bulanık sinir ağları hem de sinirsel bulanık ağ modelleri ile gerçekleştirilebilmektedir. Kısa dönemli elektrik enerjisi talep tahmini için Tamimi ve Egbert (2000), Dash vd. (1998) bulanık sinir ağlarını kullanmışlardır. Kodogiannis ve Anagnostakis (1999) çalışmalarında, Bulanık Sinir Ağları ile Otoregresif (AR) modellerini kıyaslamaktadır. Chogumaira ve Hiyama (2011), Avustralya için geçmiş elektrik fiyat ve talep verilerini yapay sinir ağı tabanlı bulanık bir çıkarım tekniği kullanarak analiz etmiştir. Bakirtzis vd. (1995), makalelerinde kısa süreli yük tahmini için bulanık bir sistemin geliştirilmesini sunmaktadır. Bulanık sistem, bir ağ yapısına ve bir sinir ağının eğitim prosedürüne sahiptir ve bir bulanık sinir ağı olarak adlandırılır. Bu ağ başlangıçta mevcut tarihsel yük verilerinden bir kural tabanı oluşturur. Kural tabanının parametreleri daha sonra bir eğitim süreci boyunca ayarlanır, böylece ağın çıktısı, mevcut geçmiş yük verileriyle yeterince örtüşmektedir. Eğitildikten sonra, önerilen ağ gelecekteki yükleri tahmin etmek için kullanılabilir.

Hibrit sistemelerin kullanıldığı bir diğer alan finansal tahminler ve analizlerdir. Li ve Xiong (2005) Şanghay borsasında endeks tahmini için sinir ağlarının dezavantajlarını elemine edecek bir bulanık sinir ağı önerilmiştir. Çalışmanın sonuçları, önerilen bulanık sinir ağının finansal zaman serilerini tahmin etmede etkili olabildiğini göstermektedir. Rast (1999), 1987 ve 1998 yıllarında yaşanan borsa çöküşlerinde bulanık sinir ağlarının ve klasik yaklaşımın bir karşılaştırmasını yapmıştır. Almanya DAX-30 endeksi fiyat yönünü tahmini için hibrit bulanık nöral ağları öneren García vd. (2018), belirledikleri göstergelerin, Alman DAX-30 hisse senedi endeksinde öngörülen gücünün olup olmadığını analiz ederek, bir gün öncesinin endeks yönünü tahmin etmek için bir karma bulanık sinir ağı uygulayarak analiz etmektedirler. Tüm göstergelerin girdi olarak kullanılmasına veya faktör analizi yoluyla elde edilen doğrusal bir bileşiminin kullanılmasına bağlı olarak farklı modeller uygulamaktadırlar. Chou ve Lin' in yaptıkları Baltık Kuru Yük Endeksi (BDI) tahmini çalışmasında (2019), hem geleneksel bir bulanık sinir ağı uygulanmakta hem de teknik göstergelerle birleştirilmiş bütünleşik bulanık sinir ağı tahminde kullanılmaktadır.

Bulanık sinir ağları için öğrenme algoritmaları ve uygulamalarının araştırıldığı çalışmalarında Buckley ve Hayashi (1994), bulanık sinyalleri ve/veya bulanık ağırlıkları olan katmanlı, ileri beslemel bulanık bir sinir ağı önermektedir. Kuo (2001), genetik algoritma tarafından oluşturulan başlangıç ağırlıkları ile bulanık sinir ağını temel alan bir satış tahmin sistemi oluşturduğu araştırmada, pazarlama uzmanlarından elde edilen promosyon için bulanık IF–THEN kurallarını öğrenmek amacıyla, genetik algoritma tarafından üretilen başlangıç ağırlıkları ile önerilen bulanık sinir ağını kullanmaktadır. Genel tip-2 bulanık kümeleri kullanarak geri yayılım öğrenimi ile sinir ağlarının ağırlık ayarında hibritleştirilmiş bir tahmin yöntemi öneren makalelerinde Pal ve Kar (2019)' ın bu yöntemleri, Alabama Üniversitesi kayıt verileri, Shenzhen borsa kapanış fiyat endeksi, Şanghay borsa kapanış fiyat endeksi, Kanada lynx verileri ve sonuçları üzerinde de uygulanmaktadır.
Çalışmalarında sinir ağı modellemesi ile bulanık mantık ve bulanık küme teorisindeki teknikleri elektriksel yük tahmini için birleştiren bir karma bulanık sinir tekniğinin uygulanması ve tahmini sonuçları açıklayan Srinivasan, Chang ve Liew (1995), bulanık sinirsel hesaplama kullanarak hafta sonları ve tatil günleri için talep tahmini yapmışlardır.
Satış tahmini için yaptıkları uygulamada veri kümelemesi ve bulanık sinir ağı kullanan Chang, Liu ve Fan (2009), baskılı devre panosu fabrikasının gelecekteki satışlarını tahmin etmek için K-ortalama küme ve bulanık sinir ağını entegre ederek bir melez model geliştirmişlerdir.
Zaman serileri tahmini için bulanık sinir ağı öneren Souza ve Torres (2018), zaman serileri tahmini problemlerine tutarlı ve doğru modeller üretebilen düzenli bulanık sinir ağları için bir eğitim algoritması sunmaktadırlar. Model, bulanık sinir ağları modellerinin zaman serileri tahmininde daha az bulanık kurallarla öngördüğü yanıtların tahminlerini yapmaktadır. Hou, Zhao ve Lu (2018) ise, gelişmiş diferansiyel evrime dayalı bulanık sinir ağı optimizasyonu ile ağ trafiği tahmini yaptıkları çalışmalarında, diferansiyel evrim algoritmasını geri yayılım algoritması ile birleştirmekte ve ağ trafiğini tahmin eden bulanık sinir ağını optimize etmek için geliştirilmiş bir evrimsel geri yayılım algoritması önermektedirler.
Trafik akışı tahmininde bulanık sinir ağının gerçek zamanlı bir uygulanmasını öneren Tian, Ming ve Yun (2018), bu modeli kullanarak trafik akış zaman serilerinin her bir frekans bileşenini tahmin etmekte ve trafik verilerini modelin öngörücü etkinliğini doğrulamak için kullanmaktadır.

4.2. Sinirsel Bulanık Ağ Modelleri İle Yapılan Çalışmalar

Bu bölümde, özellikle sosyal bilimler alanında sinirsel bulanık (neuro-fuzzy) ağ modelleri kullanılarak yapılan çalışmalara değinilecektir. Bu modeller, yapay sinir ağılarının bir bulanık çıkarım sistemi gibi tasarlanması şeklinde uygulanmaktadır. Özellikle mühendislik alanlarında çok yaygın kullanılan modellerin çalışıldığı yayınlara, sağladıkları avantajlar nedeni ile farklı alanlarda da karşılaşılmaktadır. Nöro-bulanık tekniklerle bitcoin fiyat tahmini yapan Atsalakis vd. (2019), önerdikleri modelin yatırım getirilerinin, saf alım satım stratejisinden daha iyi performans gösterdiğini belirtmektedirler.
Chen, Huang ve Lin (2009), firma finansal başarısızlıklarının tahmininde sinirsel bulanık ağ modelini kullandıkları çalışmalarında büyüklük, sektör ve süreç faktörlerini dikkate almışlar ve sinirsel bulanık ağ modeli logit modelden daha başarılı bulmuşlardır. Yalın sinirsel bulanık bir model ile İMKB-100 endeksi tahmini öneren Ok, Atak ve Akçayol' un çalışmalarında (2011), endeks dünden bugüne öngörülebilirliği Adaptive Neuro Fuzzy Inference System (ANFIS) kullanılarak test edilmektedir.
Elektrik enerjisi yük tahmini sinirsel bulanık ağ modelleri ile de yapılabilmektedir. ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini yapan Demirel, Kakilli ve Tektaş (2013) hangi yöntemin talep tahmininde daha başarılı olduğunu da tartışmışlardır. Elde edilen sonuçlar ilgili kurumların öngörüleri ile karşılaştırılmış ve ANFIS modelden alınan tahminlere göre

yapılacak olan sistem planlamasının en ekonomik ve en doğru tercih olacağı belirtilmiştir. Yine Chen (2019), gün öncesi fiyat tahmini için bulanık kural tabanlı sistemleri entegre eden yeni bir yaklaşım geliştirerek elektrik yükü tahmini için nöro-bulanık tabanlı tahmini önermektedir. Samanta vd. (2019) sistem tanımlama ve zaman serisi tahmini için dinamik nöronlara sahip yeni bir nöro-bulanık çıkarım sistemi (NFIS-DN) ile sonuçların, Friedman testi ve Bonferroni–Dunn testi gibi istatistiksel tekniklerden daha iyi bir performans gösterdiğini iddia etmektedirler.

Finansal zaman serileri tahmini için yeni bir neuro-fuzzy modeli öneren Vlasenko vd. (2019) da daha önce başarılı bir şekilde uygulanan beş katlı çok boyutlu Gauss nöron bulanık modelini ve öğrenmesini geliştirmektedirler. Ürdün taşımacılık sektörünün enerji tüketiminin modellenmesi için çok değişkenli lineer regresyon ve adaptif nöro-bulanık teknikleri uygulayan Obaidat vd. (2019), enerji tüketimini; araç sayısı, gelir düzeyi, sahiplik düzeyi ve yakıt fiyatları gibi bir dizi faktörün bir fonksiyonu olarak modellemişlerdir. İki model arasında yapılan karşılaştırma, nöro-bulanık modelin tahmin performansının çok değişkenli doğrusal regresyon modelininkinden daha yüksek olduğunu öne sürmektedir. Nöro bulanık sistemler kullanarak çalkantılı piyasa dönemlerinde borsa tahmini (Atsalakis, Protopapadakis ve Valavanis, 2016), şirketlerin mali tehlikesinin uyarlanabilir nöro-bulanık çıkarım sistemi ve diskriminant analizinin karşılaştırılarak tahmin edilmesi (Mokhtar ve Abdul Rashid, 2016) gibi farklı finansal piyasa uygulamaları ile karşılaşılmaktadır.

Yapılan bir diğer ilgi çekici çalışma ise politik içerikli Twitter verileri üzerinde yapılmış ve duygu analizi için hibrit uyarlamalı bir nöro-bulanık arayüz ve destek vektörü makine tabanlı bir model önerilmektedir (Katta ve Hegde, 2019). Sonuç, sosyal ağ verilerinin ANFIS ve doğrusal olmayan destek vektör makinesi tabanlı duygu analizinin daha az karmaşık olduğunu ve mevcut metodolojilere kıyasla yüksek oranda doğruluk sağladığını göstermiştir.

5.SONUÇ

Bulanık mantıkta, klasik küme kuramından farklı olarak bulanık küme kuramı ile bir kümede sınır koşulları esnek olarak tanımlanabilmekte, kesin sınırlamaları ve tanımlamaları gerektirmeyen problemlerin çözümü gerçekleştirilebilmektedir. Yapay sinir ağları ise, birbirleri ile bağlantılı yapay sinir hücrelerinin oluşturduğu bir sistem ile biyolojik sinir sisteminin bilgiyi depolama, kullanma ve işleme yeteneklerini taklit etmeyi ve insan gibi karar verebilen ve muhakeme yeteneği olan zeki sistemler elde etmeyi amaçlamaktadır.

Yapay sinir ağlarının en önemli özellikleri öğrenme, genelleme yapabilme ve paralel çalışabilmesidir. Öte yandan sinir ağlarının; çok katmanlı ağ yapısında, sistem bilgisinin tüm ağa ağırlıklarla dağıtılmış olması nedeniyle ağırlıkların anlamsal özelliklerini açıklamanın ve ağda bulunan daha önceki bilgileri birleştirmenin zor olması gibi dezavantajları da bulunmaktadır. Bulanık mantığın en önemli eksiği ise öğrenme yeteneği olmamasıdır. Bu iki tekniğin faydalarını bir araya getirmek için birlikte kullanıldığı hibrit sistemlerde, yapay sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilmekte, sinir ağları ile sunulan bilgideki anlaşılma zorluğu da bulanık mantığın kuralları ile ortadan kaldırılarak anlaşır çıktılar elde edilebilmektedir.

Özellikle mühendislik alanında yaygın olarak uygulanan hibrit sistemler, sosyal bilimlerle ilgili konularda da geçmişten günümüze uygulama alanı bulabilmektedir. Bu yöntemler hem bulanık mantık ve yapay sinir ağlarının bağımsız olarak uygulandığı modellere göre daha iyi sonuçlar vermekte hem de bu iki yöntemin avantajlarını bir araya getirebilmektedir. Öte yandan farklı istatistik veya yapay zeka teknikleri ile karşılaştırmalı yapılan çalışmalar mevcuttur ve sonuçlar hibrit modellerin daha iyi öngörülerde bulunabildiğini göstermektedir.

Bulanık ve yapay sinir ağları ile yapılan hibrit yöntem yaklaşımının, diğer yapay zeka yöntemleri, tahmin modelleri, istatistiksel çıkarım metotları için de yapılabildiği bilinmektedir. Aynı zamanda farklı disiplinleri birbirine yaklaştıran hibrit (melez) çalışmaların gelecekte de araştırmacılar açısından ilgi çekeceği tahmin edilebilir. Sosyal bilimler alanında da özellikle mobil teknolojilerin ve internet kullanımının artması ile biriken verilerin analizinde bu yaklaşımlara ihtiyaç duyulacağı açıktır.

REFERENCES

- Abonyi, J. (2003) "Fuzzy Model İdentification", Fuzzy Model İdentification For Control, 87-164, Birkhauser, Boston.
- Akman, T, Yılmaz, C, Sönmez, Y. (2018) "Elektrik Yükü Tahmin Yöntemlerinin Analizi" Gazi Mühendislik Bilimleri Dergisi (GMBD), 4(3) , 168-175. Retrieved from https://dergipark.org.tr/tr/pub/gmbd/issue/41439/459112.
- Atalay, M. (2015) "Zaman Serilerinde Yapay Sinir Ağları ve Bulanık Mantığa Dayalı Tahmin ve Bir Uygulama" (Yayınlanmamış Doktora Tezi), İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Atsalakis, G.S., Atsalaki, Ioanna G., Pasiouras, Fotios, Zopounidis, Constantin (2019). "Bitcoin price forecasting with neuro-fuzzy techniques", European Journal of Operational Research, Volume 276, Issue 2, Pages 770-780.
- Atsalakis, G.S., Protopapadakis, E.E. & Valavanis, K.P. (2016) "Stock trend forecasting in turbulent market periods using neuro-fuzzy systems", Operational Research, Volume 16, Issue 2, pp 245–269.
- Bakirtzis A.G.; Theocharis J.B.; Kiartzis S.J.; Satsios K.J. (1995) "Short term load forecasting using fuzzy neural networks", IEEE Transactions on Power Systems, Volume: 10 , Issue: 3.
- Barnard, E. (1992) "Optimization For Training Neural Nets", IEEE Transactions On Neural Networks, 3 (2) , 232-240.
- Baykal, N., Beyan, T. (2004) Bulanık Mantık Uzman Sistemler ve Denetleyiciler, Bıçaklar Kitabevi, Ankara.
- Buckley, J. J., Hayashi, Y. (1994) "Fuzzy neural networks: A survey", Fuzzy Sets and Systems, Volume 66, Issue 1, 1994, Pages 1-13.
- Chang, P-C., Liu, C-H., Fan, C-Y. (2009) "Data clustering and fuzzy neural network for sales forecasting: A case study in printed circuit board industry", Knowledge-Based Systems, Volume 22, Issue 5, Pages 344-355.
- Chen, H.J., Huang, S.Y., Lin, C.S. (2009) "Alternative Diagnosis of Corporat Bankruptcy: A Neuro Fuzzy Approach", Expert Systems with Applications, Vol. 36, 7710-7720.
- Chen, T. (2019) "Neuro-fuzzy based Forecast Engine for Electric Load Prediction", International Research Journal of Applied and Basic Sciences, 13 (1): 30-47.
- Chou, C-C. & Lin, K-S. (2019) "A fuzzy neural network combined with technical indicators and its application to Baltic Dry Index forecasting", Journal of Marine Engineering & Technology, 18:2, 82-91, DOI: 10.1080/20464177.2018.1495886
- Chogumaira, E.N., Hiyama T. (2011) ''Short-term electricity price forecasting using a combination of neural networks and fuzzy inference,'' Energy and Power Engineering, vol. 3, pp. 9-16.
- Dash, P.K., Satpathy, H.P., Liew, A.C. (1998) "A RealTime Short-Term Peak and Average Load Forecasting System Using a Self-Organising Fuzzy Neural Network", Engineering Applications of Artificial Intelligence, Cilt 11, No 2, 307-316.

- De Campos Souza P.V., Torres L.C.B. (2018) "Regularized Fuzzy Neural Network Based on Or Neuron for Time Series Forecasting". In: Barreto G., Coelho R. (eds) Fuzzy Information Processing. NAFIPS 2018. Communications in Computer and Information Science, vol 831. Springer, Cham.
- Demirel, Ö , Kakilli, A , Tektaş, M . (2013) "ANFIS ve ARMA Modelleri ile Elektrik Enerjisi Yük Tahmini", Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 25 (3), https://dergipark.org.tr/tr/pub/gazimmfd/issue/6685/88585
- Durmuş, A. (2005) "Yapay Ve Bulanık Sinir Ağları İle Sistemlerin Modellenmesi" (Yayınlanmamış Yüksek Lisans Tezi), Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- García, F., Guijarro, F., Oliver, J., & Tamošiūnienė, R. (2018) "Hybrid fuzzy neural network to predict price direction in the German DAX-30 index". Technological and Economic Development of Economy, 24(6), 2161-2178. https://doi.org/10.3846/tede.2018.6394.
- Hou, Y., Zhao, L., Lu, H. (2018) "Fuzzy neural network optimization and network traffic forecasting based on improved differential evolution", Future Generation Computer Systems, Volume 81, Pages 425-432.
- Jacek, M.L. (2003) "Neuro-Fuzzy System With Learning Tolerant To Imprecision", Fuzzy Sets And Systems, 138, 427–439.
- Jang, J.-S.R. (1993) "ANFIS: Adaptive-Network-Based Fuzzy İnference System", Ieee Trans Syst Man Cybern, 23(3):665–685.
- Jang, J-S.R., Sun, C.-T., Mızutanı, E. (1997) Neuro-Fuzzy And Soft Computing: A Computational Approach To Learning And Machine Learning, Upper Saddle River, Prentice Hall.
- Katta, P., Hegde, N.P. (2019) "A Hybrid Adaptive Neuro-Fuzzy Interface and Support Vector Machine Based Sentiment Analysis on Political Twitter Data", International Journal of Intelligent Engineering and Systems, Vol.12, No.1, 165-173.
- Kodogiannis, V.S., Anagnostakis, E.M. (1999) "A Study of Advanced Learning Algorithms for STLF", Eng. App. of Artificial Intelligence, Cilt 12, No 2, 159-173.
- Kosko, B., Isaka, S.: (1993) "Fuzzy Logic", Scientific American Science, Vol. 1, No. 1, 76-81.
- Kuo R.J. (2001) "A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm", European Journal of Operational Research, Volume 129, Issue 3, Pages 496-517.
- Li, R., Xiong Z. (2005) "Forecasting Stock Market With Fuzzy Neural Networks", Machine Learning and Cybernetics, Proceedings of 2005 International Conference on Volume: 6.
- Lin, C-T., Lee, C.S.G.. (1994) "Reinforcement Structureparameter Learning For Neural-Network-Based Fuzzy Logic Control Systems", IEEE Transactions On Fuzzy Systems, Vol. 2, No. 1.
- Memmedova, N. (2012) "Süt Sığırlarında Mastitisin Bazı Yapay Zeka Yöntemleri Kullanılarak Erken Dönemde Tespiti" (Basılmamış Doktora Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Nauck, D., Kruse, R. (1994) "Choosing Appropriate Neuro-Fuzzy Models", In Proc. Second European Congress On Fuzzy And Intelligent Technologies (Eufıt'94), Aachen, Pp. 552-557.
- Obaidat, M., A., Obeidat, A., Al-Ghandoor, M., Gharaibeh, M. A. & Almomani, H. A. (2019) "Modelling energy consumption of the Jordanian transportation sector: the

application of multivariate linear regression and adaptive neurofuzzy techniques", International Journal of Sustainable Energy, 38:9, 814-820, DOI: 10.1080/14786451.2018.1563092

- Ok, Y., Atak, M., Akçayol, M. A. (2011) "Yalın Sinirsel Bulanık Bir Model İle İmkb 100 Endeksi Tahmini" Journal of the Faculty of Engineering & Architecture of Gazi University, Vol. 26 Issue 4, p. 897-904.
- Pal, S.S.& Kar, S. (2019) "A Hybridized Forecasting Method Based on Weight Adjustment of Neural Network Using Generalized Type-2 Fuzzy Set", International Journal of Fuzzy System, 21(1):308–320.
- Rast, M. (1999) "Forecasting with Fuzzy Neural Networks: A Case Study in Stock Market Crash Situations", 18th International Conference of the North American Fuzzy Information Processing Society - NAFIPS (Cat. No.99TH8397).
- Samanta, S., Suresh, S., Senthilnath, J., Sundararajand, N. (2019) "A new Neuro-Fuzzy Inference System with Dynamic Neurons (NFIS-DN) for system identification and time series forecasting", Applied Soft Computing, Volume 82, 105567.
- Srinivasan, D., Chang C.S., Liew A.C. (1995) "Demand forecasting using fuzzy neural computation, with special emphasis on weekend and public holiday forecasting", IEEE Transactions on Power Systems, Volume: 10, Issue: 4, 1897 – 1903.
- Tamimi, M., Egbert, R. (2000) "Short Term Electric Load Forecasting Via Fuzzy Neural Collaboration", Electric Power Systems Research, Cilt 56, 243-248.
- Tian F., Tian Ming, W., Yun, W. (2018) "Application of Wavelet Fuzzy Neural Network in Real Time Traffic Flow Forecasting", 2018 2nd IEEE Advanced Information Management,Communicates,Electronic and Automation Control Conference (IMCEC).
- Tortum A., Çodur, Y. (2007) "Sinirsel Bulanık Sistemler ile Trafik Gürültüsünün Tahmini", 7. Ulaştırma Kongresi, TMMOB İnşaat Mühendisleri Odası, İstanbul, 19-21 Eylül 2007.
- Vlasenko, A., Vlasenko, N., Vynokurova, O., Bodyanskiy, Y., & Peleshko, D. (2019) "A Novel Ensemble Neuro-Fuzzy Model for Financial Time Series Forecasting". Data, 4(3), 126.
- Yıldız, B., Akkoç, S. (2009) "Banka Finansal Başarısızlıklarının Sinirsel Bulanık Ağ Yöntemi İle Öngörüsü", BDDK Bankacılık Ve Finansal Piyasalar, Cilt:3, Sayı:1, S. 9-36.
- Zhang, D., Bai, X., Cai, K. (2004) "Extended Neuro-Fuzzy Models Of Multilayer Perceptrons", Fuzzy Sets And Systems, 142, 221–242