

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ANFIS VE BULANIK C-ORTALAMALAR
YÖNTEMLERİ TABANLI ÇOK KRİTERLİ
ENVANTER SINIFLANDIRMA MODELİ**

YÜKSEK LİSANS TEZİ

Elif İSEN

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Yrd. Doç. Dr. Mümtaz İPEK

Kasım 2017

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ANFIS VE BULANIK C-ORTALAMALAR
YÖNTEMLERİ TABANLI ÇOK KRİTERLİ
ENVANTER SINIFLANDIRMA MODELİ**

YÜKSEK LİSANS TEZİ

Elif İSEN

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

**Bu tez 27/12/2017 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile
Kabul edilmiştir.**

.....
Jüri Başkanı

.....
Üye

.....
Üye

BEYAN

Bu tezin yazılmasında bilimsel ahlak kurallarına uyulduđunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduđunu, kullanılan verilerde herhangi bir tahrifat yapılmadıđını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadıđını beyan ederim.

Elif İSEN

29.10.2017

TEŐEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Yrd. Doç. Dr. Mümtaz İpek'e ve Doç. Dr. Semra BORAN'a teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	vii
ÖZET.....	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
LİTERATÜR ARAŞTIRMASI.....	4
2.1. Çok Kriterli Envanter Sınıflandırma ile İlgili Literatür Çalışması	4
2.1.1. Matris tabanlı ABC envanter sınıflandırma çalışmaları.....	4
2.1.2. Çok kriterli karar verme yöntemleri kullanılarak yapılmış envanter sınıflandırma çalışmaları.....	5
2.1.3. Yapay zekâ tabanlı envanter sınıflandırma çalışmaları	5
2.1.4. Kümeleme tabanlı envanter sınıflandırma çalışmaları.....	6
2.1.5. Ağırlıklı doğrusal optimizasyon tabanlı envanter sınıflandırma çalışmaları	7
2.2. ANFIS ile İlgili Literatür Çalışması	9
2.3. Bulanık C-Ortalamlar ile İlgili Literatür Çalışması	10
2.4. Birleştirilmiş ANFIS ve FCM Algoritması Uygulamaları ile İlgili Literatür Çalışması	11

BÖLÜM 3.

MODEL OLUŞTURULURKEN KULLANILAN YÖNTEMLER.....	12
3.1. Bulanık Mantık.....	12
3.1.1. Bulanık mantık kavramı.....	12
3.1.2. Bulanık kümeler ve üyelik fonksiyonları.....	13
3.1.2.1. Üçgensel üyelik fonksiyonları.....	14
3.1.2.2. Yamuk üyelik fonksiyonları.....	14
3.2. Yapay Sinir Ağları.....	15
3.2.1. Yapay sinir ağlarının yapısı.....	15
3.2.2. Yapay sinir ağlarının eğitimi ve testi.....	16
3.2.3. Yapılarına göre yapay sinir ağları.....	17
3.3. Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS).....	17
3.3.1. ANFIS genel yaklaşımı.....	17
3.3.2. ANFIS mimarisi.....	18
3.3.3. ANFIS yapısındaki katmanlar.....	19
3.3.4. ANFIS öğrenme algoritması.....	20
3.3.5. ANFIS yönteminin avantajları.....	21
3.4. Bulanık c-Ortalamalar Kümeleme Yöntemi.....	23
3.4.1. Bulanık c-Ortalamalar Kümeleme Yöntemi Genel Yaklaşımı.....	23
3.4.2. Bulanık c-Ortalamalar Algoritması.....	23
3.4.3. Bulanık c-ortalamalar kümeleme yönteminin avantaj ve dezavantajları.....	25

BÖLÜM 4.

ANFIS ve BULANIK C-ORTALAMALAR YÖNTEMLERİ TABANLI ÇOK KRİTERLİ ENVANTER SINIFLANDIRMA UYGULAMASI.....	27
4.1. Uygulamanın Amacı.....	27
4.2. Verilerin Elde Edildiği İşletmenin Tanıtımı.....	29
4.3. Amaçlanan Modelin Uygulaması.....	30
4.3.1. Kullanılacak veri setinin oluşturulması.....	30
4.3.2. FCM algoritmasının optimize edilmesi.....	32
4.3.2.1. Verilerin normalize edilmesi.....	33

4.3.2.2. Farklı m değerleri için hata değerlerinin hesaplanması	34
4.3.3. FCM algoritması kullanılarak envanter kalemlerinin kümelenmesi	35
4.3.4. ANFIS sınıflandırma modelinin oluşturulması	37
4.3.4.1. Veri setinin hazırlanması.....	37
4.3.4.2. FIS parametrelerinin belirlenmesi	38
4.3.4.3. Üyelik fonksiyonu tipinin belirlenmesi	39
4.3.4.4. Modelin eğitilmesi	40
4.3.4.5. Bulanık kuralların oluşturulması	41
4.3.4.6. Model çıktılarının elde edilmesi	44
4.3.5. Yapay sinir ağları kullanılarak yeni bir tahmin modelinin oluşturulması	44
4.3.6. Amaçlanan hibrit model ve yapay sinir ağları modelinin performanslarının karşılaştırılması.....	46
BÖLÜM 5.	
SONUÇLAR.....	50
KAYNAKLAR.....	52
ÖZGEÇMİŞ	58

SİMGELER VE KISALTMALAR LİSTESİ

ANFIS	: Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
AHP	: Analitik Hiyerarşi Prosesi
ANP	: Analytic Network Proses (Analitik Ağ Süreci)
EDAS	: Evaluation based on distance from average solution (Ortalama sonuca olan uzaklığa bağlı değerlendirme)
ERP	: Kurumsal kaynak planlama
FCM	: Fuzzy c-means (Bulanık c-ortalamlar)
FIS	: Fuzzy inference system (Bulanık çıkarım sistemi)
GA	: Genetik algoritma
KM	: K-means (K-ortalamlar)
MgO-EG	: Etilen-Glikol
MRP	: Material requirements planning (Malzeme ihtiyaç planlaması)
MSE	: Ortalama hata kareler
PCA	: Principal components analysis (Temel bileşenler analizi)
PSO	: Parçacık sürü optimizasyonu
RMSE	: Ortalama hata kareleri kökü
RNA	: Ribo nükleik asit
TOPSIS	: Technique for order preference by similarity to ideal solution
YSA	: Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 3.1. Yapay sinir hücre yapısı.....	15
Şekil 3.2. 2 girdi, 1 çıktı ve 2 kuraldan oluşan örnek bir ANFIS yapısı.....	18
Şekil 4.1. MATLAB çalışma alanı.....	38
Şekil 4.2. Anfisedit ana komut penceresi.....	38
Şekil 4.3. Üyelik fonksiyonları (Gauss2mf)..	39
Şekil 4.4. Alternatif üyelik fonksiyonu tipleri.	40
Şekil 4.5. Verilerin eğitimi.....	41
Şekil 4.6. Bulanık Kurallar..	42
Şekil 4.7. Kural izleyici.....	43
Şekil 4.8. ANFIS yapısı.	43
Şekil 4.9. YSA MATLAB arayüzü.....	45
Şekil 4.10. Kullanılan parametreler.	46

TABLULAR LİSTESİ

Tablo 2.1. Literatür çalışması özeti	8
Tablo 3.1. Klasik Mantık-Bulanık Mantık Arasındaki Temel Farklılıklar.	13
Tablo 3.2. ANFIS Öğrenme Algoritması Detayları	21
Tablo 4.1. Veri Seti.	30
Tablo 4.2. Normalize edilmiş veriler	33
Tablo 4.3. Farklı m değerleri için hata değerleri.....	35
Tablo 4.4. Küme merkezleri.....	35
Tablo 4.5. Üyelik dereceleri ve kümeleme sonuçları.....	36
Tablo 4.6. Parametreler	39
Tablo 4.7. Üyelik fonksiyonları hata değerleri	40
Tablo 4.8. FCM-ANFIS ve YSA modellerinden elde edilen sonuçlar	47
Tablo 4.9. Eşik değerler	48
Tablo 4.10. Performans değerlendirme sonuçları	49

ÖZET

Anahtar kelimeler: ANFIS, FCM, Çok Kriterli Envanter Sınıflandırma

Günümüz imalat şartlarında, işletmelerin envanter yönetimini optimize etmenin en iyi yolu, envanterlerin sınıflandırılmasıdır. Bu ihtiyaç üzerine geliştirilmiş çok sayıda çok kriterli envanter sınıflandırma yöntemi mevcuttur. Fakat mevcut yöntemler uygulama zorluğu, kalitatif verilerle çalışamama ve öznellik içerme gibi pek çok açıdan eleştirilere maruz kalmaktadır. Mevcut yöntemlerde en sık karşılaşılan sorunlardan biri de, yeni bir envanter kalemi dahil edildiğinde sınıflandırma işleminin tekrar edilmesi zorunluluğudur.

Bu tez çalışmasında, yapay zeka yöntemlerinden faydalanılarak yeni bir çok kriterli envanter sınıflandırma modeli geliştirilmiştir. Bu hibrit model oluşturulurken Bulanık C-Ortalamlar (FCM) ve Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS) yöntemlerinden faydalanılmıştır. FCM ve ANFIS metotları pek çok kez bir araya getirilmiş fakat daha önce envanter sınıflandırma problemleri için kullanılmamıştır. Çalışma sonucunda; tahmin, öğrenme ve sınıflandırma yeteneğine sahip bir çok kriterli envanter sınıflandırma modeli geliştirilmiştir.

Bu model diğer modellerden farklı olarak, yeni bir envanter birimi dahil edildiğinde modelin tekrar oluşturulması zorunluluğunu ortadan kaldırmaktadır. Ayrıca, yine birçok modelden farklı olarak, bu model kantitatif verilerin yanı sıra, kalitatif verilerle de çalışabilmektedir. Bir firmadan elde edilen veriler ile geliştirilen modelin uygulaması yapılmıştır. Daha sonra aynı veri seti ile yapay sinir ağları kullanılarak yeni bir model oluşturulmuştur. Son olarak iki modelin performansları karşılaştırılmıştır.

MULTI-CRITERIA INVENTORY CLASSIFICATION MODEL BASED ON ANFIS AND FUZZY C-MEANS METHODS

SUMMARY

Keywords: ANFIS, FCM, Multi Criteria Inventory Classification

In today's manufacturing environment, the best way to optimize inventory management is classifying the inventories for enterprises. Upon this needs, a lot of multi criteria inventory classification methods are developed. However, each of these methods are criticized in many ways, such as; the difficulty of the application, not having capability of handling qualitative data, involving subjectivity. In addition, one of the most common problem is that, in most of the existing methods, when a new inventory item is stored in a warehouse, the classification process must be repeated.

In this study, a new multi criteria inventory classification model is generated by utilizing artificial intelligence (AI) techniques. By using Fuzzy C-Means (FCM) and Adaptive Neuro Fuzzy Inference Systems (ANFIS), a hybrid model is developed. For the first time, ANFIS and FCM methods are combined to solve multi criteria inventory classification problem. As a result of the study, multi criteria inventory classification model with ability of prediction, learning and classification, is generated.

The proposed model does not need to regenerate and solve whenever a new inventory item is introduced. At the same time, this model is capable of handling both quantitative and qualitative criteria. The model is applied to a real life data set that obtained from a company. Then a new model is generated by using Artificial Neural Network (ANN) method. The performance of the proposed model is verified by comparing with ANN model.

BÖLÜM 1. GİRİŞ

Envanter, gelecekte oluşabilecek talebi karşılamak amacıyla girişimcinin elinde bulundurduğu hammadde, yarı mamul, mamul ya da varlıklar olarak ifade edilir. Tüm işletme ve kuruluşlar, toplam varlıklarının önemli bir yerini tutan envanterlere ihtiyaç duyarlar. Finansal anlamda üretim firmalarının bilançolarında toplam varlıklarının %20 ile %60'ını envanterler oluşturmaktadır (Özdemir & Özveri, 2004).

İyi bir envanter yönetimi doğru bir envanter sınıflandırmasını ve uygun envanter modellerinden yararlanmayı gerektirmektedir. Envanter kontrol modelleri ve envanter sınıflandırma yöntemleri, 19. yüzyılın ikinci yarısından itibaren öncelikle büyük ölçekli global şirketlerin ihtiyaçlarına cevap vermek amacıyla geliştirilmiştir. 1940'larda Pareto prensibinin ilk defa envanter sınıflandırmada ABC analizi olarak uygulanmasının ardından bu yöntem hızla diğer şirketlere yayılmış ve günümüzde halen devam eden çok geniş bir kullanım alanına kavuşmuştur.

Envanter yönetiminde ABC analizi, stok kalemlerinin önem derecelerine göre sınıflandırılmasını sağlar ve bu sistemde ayrı önem derecelerine ait sınıflara ayrı envanter politikaları uygulanır. Geleneksel ABC analizinde, envanter yıllık toplam kullanım tutarı üzerinden en büyükten en küçüğe doğru sıralanır. Bu sıralama ve tutarlar yüzdesel olarak kümülatif halde yeniden yazılır.

Böylece üst sıralarda kalan az sayıda ancak kullanım tutarının büyük bir kısmını teşkil eden envanter, A sınıfı olarak belirlenir ve bu envanter en önemli envanter sınıfı olarak değerlendirilir (Flores ve Whybark. 1987). Bunun tersi olarak en alt sıralarında itibaren toplam kullanım tutarının az bir kısmını oluşturan çok sayıda envanter C sınıfı olarak belirlenir ve bunlar önceliksiz envanter olarak değerlendirilir ve envanter politikası olarak sıkı takip ve kontroller yerine çoğunlukla yüksek stok

miktarı ve düşük takip prensibi uygulanır. Arada kalan envanter ise orta önem sahip B sınıfı envanterdir ve orta öncelikli olarak değerlendirilir. Böylece A, B, C sınıfı envanterlere ayrı envanter politikası uygulanır (Flores ve diğ., 1992).

Oldukça yararlı ve kullanımı kolay olmasına rağmen, bu yöntemin yalnızca maliyete dayalı geleneksel sınıflandırma yaklaşımı oluşu ve diğer ölçütleri göz ardı etmesi, tek başına yetersiz bulunmasına neden olmuştur. Bunun üzerine envanterin temin süreleri, tedarikçileri, risk dereceleri gibi değişik ölçütlerini de dikkate alan çok kriterli envanter sınıflandırma modelleri geliştirilmiş ve uygulamalarda sıkça yer bulmuştur.

Tek kriterli analizlerde en önemli varsayım, olaydaki diğer kriterlerin etkilerinin sabit kabul edilmesi ve her defasında sadece bir kriterin inceleme konusu yapılmasıdır. Hâlbuki evrendeki olaylar ve objeler sadece tek bir kriterin etkisi ile değil, çok sayıda iç ve dış kriterlerin ortak etkisi ile oluşmakta ve karmaşık bir yapı göstermektedir. Bu nedenle, olaylar ve objeler sadece bir değişkene göre değil, çok sayıda değişkene ve bunların ortaklaşa etkilerine göre tanımlanmalıdır. Bu gerekçeden dolayı çok kriterli envanter sınıflandırma metotlarına sıklıkla başvurulmaktadır. Kullanım değeri, kullanım miktarı, ömrü, tedarik süresi, birim fiyatı, kritikliği, ikame edilebilirliği, boyutu gibi kriterler dikkate alınabilmektedir.

Geleneksel yöntemde göz önüne alınamayan kriterlerin çok kriterli yöntemlerde dikkate alınması esas önemli yenilik iken diğer yandan bu başka bir uygulamayı daha beraberinde getirmiştir. Bu yöntemlerin en iyi avantajları sadece kantitatif ve objektif değerlendirmelerin yapılması yerine, sınıflandırmada uzmanların ve yöneticilerinin de görüşlerini dikkate alabilmesidir. Zira birden fazla kriterin önem derecelerinin ve sınıflandırmaya etkilerinin belirlenmesinde bu değerlendirmelere ihtiyaç duyulmuştur. Çok kriterli sınıflandırmalarda matris tabanlı yöntemler, doğrusal optimizasyon yöntemleri, analitik hiyerarşi süreci ve sezgisel (yapay öğrenen) yöntemler kullanılmaktadır.

Bu çalışmada yapay zeka tekniklerinden yararlanılarak, çok kriterli envanter sınıflandırma problemlerinin çözümüne yönelik yeni bir hibrit model tasarlanmıştır. Bu model ANFIS ve FCM yöntemleri bir araya getirilerek geliştirilmiştir. FCM ve ANFIS metotları literatürdeki farklı alanlardaki çalışmalarda bir araya getirilmiştir. Fakat sınırlı araştırmamızda daha önce envanter sınıflandırma problemleri için kullanılmadığı görülmüştür.

Bulanık çıkarım sistemini optimize etmenin en iyi yolu FCM kümeleme yöntemi gibi yöntemlerle birleştirmektir (Abdulshahed ve diğ., 2015). Bu yüzden, FCM ve ANFIS metotları birleştirilerek, daha iyi ve hızlı öğrenebilen bir model elde edilmiştir.

ANFIS'in içinde yer alan yapay sinir ağları sayesinde, geliştirilen model sınıflandırmanın yanında tahmin edebilme özelliğine de sahiptir. Modelimiz diğer geliştirilen birçok envanter sınıflandırma modellerinden farklı olarak, yeni bir envanter dahil edildiğinde modelin tekrar oluşturulması zorunluluğunu ortadan kaldırmaktadır. Ayrıca, yine birçok modelden farklı olarak, bu model kantitatif verilerin yanı sıra, kalitatif verilerle de çalışabilmektedir.

Bir firmadan elde edilen veriler ile geliştirilen modelin uygulaması yapılmıştır. Daha sonra aynı veri seti ile yapay sinir ağları kullanılarak yeni bir model oluşturulmuştur. Son olarak iki modelin performansları karşılaştırılmıştır.

BÖLÜM 2. LİTERATÜR ÖZETİ

Bu bölümde kronolojik sıraya göre literatürde yer alan çok kriterli envanter sınıflandırma yöntemlerinin yanında, ANFIS ve FCM yöntemleri kullanılarak yapılmış sınıflandırma çalışmaları incelenmiştir.

2.1. Çok Kriterli Envanter Sınıflandırma ile İlgili Literatür Çalışması

Bu alanda yapılmış pek çok çalışma bulunmaktadır. En sık kullanılan yöntemler klasik ya da matris tabanlı ABC sınıflandırma yöntemi, çok kriterli karar verme yöntemleri ve yapay zekâ tabanlı yaklaşımlardır.

2.1.1. Matris tabanlı ABC envanter sınıflandırma çalışmaları

Matris esaslı yöntemlerden pek çok karar verme probleminde yararlanıldığı gibi çok kriterli sınıflandırmalarda da kriterlerin birbirlerine göre önceliklerinin belirlenmesinde yararlanılan yöntemler arasında yer almıştır. Bir önceliklendirme matrisi, pek çok kriter arasındaki önceliğin belirlenmesine yarar. Kullanım alanı oldukça yaygındır. Çok sayıda seçenek ya da kriter matris üzerine yerleştirilerek karşılaştırılır ve önem dereceleri belirlenir.

Flores ve arkadaşları 1986 yılında, matris temelli çok kriterli ABC sınıflandırma yöntemini kullanarak, envanter sınıflandırma modeli geliştirmişlerdir. Bu çalışmada iki kriter olarak envanterin toplam parasal kullanımı ve bir kriter matris formunda karşılaştırılmış ve önceliği belirlenmiştir.

2.1.2. Çok kriterli karar verme yöntemleri kullanılarak yapılmış envanter sınıflandırma çalışmaları

Parvoti ve Burton 1993 yılında, kalitatif ve kantitatif kriterlere sahip envanter sınıflandırma modeli geliştirmişlerdir. Bu modeli oluştururken analitik hiyerarşi süreci (AHP) yöntemini kullanmışlardır.

Bhattacharya ve arkadaşları 2007 yılında, mesafe tabanlı çok kriterli ABC analizi modeli geliştirmişlerdir. Bu modelin oluşturulmasında TOPSIS (technique for order preference by similarity to ideal solution) yönteminden faydalanmışlardır.

Çakır ve Canpolat 2008 yılında, bulanık AHP metodunu kullanarak, çok kriterli envanter sınıflandırmaya yönelik web tabanlı bir karar destek sistemi geliştirmişlerdir.

Hadi-Vencheh ve Mohamadghasemi 2011 yılında, AHP ve veri zarflama analizi yöntemlerini birleştirerek, çok kriterli ABC envanter sınıflandırma problemlerinin çözümü için yeni bir model geliştirmişlerdir.

Chen 2012 yılında, TOPSIS yönteminden faydalanarak alternatif bir çok kriterli envanter sınıflandırma modeli geliştirmiştir.

2.1.3. Yapay zekâ tabanlı envanter sınıflandırma çalışmaları

Erel ve Güvenir 1998 yılında, GA kullanarak çok kriterli envanter sınıflandırma modeli oluşturmuşlardır. Sonuçları AHP yöntemi ile kıyaslamışlar ve GA'nın AHP yönteminden daha iyi sonuç verdiğini gösteren sonuçlar elde etmişlerdir.

Partovi ve Anandarajan 2001 yılında, bir sınıflandırma probleminin çözümünde yapay sinir ağlarından (YSA) faydalanmışlardır. Dört kriterli bu sınıflandırma probleminin kriterleri; birim fiyat, sipariş maliyeti, talep oranı ve tedarik süresi olarak belirlenmiştir. Bu kriterler YSA'nın girdi değerleri olarak alınmıştır. YSA'nın

ürettiği çıktılar sınıflandırma sonuçları olarak A,B ya da C sınıfı şeklinde atanmıştır. Modelin performansı başarılı olarak değerlendirilmiştir.

Lei ve arkadaşları 2005 yılında, ABC envanter sınıflandırmaya yönelik iki metot geliştirmişlerdir. İlk metot temel bileşenler analizi (principal components analysis (PCA)) tabanlı envanter sınıflandırma yöntemidir. İkinci metot, PCA ve YSA yöntemlerinin birleşimi olan hibrit bir yöntemdir.

Chu ve arkadaşları 2008 yılında, ABC analizi ve bulanık sınıflandırma yöntemlerinin birleşimi olan yeni bir envanter kontrol yaklaşımı geliştirmişlerdir.

Tsai ve Yeh 2008 yılında, parçacık sürü optimizasyonu (PSO) yaklaşımını kullanarak, envanter kalemlerinin sınıflandırıldığı bir model geliştirmişlerdir.

Rezaei ve arkadaşları 2010 yılında, çok kriterli envanter sınıflandırma problemlerinin çözümüne yönelik, bulanık kural tabanlı bir model geliştirmişlerdir. Modelin dört kriteri; birim fiyat, yıllık talep, temin süresi ve dayanıklılık olarak belirlenmiştir.

Kiriş 2013 yılında, bulanık analitik ağ süreci (ANP) yaklaşımını kullanarak kriterleri ağırlıklandırarak, çok kriterli envanter sınıflandırma modeli geliştirmiştir.

Kabir ve Hasin 2013 yılında, AHP yöntemi ve YSA'yı birleştirerek çok kriterli envanter sınıflandırma modeli geliştirmişlerdir.

2.1.4. Kümeleme tabanlı envanter sınıflandırma çalışmaları

Cohen ve Ernst 1988 yılında, birçok farklı özellikteki envanter birimlerini sınıflandırmaya yönelik, istatistiksel kümeleme tabanlı bir model geliştirmişlerdir. Fakat bu modele yeni bir envanter birimi eklendiğinde, modelin tekrar oluşturulması gerektiğinden, model kullanıma elverişli bulunmamıştır.

Lolli ve arkadaşları 2014 yılında yaptıkları çalışmalarında, çok kriterli envanter sınıflandırma işlemi için, AHP ve K-ortalamar algoritmasını birleştirmiş, böylelikle kümeleme işlemini daha objektif hale getirmeyi hedeflemişlerdir.

2.1.5. Ağırlıklı doğrusal optimizasyon tabanlı envanter sınıflandırma çalışmaları

Basit ağırlıklı doğrusal optimizasyonun çok kriterli ABC sınıflandırmasında kullanılması ilk olarak Ramanathan'ın 2006 yılında yaptığı bir çalışmada bir model olarak önerilmiştir. Bu çalışmada veri zarflama analizine benzer bir yaklaşımla basit ağırlıklı doğrusal programlama ile ABC analizi gerçekleştirilmiştir. Fakat tıpkı istatistiksel kümeleme yöntemleri gibi bu yöntemde de, yeni bir envanter kalemi eklendiğinde model tekrar oluşturulmak zorundadır.

Daha sonra bu çalışmayı temel alan başka çalışmalar bu modele çeşitli eklentiler yaparak yeni model önerilerinde bulunmuşlardır. Zhou ve Fan 2006 yılında, geliştirdikleri modelde; N envanter kaleminin, A, B, C sınıflarına ayrılmasında J adet kriter olduğunu varsaymışlardır. Bu sınıflandırmada, m. envanterin j. kriter açısından etkisi tespit edilmeye çalışılmıştır. Tüm kriterler açısından, elde edilecek puanlara göre sınıflandırmalar gerçekleştirilmiştir.

Zhou ve Fan'dan sonra basit ağırlıklı doğrusal optimizasyon yöntemine dayalı bir model önerisi de Ng tarafından 2007'de yapılmıştır. Bu modelde diğerlerinden farklı olarak karar vericilerden kriterler arasında yalnızca önemine göre bir sıralama yapmaları beklenmektedir. Bir ağırlık belirlenmesi istenmemekte ve gerekmemektedir. Bu model Ramanathan'ın modeline alternatif bir ağırlıklı doğrusal optimizasyon modeli önermekte iken, çözüm yaklaşımını daha da basitleştirmeyi hedeflemiştir.

Ng'nin çalışması kısıtlar değiştirilerek Hadi-Vencheh tarafından 2010 yılında iyileştirilmiştir ve elde edilen sınıflandırma sonuçlarının önceki modellerden daha iyi olduğu iddia edilmiştir. Geliştirilen yeni model HV modeli olarak isimlendirilmiştir.

Park ve arkadaşları 2014 yılında, çok kriterli envanter sınıflandırma problemlerinin çözümüne yönelik, çapraz değerlendirme tabanlı ağırlıklı lineer optimizasyon modeli geliştirmişlerdir.

Soylu ve Akyol 2014 yılındaki çalışmalarında UTADIS metodunu kullanarak, karar vericilerin önceliklerini göz önünde bulunduran yeni bir çok kriterli envanter sınıflandırma modeli geliştirmişlerdir.

Ketkar ve Vaidya 2014 yılında, basit toplamsal ağırlıklandırma metodunu kullanarak çok kriterli envanter sınıflandırma modeli geliştirmişlerdir.

Hatefi ve Torabi 2015 yılında, HT modeli adını verdikleri yeni bir çok kriterli envanter sınıflandırma modeli geliştirmişlerdir. Bu model ağırlıklı lineer optimizasyon yönteminden faydalanılarak oluşturulmuştur.

Ghorabae ve arkadaşları 2015 yılında, EDAS (Evaluation based on Distance from Average Solution) adını verdikleri çok kriterli karar verme yöntemini kullanarak ABC envanter sınıflandırma modeli geliştirmişlerdir.

Çok kriterli envanter sınıflandırmaya yönelik farklı yöntemler kullanılarak geliştirilen modeller Tablo 2.1.'de özetlenmiştir.

Tablo 2.1. Literatür çalışması özeti

Yöntemler	Yazar
Matris Tabanlı Yöntemler	Flores ve ark.,1986
	Parvoti ve Burton, 1993
Çok Kriterli Karar Verme	Bhattacharya ve ark., 2007
	Çakır ve Canpolat, 2008
Tabanlı Yöntemler	Hadi-Vencheh ve Mohamadghasemi, 2011
	Chen, 2012

Tablo 2.1. (Devamı)

	Erel ve Güvenir, 1998
	Partovi ve Anandarajan, 2001
	Lei ve ark., 2005
Yapay Zekâ	Chu ve ark., 2008
Tabanlı Yöntemler	Tsai ve Yeh, 2008
	Rezaei ve ark., 2010
	Kiriş, 2013
	Kabir ve Hasin, 2013
Kümeleme	Cohen ve Ernst, 1988
Tabanlı Yöntemler	Lolli ve arkadaşları, 2014
	Ramanathan, 2006
	Zhou ve Fan, 2006
	Ng, 2007
Ağırlıklı Doğrusal	Hadi-Vencheh, 2010
Optimizasyon	Park ve ark., 2014
Tabanlı Yöntemler	Soylu ve Akyol, 2014
	Ketkar ve Vaidya, 2014
	Hatefi ve Torabi, 2015
	Ghorabae ve ark., 2015

2.2. ANFIS ile İlgili Literatür Çalışması

Daha önce bahsedildiği gibi, ANFIS yöntemi kullanılarak yapılmış çok kriterli envanter sınıflandırma çalışmasına literatürde rastlanmamıştır. Fakat ANFIS yöntemi en çok kullanılan yapay zekâ tekniklerinin başında gelmektedir.

Son yıllarda ANFIS yöntemi tahmin (Sangaiah ve ark., 2015; Chen ve ark., 2011; Dariane ve Azimi, 2014; Yuan ve ark., 2014; Sarkheyli ve ark., 2015; Barak ve ark., 2015), kontrol (Wali ve ark., 2012 ve Erkal, 2009), hata belirleme (Zheng ve ark., 2011 ve proje değerlendirme (Sarac, 2012) problemlerinde kullanılmıştır.

Ayrıca ANFIS yöntemi sınıflandırma problemlerinde de kullanılmaktadır. Güler ve Ubeyli 2005 yılında, elektroansefalogram sinyallerinin sınıflandırmasında ANFIS yönteminden faydalanmışlardır. Oluşturulan ANFIS sınıflandırma modelinin eğitim

performansı ve sınıflandırma başarısı ile performans değerlendirilmiş ve oldukça başarılı bir sonuç elde edilmiştir.

Wu ve Kuo 2010 yılında, bir motorlu jeneratörde oluşabilecek hataların sınıflandırılmasında ANFIS yönteminden faydalanmışlardır.

Zapata ve arkadaşları 2010 yılında, kaynak yapma işlemi sırasında meydana gelen hataların sınıflandırılması için ANFIS yöntemini kullanmışlardır.%84 oranında sınıflandırma başarısı elde etmişleridir.

Doğantekin ve arkadaşları 2013 yılında, Entropi ve ANFIS adını verdikleri yeni bir model geliştirmişlerdir. Bu model RNA virüslerinin sınıflandırılmasında kullanılmıştır.

Chung ve arkadaşları 2014 yılında, ANFIS yöntemini, kısmi boşalma ölçümünde kullanılan 74 istatistiksel değerlendirme ölçütünün sınıflandırılmasında kullanmışlardır. Çalışma sonucunda ANFIS yönteminin sınıflandırma başarısı %91,5 olarak bulunmuştur.

Tuna ve Karaca 2015 yılında yaptıkları çalışmalarında, firmaların sermaye artırımını etkileyen faktörleri belirlemeyi amaçlamışlardır. Çalışmanın ilk adımında, panel veri analizi yöntemi kullanılarak sermaye artırımını etkileyen 5 oran belirlenmiştir. İkinci adım olarak ANFIS yöntemi ile sınıflandırma yapılarak sonuçlar karşılaştırılmıştır. Sonuç olarak, sermaye artırım kararını etkileyen ve panel veri analizi ile belirlenen değişkenler ANFIS yönteminde de anlamlı bulunmuştur.

2.3. Bulanık C-Ortalamalar ile İlgili Literatür Çalışması

Literatürde bulanık c-ortalamar (fuzzy c-means – FCM) algoritması kullanılarak yapılmış pek çok çalışma bulunmaktadır. Bu algoritma kullanım kolaylığı ve başarılı performansı sayesinde diğer kümeleme algoritmalarından daha öne çıkmayı başarmıştır.

FCM algoritması birçok farklı alanda kümeleme amaçlı kullanılmıştır (Bulut ve İstanbullu, 2004; Hekim ve Orhan, 2011; Kannan ve ark., 2013; Keskin ve Özkan, 2013; Çelikalça ve ark., 2014; Soner ve ark., 2015; Verma ve ark., 2015; Kim ve ark., 2016).

Keskin ve Özkan 2013 yılında, FCM yöntemini kullanarak çok kriterli ABC sınıflandırma problemine çözüm üreten bir model geliştirmişlerdir. Çalışmaya göre, FCM yöntemi envanter sınıflandırma problemlerinde kolaylıkla kullanılabilir.

2.4. Birleştirilmiş ANFIS ve FCM Algoritması Uygulamaları ile İlgili Literatür Çalışması

Fariman ve arkadaşları 2015 yılında, birleştirilmiş ANFIS ve FCM yöntemlerini kullanarak protez el ile yapılabilecek hareketleri sınıflandırmışlardır. Ayrıca aynı veriler ile YSA modeli de oluşturulup sonuçları karşılaştırmışlardır. ANFIS-FCM modelinden çok daha üstün sınıflandırma performansı elde etmişlerdir.

Abdulshaded ve arkadaşları 2015 yılında, FCM yöntemini kullanarak termal görüntü kamerasından elde edilen termal hataları sınıflandırmış, daha sonra bu sınıflandırma sonuçları ile ANFIS tahmin modeli oluşturmuşlardır. Bu modelin tahmin yeteneği YSA modeli oluşturularak değerlendirilmiştir.

Kaur ve ark. 2015 yılında, Bombay borsasının çok boyutlu borsa fiyatlarının sınıflandırılması ve tahmini için birleştirilmiş ANFIS-FCM yönteminden faydalanmışlardır.

Adio ve arkadaşları 2016 yılında, nano sıvı olan etilen-glikol'ün (MgO-EG) etkili viskozite edilmesi için ANFIS-FCM yöntemini kullanmışlardır. ANFIS ve FCM yöntemleri özellikle son yıllarda literatürde pek çok kez birlikte kullanılmış olmasına rağmen, bu yöntemler çok kriterli envanter sınıflandırma amacıyla daha önce birlikte kullanılmamıştır. FCM ve ANFIS metotları birleştirilerek daha iyi ve hızlı öğrenebilen bir model elde edilmiş ve bulanık çıkarım sistemi optimize edilmiştir.

BÖLÜM 3. MODEL OLUŞTURULURKEN KULLANILAN YÖNTEMLER

3.1. Bulanık Mantık

3.1.1. Bulanık mantık kavramı

Bulanık mantık, bulanık eseme ya da puslu mantık, 1965 yılında Lotfi A. Zadeh'in yayınladığı bir makalenin sonucu oluşmuş bir mantık yapısıdır (Zadeh, 1965). Bulanık mantığın temeli bulanık küme ve alt kümelere dayanır. Klasik yaklaşımda bir varlık ya kümenin elemanıdır ya da değildir. Matematiksel olarak ifade edildiğinde varlık küme ile olan üyelik ilişkisi bakımından kümenin elemanı olduğunda "1", kümenin elemanı olmadığı zaman "0" değerini alır. Klasik kümelerin aksine bulanık kümelerde elemanların üyelik dereceleri $[0, 1]$ aralığında sonsuz sayıda değişebilir. Bunlar üyeliğin derecelerinin devamlı ve aralıksız bütünüyle bir kümedir.

Keskin kümelerdeki soğuk-sıcak, hızlı-yavaş, aydınlık-karanlık gibi ikili değişkenler, bulanık mantıkta biraz soğuk, biraz sıcak, biraz karanlık gibi esnek niteleyicilerle yumuşatılarak gerçek dünyaya benzetilir. En önemli fark, böyle bir çatıda bilginin kaynağındaki küme üyeliğinin kesin tanımlanmış önkoşullarının olmayışı ve daha çok sorunlarla rastgele değişkenlerin hazır bulunmasındadır. Klasik mantık ile bulanık mantık arasındaki temel farklılıklar Tablo 3.1.' de gösterilmektedir.

Tablo 3.1. Klasik Mantık-Bulanık Mantık Arasındaki Temel Farklılıklar (Zadeh, 2009)

Klasik Mantık	Bulanık Mantık
A veya A Değil	A ve A Değil
Kesin	Kısmi
Hepsi veya Hiçbiri	Belirli Derecelerde
0 veya 1	0 ve 1 Arasında Süreklilik
İkili Birimler	Bulanık Birimler

Bulanık mantık kontrollü bir modeli dört adımda oluşturmak mümkün olmaktadır:

1. Sistem için girdi değişkenlerinin ve değişim aralıklarının belirlenmesi,
2. Sistem için çıktı değişkenlerinin ve değişim aralıklarının belirlenmesi,
3. Her girdi-çıktı değişkeni için üyelik fonksiyonlarının belirlenmesi,
4. Sistemin çıktı değişkenleri üzerine bir kural tabanının oluşturulması.

Günümüzde bulanık mantık; otomatik kontrol sistemleri, robotik, otomasyon, akıllı denetim, izleme sistemleri, bilgi sistemleri, görüntü tanımlama, optimizasyon vb. gibi birçok alanda kullanılmaktadır.

3.1.2. Bulanık kümeler ve üyelik fonksiyonları

Eğer $A, R \in (-\infty, +\infty)$ 'da, söz konusu kümenin bir elemanı ise $\mu_A(x)$ üyelik fonksiyonu $R \rightarrow [0,1]$ aralığında oluşur. Diğer bir deyişle A kümesi $A = [a_1, a_3]$ aralığında ise genel olarak $\mu_A(x)$ üyelik fonksiyonu (3.1) formülüyle gösterilebilir.

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ 1, & a_1 \leq x \leq a_3 \\ 0, & x > a_3 \end{cases} \quad (3.1)$$

Pek çok üyelik fonksiyonu bulunmaktadır. Burada sadece üçgensel üyelik fonksiyonları ve yamuk üyelik fonksiyonları gösterilmektedir.

3.1.2.1. Üçgensel üyelik fonksiyonları

$\mu_A(x)$ üçgensel üyelik fonksiyonu, (3.2) formülünde tanımlanmıştır (Kaufmann, Meierb, & Stoffelc, 2015)

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x-a_1}{a_2-a_1}, & a_1 \leq x \leq a_2 \\ \frac{a_3-x}{a_2-a_1}, & a_2 \leq x \leq a_3 \\ 0, & x > a_3 \end{cases} \quad (3.2)$$

Bu formülüne göre küme, $A = (a_1, a_2, a_3)$ olmalıdır. Burada a_2 normal değerli üyelik olarak tanımlanabilir. Bulanık Mantık bu noktada bir α katsayısına bağlı olarak a_2 'ye yakın değerlerin, bu değere yüklenen anlam ile temsil edileceğini varsaymaktadır. Diğer bir deyişle a_2 'deki belirsizlik, varsayılacak ya da dağılıma göre bulunabilecek bir α katsayısı ile tolere edilebilir.

3.1.2.2. Yamuk üyelik fonksiyonları

Eğer bulanık mantık sayılarına ilişkin kümede normal kabul edilen iki değer varsa diğer bir deyişle küme, $A=(a_1, a_2, a_3, a_4)$ şeklinde dört belirleyici değerden oluşuyorsa bu durumda üyelik fonksiyonu yamuk üyelik fonksiyonu tipinde oluşacaktır.

Yamuk üyelik fonksiyonu (3.3) formülünde gösterilmiştir.

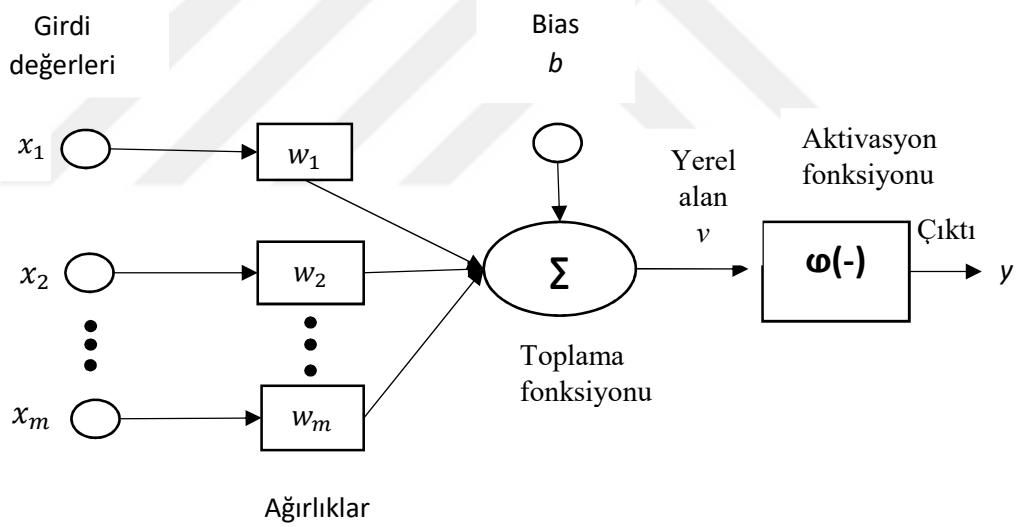
$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x-a_1}{a_2-a_1}, & a_1 \leq x \leq a_2 \\ 1, & a_2 \leq x \leq a_3 \\ \frac{a_4-x}{a_4-a_3}, & a_3 \leq x \leq a_4 \\ 0, & x > a_4 \end{cases} \quad (3.3)$$

3.2. Yapay Sinir Ağları

3.2.1. Yapay sinir ağlarının yapısı

Yapay sinir ağları (YSA), insan beyninin bilgi işleme tekniğinden esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. YSA ile basit biyolojik sinir sisteminin çalışma şekli taklit edilir. Taklit edilen sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler.

Yapay sinir ağları başlıca; sınıflandırma, modelleme, tahmin ve örüntü tanıma uygulamaları olmak üzere, pek çok alanda kullanılmaktadır (Ameli, & Birjandi, 2012).



Şekil 3.1. Yapay sinir hücre yapısı

Şekil 3.1.'de görünen yapay sinir hücresinin dendritleri x_m ve her bir dendritin ağırlık katsayısı (önemlilik derecesi) w_m ile belirtilmiştir. Böylece x_m girdi sinyallerini, w_m ise o sinyallerin ağırlık katsayılarının değerlerini taşımaktadır. Çekirdek (Bias) ise tüm girdi sinyallerinin ağırlıklı toplamalarını elde etmektedir. Tüm bu toplam sinyal v ile gösterilmiş ve sinapsise aktivasyon fonksiyonuna girdi

olarak yönlendirilmiştir. Sinapsis üzerindeki aktivasyon fonksiyonundan çıkan sonuç sinyali y ile belirtilmiş ve diğer hücreye beslenmek üzere yönlendirilmiştir.

3.2.2. Yapay sinir ağlarının eğitimi ve testi

Yapay sinir hücresinin görevi kısaca; x_m girdi örüntüsüne karşılık y çıktısı sinyalini oluşturmak ve bu sinyali diğer hücrelere iletmektir. Her x_m ile y arasındaki korelasyonu temsil eden w_m ağırlıkları, her yeni girdi örüntüsü ve çıktı sinyaline göre tekrar ayarlanır. Bu ayarlama süreci öğrenme olarak adlandırılır. Öğrenmenin tamamlandığının belirtilebilmesi için; girdi örüntüleri, w_m ağırlıklarındaki değişim stabilize olana dek sistemi beslemektedir. Stabilizasyon (durağanlık) sağlandığı zaman hücre öğrenmesini tamamlanmıştır.

Yapay sinir ağlarının öğrenme sürecinde de dış ortamdan girişler alınır, aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Bu çalışma süresince yenilenen yapay sinir ağının ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilenecek amaca ulaşmaya çalışılır. Eğer yapay sinir ağı verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenecek istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir.

YSA sistemlerinin problemi öğrenme başarısı, gerçekleştirilen testlerle sınanmalıdır. Test işlemi için, eğitim setinde kullanılmayan verilerden oluşan test seti kullanılır. Test setindeki girdiler YSA modeline verilir ve YSA'nın çıktı değeri ile istenilen çıktı değeri karşılaştırılır. Amaç, YSA modelinin yeterli bir genelleme yapıp yapamadığını görmektir. Eğitim ve test aşamalarında istenilen başarı elde edilirse YSA modeli kullanılabilir. YSA'nın performansı, k farklı YSA'nın test sonuçlarının ortalaması ile ölçülür.

3.2.3. Yapılarına göre yapay sinir ağları

Yapılarına göre yapay sinir ağları ileri beslemeli ağlar ve geri beslemeli ağlar olmak üzere ikiye ayrılır.

İleri beslemeli ağlarda nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir. Bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır. Yapay sinir ağına gelen bilgiler giriş katmanına daha sonra sırasıyla ara katmanlardan ve çıkış katmanından islenerek geçer ve daha sonra dış dünyaya çıkar.

Geri beslemeli yapay sinir ağlarında ileri beslemeli olanların aksine bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir nörona girdi olarak bağlanabilir. Bu yapısı ile geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir davranış göstermektedir. Geri besleme özelliğini kazandıran bağlantıların bağlantı sekline göre geri aynı yapay sinir ağıyla farklı davranışta ve yapıda geri beslemeli yapay sinir ağları elde edilebilir (Cemil, 2015).

3.3. Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS)

3.3.1. ANFIS genel yaklaşımı

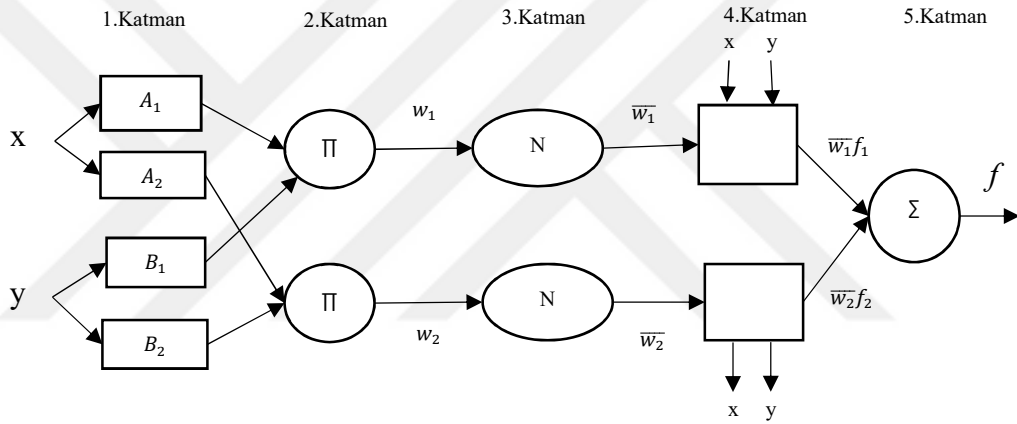
1993 yılında Jang tarafından geliştirilen ANFIS yöntemi, temel olarak Bulanık Çıkarım Sistemi'nin (Fuzzy Inference System-FIS) adaptif ağlara uyarlanmış halidir. Melez öğrenme algoritması ile birlikte ANFIS, bulanık eğer-ise kuralları ile insan bilgisini yansıtan girdi çıktı yapısını ortaya koymaktadır.

Yöntemin çıkış noktası, insan düşünce ve bilgisini yansıtan bulanık eğer-ise kurallarının avantajı ile sinirsel ağların öğrenme yeteneklerini bir araya getirerek entegre etkili bir çözüm sunma gereksinimidir.

3.3.2. ANFIS mimarisi

Yapı bakımından ANFIS, bulanık çıkarım sistemindeki eğer-ise kuralları ve giriş çıkış bilgi çiftlerinden oluşur. Sistem eğitiminde yapay sinir ağı öğrenme algoritmaları kullanılır.

Burada ANFIS yapısını basit bir şekilde anlatabilmek için örnek olarak iki kurallı ve iki girdili bir ANFIS yapısı verilmiştir (Şekil 3.2.). Düğümlerin 4. katmana kadar ileri gidişlerinde soncul parametreler en küçük kareler yöntemi ile belirlenmekte, geriye doğru gidişte ise bu sefer öncül parametreler gradyent azaltım yöntemi ile belirlenmektedir.



Şekil 3.2. 2 girdi, 1 çıktı ve 2 kuraldan oluşan örnek bir ANFIS yapısı

Şekil 3.2.'de gösterilen ANFIS modeli 2 girdi, 1 çıktı değeri ve 2 kuraldan oluşmaktadır.

Kural 1: Eğer x değeri A_1 ve y değeri B_1 ise,

$$f_1 = p_{1x} + q_{1y} + r_1 \quad (3.4)$$

Kural 2: Eğer x değeri A_2 ve y değeri B_2 ise,

$$f_2 = p_{2x} + q_{2y} + r_2 \quad (3.5)$$

Burada ANFIS yapısını basit bir şekilde anlatabilmek için örnek olarak iki girişli ve tek çıkışlı bir ANFIS yapısı verilmiştir. A ve B, x ve y üyelik fonksiyonları için tanımlanmış öncül kısımdaki bulanık kümeler; p, q ve r ise soncul parametrelerdir. Böylece her bir kural için bir çıktı değeri elde edilir.

3.3.3. ANFIS yapısındaki katmanlar

Şekil 3.2.'de görülebileceği gibi ANFIS yapısı 5 katmandan oluşmaktadır. ANFIS yapısındaki her katmana ait düğüm işlevleri ve katmanların işleyişi sırasıyla şöyledir (Hocaoğlu & Kurban, 2005):

1. Katman: Bulanıklaştırma: Bulanıklaştırma katmanı olarak adlandırılır. Giriş değerlerini bulanık kümelere ayırmada Jang'ın ANFIS modeli, üyelik fonksiyonu şekli olarak geliştirilmiş Bell aktivasyon fonksiyonunu kullanmaktadır. Burada, her bir düğümün çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır ve 2. katmandan elde edilen üyelik dereceleri $\mu_{Ai}(x)$ ve $\mu_{Bi}(y)$ şeklinde gösterilir. Üçgensel üyelik fonksiyonu, geliştirilmiş çan eğrisi üyelik fonksiyonu ve gauss üyelik fonksiyonu gibi birçok üyelik fonksiyonu mevcuttur.

2. Katman: Kural oluşturma: Kural katmanıdır. Bu katmandaki her bir düğüm, Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve sayısını ifade etmektedir. Her bir kural düğümünün çıkışı μ_i , ikinci katmandan gelen üyelik derecelerinin çarpımı olmaktadır. μ_i değerlerinin elde edilişi ise, (j=1,2) ve (i=1,...,n) olmak üzere,

$$y_i^3 = \prod_{j=1}^2 \mu_{Aj}(x) \times \mu_{Bi}(y) = \mu_i \quad (3.6)$$

şeklindedir. Burada, y_i^3 , üçüncü katmanın çıkış değerlerini; n ise, bu katmandaki düğüm sayısını ifade etmektedir.

3. Katman: Normalizasyon: Normalizasyon katmanıdır. Bu katmandaki her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul etmekte ve her bir kuralın normalleştirilmiş ateşleme seviyesini hesaplamaktadır. Normalleştirilmiş ateşleme seviyesi $\bar{\mu}_i$ 'nin hesaplanması ise,

$$y_i^4 = N_i = \frac{\mu_i}{\sum_{i=1}^n \mu_i} = \bar{\mu}_i \quad , \quad (i=1,n) \quad (3.7)$$

formülüne göre gerçekleştirilir.

4. Katman: Berraklaştırma: Bu katman berraklaştırma katmanıdır. Bu katmanda yer alan her düğüm kare düğümdür ve adaptiftir. Katmanda bulunan her bir düğümden verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanır. Bu katmanda yer alan parametreler sonuç parametreleri olarak adlandırılır.

5. Katman: Toplama: Toplam katmanıdır. Bu katmanda sadece bir düğüm vardır ve Σ ile etiketlenmiştir. Burada, beşinci katmandaki her bir düğümün çıkış değeri toplanarak sonuçta, ANFIS sisteminin gerçek değeri elde edilir.

Sistemin çıkış değeri olan y 'nin hesaplanması ise,

$$y = \sum_{i=1}^n \bar{\mu}_i [p_i x_1 + q_i x_2 + r_i] \quad (3.8)$$

formülüne göre olmaktadır.

3.3.4. ANFIS öğrenme algoritması

ANFIS mimarisinin işleyişinde görüldüğü üzere, giriş değişkenleri ve sonuç değişkenlerinin değerlerinin bilinmesi önem taşımaktadır. ANFIS'in öğrenme algoritması, hem giriş değişkenlerini hem de sonuç değişkenlerini optimize etmektedir. Söz konusu öğrenme işlemi gerçekleşirken ANFIS melez öğrenme

algoritmasını kullanmaktadır. Melez öğrenme algoritması, en küçük kareler yöntemi ile geri yayımlı öğrenme algoritmasının bir arada kullanılmasından oluşmaktadır.

Melez öğrenme algoritması, ileri besleme ve geri besleme olmak üzere iki kısımdan oluşmaktadır. İleri beslemede, giriş parametreleri sabit alınarak sonuç parametrelerinin değerleri en küçük kareler yöntemi ile hesaplanırken, geri beslemede ise sonuç parametreleri sabit alınarak giriş parametreleri geri yayımlı öğrenme algoritması ile hesaplanmaktadır.

Tablo 3.2. ANFIS Öğrenme Algoritması Detayları

Melez Öğrenme Algoritması	İleri Besleme	Geri Besleme
Giriş Parametreleri	Sabit	Geri Yayımlı Öğrenme
Sonuç Parametreleri	En Küçük Kareler Yöntemi	Sabit

Buradaki ileri besleme ve geri besleme işleyiş döngüsü, tüm sistem hatası belirlenen bir hata değerinden küçük olana kadar veya fazla bir değişim göstermeyinceye kadar devam etmektedir. Hesaplanacak olan hata değeri ise, hata kareler ortalamasının karekök değerine bir anlamda sistemin standart sapma değerine eşit olmaktadır.

Hata kareler ortalamasının karekök değeri (RMSE) formülü aşağıdaki gibidir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - f_i^*)^2} \quad (3.9)$$

Formülde f_i gerçek değerleri, f_i^* ANFIS'den elde edilen değerleri, n ise örnek büyüklüğünü göstermektedir (Saraç, 2012).

3.3.5. ANFIS yönteminin avantajları

Uyarlanır ağ yapısı işleyişi sayesinde ANFIS yöntemi, hem sistem hakkındaki çevresel bilgiyi kullanarak, hem de sisteme ilişkin giriş çıkış verisinden faydalanarak kendi kendini güncelleme yeteneği edinmiştir. Ayrıca ANFIS, sayısal gruplandırma ve kural koyma gibi gelişmiş veri analiz teknikleri içermektedir.

Doğrusal olmayan bir sistemin modellenmesinde izlenebilecek bir yöntem, yerel doğrusal modeller elde edip birleştirmek yerine doğrudan doğrusal olmayan bir model yapısı kullanmaktır. ANFIS, hem bulanık mantık sistemlerinin, hem de yapay sinir ağlarının üstünlüklerini birlikte bulunduran bir yöntemdir.

Sinir ağları ile mevcut bilgiyi değerlendirme zorluğu bulanık mantığın sözel terimleri ve eğer–ise kuralları ile ortadan kaldırılmıştır. Bu sayede anlaşılması kolay ve sözel dille ifade edilebilen çıktılar elde edilebilmektedir. Bulanık mantığa sinirsel ağlar ile öğrenme yeteneği kazandırılabilir. Her kural tabanlı bulanık sisteme bir sinir ağı ile yaklaşım sağlanabilmektedir. Benzer şekilde her sinir ağına da kural tabanlı bulanık sistemler ile yaklaşım sağlanabilmektedir.

Sinirsel bulanık sistemlerde bulanık sistemin esneklik, hız ve uyarlanırlık gibi özellikleri sinir ağları ile artırılmıştır. Bulanık sinir ağlarında bulanık mantık kavramları ile klasik sinir ağlarının bilgi sunum yetenekleri zenginleştirilmektedir. Bu da sinir ağlarının girdi, ağırlıklar, aktivasyon fonksiyonları ve çıktı gibi düzeylerinde bulanık kavramların kullanılması ile sağlanabilmektedir. Bulanık sinir ağlarında sinir ağlarının girdi verisini bulanıklaştırma, öğretim örneklerine bulanık etiketler atama, öğretim işlemlerini bulanıklaştırma, sinir ağı çıktılarını bulanıklaştırma, sinir hücrelerinin standart çarpım ve toplam işlemcileri yerine bulanık küme teorisindeki birleşim, kesişim işlemcileri kullanma, ağların aktivitesini bulanıklaştırma gibi özellikler mevcuttur.

ANFIS, ele alınan problem için oluşturulan yapıya göre olası tüm kuralları atayabilmekte veya kuralların veriler yardımıyla uzman tarafından atanmasına olanak vermektedir. ANFIS'in kural oluşturabilmesi veya kural oluşturulmasına olanak sağlaması uzman görüşlerinden faydalanması anlamına gelmektedir. Bu nedenle birçok tahmin probleminde yapay sinir ağlarına uzman görüşlerinden faydalanma imkânı tanıdığı için ortalama hata kareler kriterine göre daha iyi sonuçlar elde edilmesini mümkün kılmaktadır (Cemil, 2015).

3.4. Bulanık c-Ortalamlar Kümeleme Yöntemi

3.4.1. Bulanık c-ortalamlar kümeleme yöntemi genel yaklaşımı

Bulanık c-ortalamlar (FCM) kümeleme algoritması, bulanık kümeleme tekniklerinden en iyi bilinen ve en yaygın kullanılan yöntemdir. Bulanık c-ortalamlar kümeleme algoritması 1973 yılında Dunn tarafından ortaya atılmış ve 1981'de Bezdek tarafından geliştirilmiştir (Bezdek, Ehrlich, & Full, 1984).

FCM yöntemi, k-ortalamlar algoritması üzerinde iyileştirmeler yapılarak geliştirilmiştir. Görüntü işleme, uzaktan algılama, veri madenciliği ve örüntü tanıma gibi konularda yaygın olarak kullanılan kümeleme yöntemlerinin amacı bir veri uzayını genellikle benzerliğe dayalı olarak gruplara ayırmaktır. Bir kümeye ait olan veri noktalarının kendi içinde en çok benzeşen diğer kümelere ait veri noktaları ile en az benzeşen olması istenir. Bu yüzden kümeleme işlemi veri uzayını benzer özellikli homojen gruplara bölmeyi hedefler (Mahmut Hekim, 2011).

FCM yönteminin performansı küme merkezlerinin başlangıç değerlerine bağlıdır. Bu yüzden algoritma farklı başlangıç küme merkezi değerleri ile birçok defa çalıştırılmalıdır. Genellikle kümeleme işleminin yerine getirilebilmesi için uygun parametre seçimi de önemlidir. Küme sayısı ve bulanık kümeleme algoritmalarında kullanılan üssel ağırlık parametrelerinin uygun değerlerde olması zorunludur (Baraldi & Blonda, 1999).

3.4.2. Bulanık c-ortalamlar algoritması

FCM algoritması amaç fonksiyonu temelli bir metottur ve verilerin birden fazla kümeye farklı üyelik dereceleriyle ait olabilmesi prensibine dayanır. Bulanık mantık prensibi gereği bu üyelik dereceleri $[0,1]$ arasında değişen değerler almaktadır ve bir verinin tüm kümelere ait üyelik derecelerinin toplamı 1 olmalıdır. Nesne hangi küme merkezine yakın ise o kümeye ait olma üyeliği diğer kümelere ait olma üyeliğinden daha büyük olacaktır.

D -boyutlu bir Euclidean uzayında N örnekten oluşan bir $X = \{x_1, x_2, \dots, x_N\}$ veri kümesinin verildiğini varsayalım ($x_i \in R^D$). Kümeleme, bu veri kümesinin, küme merkezleri $\{c_1, c_2, \dots, c_j, \dots, c_C\}$ olan c tane alt kümeye ayrılması işlemidir. Veri kümesini alt kümelere ayırırken istenen optimal kriter amaç fonksiyonunu minimize etmektir.

Algoritma, en küçük kareler yönteminin genellemesi olan (3.10) eşitliğindeki amaç fonksiyonunu öteleyerek minimize etmek için çalışır.

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2 \quad (3.10)$$

Burada;

m : Bulanıklık parametresi

u_{ij} : j kümesindeki x_i 'nin üyelik derecesi

x_i : D -boyutlu veri kümesi

c_j : Küme merkezleri

olarak tanımlanmıştır.

U üyelik matrisi rastgele atanarak algoritma başlatılır. İkinci adımda ise merkez vektörleri hesaplanır. Merkezler aşağıdaki formüle (3.11) göre hesaplanır.

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (3.11)$$

Hesaplanan küme merkezlerine göre U matrisi aşağıdaki formül (3.12) kullanılarak yeniden hesaplanır. Eski U matrisi ile yeni U matrisi karşılaştırılır ve fark ε 'dan küçük olana kadar işlemler devam eder.

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - c_i\|}{\|x_i - c_k\|} \right)^{2/(m-1)}} \quad (3.12)$$

Burada;

ϵ : 0 ve 1 arasında bir durma kriteri

k: İterasyon sayısı

olarak tanımlanmıştır.

Kümeleme işlemi sonucunda bulanık değerler içeren U üyelik matrisi kümelemenin sonucunu yansıtır. İstenirse, berraklaştırma yapılarak bu değerler yuvarlanıp 0 ve 1'lere dönüştürülebilir (Yıldız ve ark., 2011).

Kümeleme işlemine başlamadan önce verilerin normalize edilmesi gerekmektedir. Bu işlem için aşağıdaki formül (3.13) kullanılmaktadır.

$$X_{Normal} = \frac{X - X_{Asgari}}{X_{Azami} - X_{Asgari}} \quad (3.13)$$

3.4.3. Bulanık c-ortalamlar kümeleme yönteminin avantaj ve dezavantajları

FCM algoritmasının en önemli özelliği olan üyelik matrisinin kümeleme üzerinde olumlu etkileri vardır. Bu matris belirsiz durumların tanımlanmasını kolaylaştırır. Ayrıca üyelik dereceleri düşük olduğundan sıra dışı verilerin etkisi azdır. Esnek bir yapıya sahiptir. Örtüşen kümeleri bulma kabiliyeti diğer bölünmeli algoritmalara göre daha fazladır (Verma & Sharan, 2015).

Yukarıda bahsedilen avantajların yanında FCM algoritmasının bazı dezavantajları da vardır. Üyelik fonksiyonu işlemsel karmaşıklığı arttırdığı için zaman açısından maliyetli bir algoritmadır. Aynı zamanda eşik değerinin seçimi, küme sayısının belirlenmesi gibi hususlarda insan müdahalesi gerektirmektedir. Bunun yanı sıra

küme sayısının artması durumunda, kullanılan iteratif yöntemler sebebiyle sonucun geç alınması da söz konusu algoritmanın sorunlarından (Çelilnalça ve ark., 2014).



BÖLÜM 4. ANFIS VE BULANIK C-ORTALAMALAR YÖNTEMLERİ TABANLI ÇOK KRİTERLİ ENVANTER SINIFLANDIRMA UYGULAMASI

4.1. Uygulamanın Amacı

Daha önce yapılan çalışmalarda da görüldüğü üzere, bir işletmenin envanter yönetimini optimum seviyede gerçekleştirebilmesi için, envanterlerini sınıflandırması gerekmektedir. Bu amaçla geliştirilmiş çok sayıda çok kriterli envanter sınıflandırma yöntemi mevcuttur. Fakat mevcut yöntemler pek çok açıdan eleştirilmektedir. Örneğin; YSA ve GA tabanlı çok kriterli envanter sınıflandırma metotları anlaşılması ve uygulaması oldukça zor yöntemler olarak görülmektedir. Ayrıca geliştirilen yöntemlerin çoğu, günümüz imalat şartlarında olmazsa olmazlardan olan kalitatif verilerle çalışma özelliğine sahip değildir. Bunların dışında, AHP ve benzeri bazı çok kriterli envanter sınıflandırma yöntemleri de öznellik içerdiği için eleştirilmektedirler.

Bu çalışmada, yapay zeka yöntemlerinden faydalanılarak yeni bir çok kriterli envanter sınıflandırma modeli geliştirilmiştir. Bu hibrit model oluşturulurken bulanık c-ortalamar ve ANFIS yöntemlerinden faydalanılmıştır. Çalışmadaki amacımız yukarıda belirtilen eleştirileri yok edebilecek, bunun yanında; tahmin, öğrenme ve sınıflandırma yeteneğine sahip bir çok kriterli envanter sınıflandırma modeli geliştirmektir.

ANFIS yöntemi bir çok alanda kullanılmasına rağmen, daha önce çok kriterli envanter sınıflandırma problemlerinin çözümünde kullanılmamıştır. Bu çalışmada ANFIS yöntemi tercih edilmiştir. Çünkü bu yöntem içinde barındırdığı yapay sinir ağları sayesinde sınıflandırma yeteneğinin yanında, tahmin etme özelliğine de sahiptir. Modelin tahmin edebilme yeteneği sayesinde, yeni bir envanter birimi

eklendiğinde, model yeniden oluşturulması zorunluluğu ortadan kalkmış bulunmaktadır. Ayrıca ANFIS yöntemi, verilen veri setini öğrendikten sonra, kuralları kendiliğinden oluşturmaktadır. Bunun yanında manuel olarak da kullanıcılara kural ekleme veya değiştirme olanağı sağlamaktadır.

ANFIS yapısındaki bulanık eğer-ise kuralları sayesinde, bir sistemdeki proses bilgisi ve aynı zamanda karar vericinin deneyimleri, ANFIS modellerinde kolaylıkla kullanılabilir. Böylelikle önerilen model, hem kalitatif hem de kantitatif kriterleri ele alabilme kapasitesine sahiptir. YSA ve ANFIS modellerinin en önemli farklarından biri de budur. YSA modelleri kullanıcı müdahalesine izin vermezken, ANFIS modellerinde kullanıcı kendi kurallarını modele ekleyebilmektedir.

Amaçlanan modelin oluşturulmasında izlenecek adımlar şunlardır:

Adım 1. FCM algoritmasının optimize edilmesi.

- Verilerin normalize edilmesi
- Optimum m değerinin hesaplanması

Adım 2. FCM algoritması ile envanter birimlerinin kümelmesi.

Adım 3. ANFIS modelinin oluşturulması.

- Veri setinin oluşturulması
- Bulanık çıkarım sisteminin oluşturulması
- Optimum üyelik fonksiyonu tipinin belirlenmesi
- Modelin eğitilmesi
- Bulanık kuralların oluşturulması
- Model çıktılarının elde edilmesi

Adım 4. YSA ile envanter sınıflandırma modelinin oluşturulması.

Adım 5. Amaçlanan hibrit model ile YSA modelinin karşılaştırılması.

Modelin oluşturulmasına FCM algoritmasının optimize edilmesi ile başlanmıştır. Kullanılan veri setine en uygun bulanıklık parametresinin (m değeri) (Formül 3.10) bulunabilmesi için farklı m değerleri atanmış ve en az hata oranına sahip olan değer bulanıklık parametresi olarak kabul edilmiştir.

İkinci adımda, elde edilen en az hata oranına sahip bulanıklık parametresi kullanılarak FCM algoritması oluşturulmuş ve kümeleme işlemini gerçekleştirilmiştir. Bu aşamada; küme merkezleri, üyelik dereceleri ve kümeleme sonuçları ayrı ayrı hesaplanarak, veri seti istenilen sayıda sınıfa ayrılmıştır.

Üçüncü adımda, FCM algoritmasından elde edilen çıktılar, ANFIS modelinin girdisi haline getirilmiş ve bulanık çıkarım sistemi oluşturulmuştur. Daha sonra model eğitilmiş ve kurallar oluşturulmuştur.

Dördüncü adımda, aynı veri seti kullanılarak YSA sınıflandırma modeli oluşturulmuştur. Son aşamada, önerilen hibrit model ile YSA modelinin performansları karşılaştırılmıştır.

4.2. Verilerin Elde Edildiği İşletmenin Tanıtımı

Uygulama verilerinin elde edildiği firma, 1914 yılında Adapazarı'nda kurulmuştur ve tarım alet ve makinaları üretmektedir. Firma 1968 yılından itibaren Adapazarı'nda yüzde 65 yerli üretim oranı ile imalat başarısını göstermiştir. Fabrikada, 275.000 m² alan üzerinde 40.000 m² kapalı alanda üretim yapılmaktadır. Yıllık üretim kapasitesi 10.000 adet olup, traktörün ana parçaları olan motor, şanzıman ve hidrolik donanım ana parçaları, işlenmekte ve üretilmektedir. Farklı segmentlerdeki 2x4 ve 4x4 çekişli 20 civarında modeli; az yakıt tüketimi sayesinde en ekonomik kullanımı sağlayan, az bakım gerektiren yerli traktörleri ile çiftçilerin hizmetindedir.

4.3. Amaçlanan Modelin Uygulaması

4.3.1. Kullanılacak veri setinin oluşturulması

Uygulamada kullanılacak olan veri setinde, 69 parça envanter birimi bulunmaktadır. Firmanın envanter yöneticileri tarafından belirlenen dört farklı sınıflandırma kriterine göre envanter sınıflandırması yapılacaktır. Kriterlerin üçü kantitatif, biri de kalitatif değerlendirme kriteridir. Bu kriterler; birim maliyet, hacim, tedarik süresi ve kritiklik olarak belirlenmiştir.

Hacimsel sınıflandırma yapılırken gözlemsel verilerden yararlanılmıştır çünkü her bir parçanın ayrı ayrı ölçüleri alınarak hesaplama yapılması kolay değildir. Parçaların boyutları kendi aralarında karşılaştırılarak numaralandırılmıştır. Verilerin güvenilirliği % 95 seviyesinde doğrudur. Kritiklik faktörü kalitatif kriterdir ve ikiye ayrılmıştır. 1 değerini alan envanter birimleri kritik olarak adlandırılır ve hat duruşuna sebep olup zaman kaybına ve yüksek maliyete sebep olabilir. 2 değerini alan envanter birimleri ise üretimin tamamlanmasını engellemesine rağmen son montaj parçaları olarak gruptandırılabilir ve daha sonra ürün tamamlanabilir. Birim maliyet için para birimi Türk Lirası olarak belirlenmiştir. Tablo 4.1.'de görülebileceği gibi, toplamda veri setimizde 276 veri bulunmaktadır.

Tablo 4.1. Veri Seti

Parça kodu	Parça adı	Birim Maliyet	Hacim	Tedarik Süresi	Kritiklik Faktörü
S1	AKS KOVANI	1540	90	15	1
S2	AKS MİLİ	816	90	60	1
S3	ALT TAHRİK KUTUSU	1029	15	60	2
S4	ANA TESİSAT KOMPLE	2875	96	21	1
S5	ARA GÖVDE	12602	93	45	1
S6	ARA GÖVDE HAM	21600	86	7	1
S7	ARKA AĞIRLIK	9	86	15	2
S8	ARKA LASTİK	8100	90	15	1
S9	AYAR MİLİ KOMPLE	108	9	45	2
S10	CIVATA	7	13	60	1

Tablo 4.1. (Devamı)

S11	CONTA	53	5	15	1
S12	ÇAMURLUK	1785	15	90	1
S13	DIS FİLTRE	240	14	30	1
S14	DİFERANSİYEL GÖVDESİ	2568	61	21	1
S15	DİJİTAL GÖSTERGE PANELİ	1026	9	60	1
S16	DİSK FREN BALATASI	2145	40	60	1
S17	DİSK FREN SACI	41	85	60	1
S18	EGZOZ BORUSU KOMPLE	540	14	75	2
S19	EKSANTRİK MİLİ	1215	87	45	2
S20	EL FRENİ KOLU	12	40	60	2
S21	ELEKTRİK TESİSATI	1467	31	21	2
S22	EMNİYET MÜŞİRİ	324	5	60	1
S23	FAR KABLOSU	168	55	21	1
S24	FLANŞ	1788	88	15	1
S25	FREN BALATASI	918	55	90	1
S26	FREN GÖVDESİ	1485	96	21	1
S27	FREN GÖVDESİ	1913	15	45	2
S28	FREN MİLİ	81	11	45	1
S29	FREN SACI	81	90	90	1
S30	GÖSTERGE TABLOSU	81	5	90	1
S31	GÖVDE SİYAH	10500	12	7	1
S32	HARARET GÖSTERGE MÜŞİRİ	140	60	30	1
S33	HİDROLİK YAĞ FİLTRESİ	162	15	90	1
S34	KLİMA FİLTRESİ	38	5	7	1
S35	KOLTUK	54	95	60	1
S36	KONTAK	1350	15	60	1
S37	KOVAN	387	83	45	1
S38	KRANK MİLİ	145	90	120	1
S39	KUYRUK MİLİ	8100	90	45	1
S40	KUYRUK MİLİ KOLU	138	63	60	1
S41	MARŞ MOTORU	84	20	7	1
S42	MAZOT POMPASI	2754	38	120	1
S43	MOTOR	837	90	90	1
S44	MOTOR BLOKU	1080	89	21	1
S45	MOTOR KOMPLE	405	100	60	2
S46	O-RİNG	4050	30	7	1

Tablo 4.1. (Devamı)

S47	ÖN ÇAMURLUK	11	87	15	1
S48	ÖN SPORT	156	88	45	1
S49	ÖN TAHRİKLİ	1927	6	60	2
S50	POWERTRAIN	10800	85	90	1
S51	SELİLOZİK MAT BOYA	6528	12	7	1
S52	SERVOSTAT	2700	60	60	1
S53	SOMUN	263	6	90	1
S54	SUSTURUCU	1026	3	75	1
S55	ŞANZUMAN GÖVDESİ	10800	75	21	1
S56	TAHLİYE HORTUMU	276	20	7	1
S57	VANTİLATÖR(PERVANE)	108	40	90	1
S58	VİTES ÇATALI	280	90	45	1
S59	VİTES ÇATALI MİLİ	192	5	21	1
S60	VOLAN MUHAFAZASI	4050	29	15	1
S61	VOLANT	2100	91	15	1
S62	YAĞ KARTERİ	1010	29	60	2
S63	YAĞ MÜŞİRİ	473	85	30	1
S64	YAĞ TANKI KOMPLE	1890	60	60	1
S65	YAKIT POMPASI	837	25	120	1
S66	YANMA ODASI SACI BRAKETİ	14	15	45	1
S67	YATAK FLANŞI	503	82	45	2
S68	YATAK KAPAĞI	269	98	30	1
S69	YAY	158	12	15	1

4.3.2. Bulanık c-ortalamlar (FCM) algoritmasının optimize edilmesi

Uygulamanın ilk adımı bulanık c-ortalamlar algoritmasının optimize edilmesidir. FCM algoritması amaç fonksiyonunda (Formül 3.10) kullanılan bulanıklık parametresi (m), 1'den büyük herhangi bir değer olarak tanımlanmıştır (Bezdek ve ark., 1984). Fakat bu değer genel olarak 2 alınmaktadır.

FCM algoritması veri sınıflandırma işlemlerinde kullanılan başarılı bir yöntem olmasına rağmen, bu özelliği ile pek çok eleştiriye maruz kalmaktadır. Çünkü, m değerinin 2 alınması, her veri seti için optimum sonucu vermemektedir (Castillo ve

ark., 2012; Alata ve ark., 2013; Ramli ve ark., 2014). Bu yüzden, FCM algoritmasının en iyi sonucu üretebilmesi için, her veri setinin kendi bulanıklık parametresi olması gerekmektedir.

Optimum sonucun elde edilmesini sağlayacak bulanıklık parametresinin tespiti için öncelikle veriler normalize edilmiş, daha sonra bu veriler kullanılarak farklı m değerleri için FCM algoritmasının ürettiği hata değerleri incelenmiştir.

4.3.2.1. Verilerin normalize edilmesi

Mevcut veri setine en uygun m değerinin bulunması için, çalışmalara ilk olarak verilerin normalize edilmesi ile başlanmıştır. Tablo 4.1.'de görülebileceği gibi, maliyet kriterinin aldığı değerler diğer kriterlerin aldığı değerlerden oldukça büyüktür. Bu yüzden normalizasyon işlemi yapılmış ve Tablo 4.2.'de gösterilen değerler elde edilmiştir.

Normalizasyon işlemi için Formül 3.13 kullanılmıştır.

Tablo 4.2. Normalize edilmiş veriler

Parça kodu	Maliyet	Hacim	Tedarik Süresi	Kritiklik
S1	0,07099523	0,896907216	0,07079646	0
S2	0,037465845	0,896907216	0,469026549	0
S3	0,047330153	0,12371134	0,469026549	1
S4	0,132820822	0,958762887	0,123893805	0
S5	0,583290881	0,927835052	0,336283186	0
S6	1	0,855670103	0	0
S7	9,26226E-05	0,855670103	0,07079646	1
S8	0,374797388	0,896907216	0,07079646	0
S9	0,004677442	0,06185567	0,336283186	1
S10	0	0,103092784	0,469026549	0
S11	0,00213032	0,020618557	0,07079646	0
S12	0,0823415	0,12371134	0,734513274	0
S13	0,010790534	0,113402062	0,203539823	0
S14	0,118603251	0,597938144	0,123893805	0
S15	0,047191219	0,06185567	0,469026549	0

Tablo 4.2. (Devamı)

S16	0,099013569	0,381443299	0,469026549	0
S17	0,001574584	0,845360825	0,469026549	0
S18	0,024683925	0,113402062	0,601769912	1
S19	0,055944056	0,865979381	0,336283186	1
S20	0,000231557	0,381443299	0,469026549	1
...
S62	0,046450239	0,268041237	0,469026549	1
S63	0,021581068	0,845360825	0,203539823	0
S64	0,087204187	0,587628866	0,469026549	0
S65	0,038438383	0,226804124	1	0
S66	0,000324179	0,12371134	0,336283186	0
S67	0,022970407	0,81443299	0,336283186	1
S68	0,012133562	0,979381443	0,203539823	0
S69	0,006993007	0,092783505	0,07079646	0

4.3.2.2. Farklı m değerleri için hata değerlerinin hesaplanması

Bu adımda, MATLAB (R2014a) programında geliştirilen kodlarla, normalize edilmiş veriler FCM algoritmasına göre kümeleme işlemine tabi tutulmuşlardır. FCM algoritmasının girdileri; kümelenecek istenen veri seti, istenilen küme sayısı ve varsayılan seçenekler olarak tanımlanan 4 farklı parametredir.

Bu değerlerden biri yukarıda bahsettiğimiz bulanıklık parametresi (m)'dir. Bu değer MATLAB tarafından her seferinde 2 alınmaktadır. Fakat her veri seti için m değerinin 2 alınması en optimum sonucu vermemektedir. Bu çalışmada, MATLAB komut satırına kodlar yazılarak, bu parametreye 2'den farklı değerler atanmış ve bu değerlerde FCM algoritmasının ürettiği hata değerleri incelenmiştir. Tablo 4.3'te görülebileceği gibi, m değerine farklı 8 değer atanmış ve hata oranını en aza indirecek m parametresi tespit edilmeye çalışılmıştır.

Tablo 4.3. Farklı m değerleri için hata değerleri

m değeri	Hata değeri
1,5	9,8294
1,75	7,7437
2	6,2928
2,45	4,6216
2,5	4,4845
2,75	3,8981
3	7,7438
10	17,4867

Elde edilen sonuçlara göre FCM algoritmasının hata oranını en aza indirebilecek m değeri 2,75 olarak bulunmuştur. Tabloda görüldüğü gibi, m değeri “2” olarak alınırsa hata oranı diğer üç değerden daha yüksek bir değere sahip olacaktır. Tüm değerler içerisinde ortalama bir hata değerine sahiptir

4.3.3. Bulanık c-ortalamlar algoritması kullanılarak envanter birimlerinin kümelenmesi

Mevcut envanter sınıflandırma probleminde, elimizde 69 satır ve 4 sütundan oluşan envanter kalemi bulunmaktadır. Firmanın envanter yöneticilerinin uygun gördüğü envanter sınıf sayısı da 3 olarak belirlenmiştir. Ve ilk aşamada belirlediğimiz en optimum m değeri 2,75 olarak tespit edilmiştir. Elde edilen veriler ile FCM algoritması uygulanmaya başlanmıştır. Başlangıçta belirtildiği gibi, FCM algoritması amaç fonksiyonu temelli bir yöntemdir ve Formül 3.10’ u minimize etmeye çalışmaktadır. Bunun gerçekleştirilebilmesi için ilk olarak küme merkezleri Formül 3.11 kullanılarak hesaplanmıştır. Sonuçlar Tablo 4.4.’de gösterilmektedir.

Tablo 4.4. Küme merkezleri

Kriter	Küme adı		
	Küme 1	Küme 2	Küme 3
Maliyet	0,049694	0,110215	0,059458
Hacim	0,326584	0,822554	0,158064
Tedarik süresi	0,393096	0,293762	0,379004
Kritiklik	0,954478	0,009793	0,006119

Daha sonra envanter kalemlerinin küme merkezlerine olan üyeli dereceleri Formül 3.12 kullanılarak hesaplanmıştır. Sonuçlar Tablo 4.5.'te gösterilmektedir. Tablo incelendiğinde her satırdaki üyelik derecesi toplamları 1'e eşittir.

Tablo 4.5. Üyelik dereceleri ve kümeleme sonuçları

Parça				Parça					
kodu	Küme 1	Küme 2	Küme 3	Sınıf	kodu	Küme 1	Küme 2	Küme 3	Sınıf
S1	0,105055	0,734129	0,16082	2	S36	0,865626	0,07857	0,0558	1
S2	0,737107	0,101621	0,16127	1	S37	0,055055	0,85018	0,09476	2
S3	0,791201	0,091517	0,11728	1	S38	0,231072	0,45158	0,31735	2
S4	0,094856	0,765485	0,13966	2	S39	0,196081	0,67484	0,12908	1
S5	0,556865	0,184555	0,25858	1	S40	0,136415	0,54753	0,31605	2
S6	0,249392	0,436428	0,31418	2	S41	0,173038	0,26733	0,55963	3
S7	0,224702	0,288541	0,48676	3	S42	0,440029	0,32669	0,23328	1
S8	0,148063	0,634238	0,2177	2	S43	0,181728	0,54624	0,27203	2
S9	0,113001	0,738626	0,14837	2	S44	0,085677	0,78028	0,13404	2
S10	0,064473	0,087791	0,84774	3	S45	0,467758	0,30473	0,22752	1
S11	0,161964	0,210542	0,62749	3	S46	0,176558	0,32009	0,50336	3
S12	0,602731	0,223345	0,17392	1	S47	0,111893	0,71258	0,17552	2
S13	0,102565	0,148435	0,749	3	S48	0,059977	0,84245	0,09757	2
S14	0,131887	0,578574	0,28954	2	S49	0,712184	0,12311	0,16471	1
S15	0,84354	0,088595	0,06786	1	S50	0,488522	0,20941	0,30207	1
S16	0,578533	0,289729	0,13174	1	S51	0,193062	0,27124	0,5357	3
S17	0,105808	0,717508	0,17668	2	S52	0,137246	0,52704	0,33571	2
S18	0,715004	0,124427	0,16057	1	S53	0,179655	0,60892	0,21142	2
S19	0,515156	0,272409	0,21243	1	S54	0,139099	0,69558	0,16532	2
S20	0,073613	0,067307	0,85908	3	S55	0,173607	0,54958	0,27681	2
S21	0,136894	0,709636	0,15347	2	S56	0,172725	0,26724	0,56004	3
S22	0,085879	0,106959	0,80716	3	S57	0,184439	0,49962	0,31594	2
S23	0,145789	0,498115	0,3561	2	S58	0,060999	0,84175	0,09725	2
S24	0,103371	0,735724	0,16091	2	S59	0,144908	0,18844	0,66665	3

Tablo 4.5. (Devamı)

S25	0,18783	0,4105	0,401665	2	S60	0,161875	0,542382	0,295744	2
S26	0,09517	0,7644	0,140428	2	S61	0,104995	0,735702	0,159303	2
S27	0,7898	0,09266	0,11754	1	S62	0,04222	0,908057	0,049723	2
S28	0,04711	0,06448	0,888416	3	S63	0,059008	0,843353	0,097639	2
S29	0,18321	0,5428	0,273989	2	S64	0,136905	0,525389	0,337706	2
S30	0,18093	0,60802	0,211044	2	S65	0,234057	0,294446	0,471497	3
S31	0,21716	0,29697	0,485873	3	S66	0,039463	0,056935	0,903603	3
S32	0,12831	0,56763	0,304057	2	S67	0,255559	0,53903	0,20541	1
S33	0,17452	0,22261	0,602873	3	S68	0,087734	0,78339	0,128876	2
S34	0,18146	0,2354	0,583143	3	S69	0,155053	0,218251	0,626696	3
S35	0,11296	0,71608	0,170956	2					

Tablo 4. 5'ten aynı zamanda kümeleme işleminin sonuçlarını da elde edilmiştir. Kümeleme sonuçları üyelik fonksiyonlarından faydalanılarak elde edilmiştir. Örneğin; 1 numaralı envanter birimi Küme 1, Küme 2 ve Küme 3'e sırasıyla, 0,10506, 0,73413 ve 0,16082 üyelik dereceleriyle aittir. Bu yüzden 1 numaralı envanter biriminin Küme 2'ye ait olduğu belirlenmiştir. Çünkü en büyük üyelik derecesi Küme 2'de elde edilmiştir. Diğer envanter birimleri de aynı şekilde kümelere ayrılmıştır.

4.3.4. ANFIS sınıflandırma modelinin oluşturulması

Bu aşama veri setinin hazırlanması ile başlamaktadır. Verilerin hazırlanmasından sonra sırasıyla; bulanık çıkarım sistemi oluşturulmaya başlanır, bulanık çıkarım sistemi parametreleri belirlenir, üyelik fonksiyonu tipi ve sayısının belirlenir, eğitim, test ve kontrol verileri eğitilerek bulanık çıkarım sistemi oluşturulmaya devam edilir ve son olarak kurallar oluşturulur.

4.3.4.1. Veri setinin hazırlanması

ANFIS modelleri öğrenme işlemini gerçekleştirebilmek için girdi ve çıktı değerlerine ihtiyaç duymaktadır. Bu yüzden Tablo 4.4.'te gösterilen başlangıç veri seti ANFIS

modelinin girdileri ve Tablo 4.5.'te gösterilen FCM algoritmasından elde edilen sonuçlar da ANFIS modelinin çıktısı olarak belirlenmiştir. Sonuç olarak yeni veri seti dört girdi ve bir çıktıdan oluşmaktadır. Toplamda elde edilen 345 verinin %70'i eğitim, %20'si test ve %10'u da kontrol verisi olarak kullanılmak üzere ayrılmıştır.

Belirlenen eğitim, test ve kontrol verilerinin MATLAB çalışma alanına yüklenmesi gerekmektedir. MATLAB 'da veri girişi için; ekranının sağ tarafında çalışma alanı yer almaktadır. Çalışma alanının en solda yer alan new variable butonu ile çalışma alanına yeni değişken eklenebilmektedir. Dosya isimlendirme işlemi bittikten sonra oluşturulan değişkene çift tıklanır. Çıkan boş hücrelere belirlenen eğitim verisi Excel dosyasından kopyalanıp eğitim değişkenine yapıştırılır. Aynı aşamalar test ve kontrol verileri için de tekrar edilir ve yükleme işlemi tamamlanır (Şekil 4.1.).

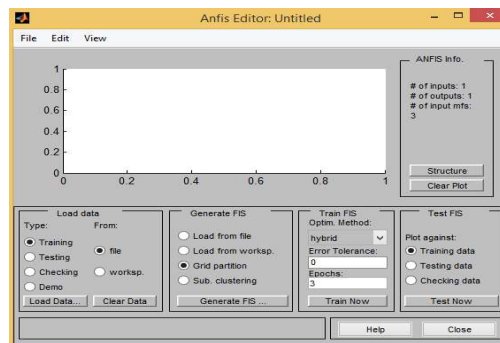


Name	Value	Min	Max
egitim	48x5 double	1	216
kontrol	6x5 double	1	189
test	15x5 double	1	108

Şekil 4.1. MATLAB çalışma alanı

4.3.4.2. Bulanık çıkarım sistemi parametrelerinin belirlenmesi

Uygulamanın bu bölümünde MATLAB yazılımının Bulanık Mantık Modülü'nden (Anfisedit) faydalanılmıştır (Şekil 4.2.).



Şekil 4.2. Anfisedit ana komut penceresi

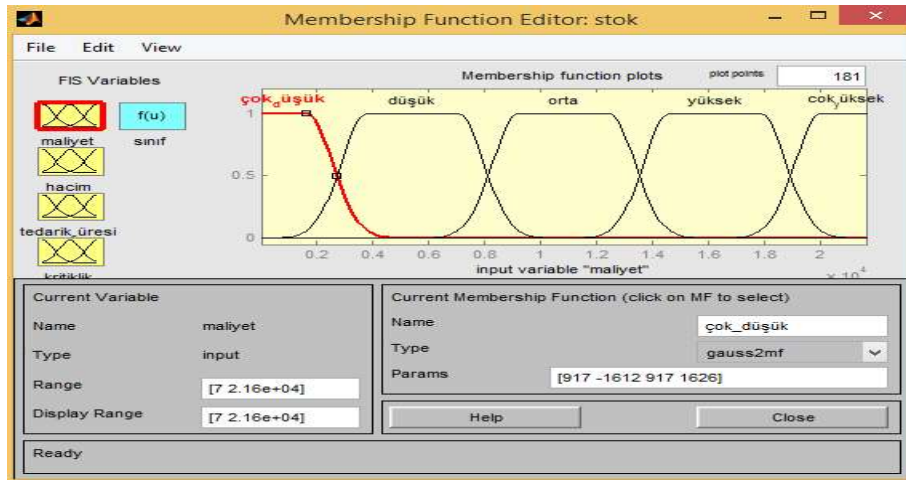
Bulanık çıkarım sistemi parametreleri kullanıcı tarafından belirlenmektedir ve bu çalışma için belirlenen parametre değerleri Tablo 4.6.'da gösterilmektedir.

Tablo 4.6. Parametreler

Parametre adı	Parametrenin Değeri
FIS yapısı tipi	Sugeno
Girdi sayısı	4
Çıktı sayısı	1
Etki aralığı	0,5
Sıklık faktörü	1,25
Kabul oranı	0,5
Ret oranı	0,15
Çevrim sayısı	100

4.3.4.3. Üyelik fonksiyonu tipinin belirlenmesi

Parametrelerin belirlenmesinden sonra, her bir girdiye ait üyelik fonksiyonu sayısına karar verilmesi gerekmektedir. İlk üç girdi için beş adet üyelik fonksiyonu tanımlanmıştır. Bunlar; çok düşük, düşük, orta, yüksek ve çok yüksek olarak belirlenmiştir. Son girdi olan kritiklik faktörü için, yüksek ve düşük olmak üzere iki adet üyelik fonksiyonu tanımlanmıştır.



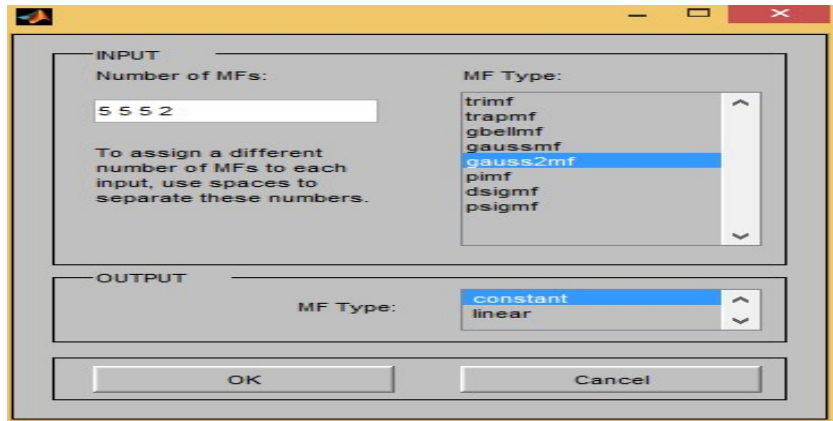
Şekil 4.3. Üyelik fonksiyonları (Gauss2mf)

Üyelik fonksiyonu adedinin belirlenmesinin ardından üyelik fonksiyonu tipinin belirlenmesi gerekmektedir. Çalışmada en uygun, diğer bir ifade ile eldeki girdi-çıkı setini en az hata ile açıklayan üyelik fonksiyonu tipini seçebilmek amacıyla, her bir üyelik fonksiyonu tipi tek tek kullanılarak eğitim verisi 100 çevrim eğitilmiş ve Tablo 4.7.'de gösterilen hata değerleri elde edilmiştir.

Tablo 4.7. Üyelik fonksiyonları hata değerleri

Üyelik fonksiyon tipi	Hata değeri
Trimf	0.03532
Trapmf	0.20136
Gbellmf	1,11671
Gaussmf	0.10203
Gauss2mf	0.023256
Pimf	1,30356
Dsigmf	0.12504
Psigmf	0.12505

Tablo 4.7.'de görülebileceği gibi en düşük hata değerini veren üyelik fonksiyonu tipi gauss2mf (Gaussian üyelik fonksiyonu) olarak tespit edilmiştir. (Şekil 4.4).

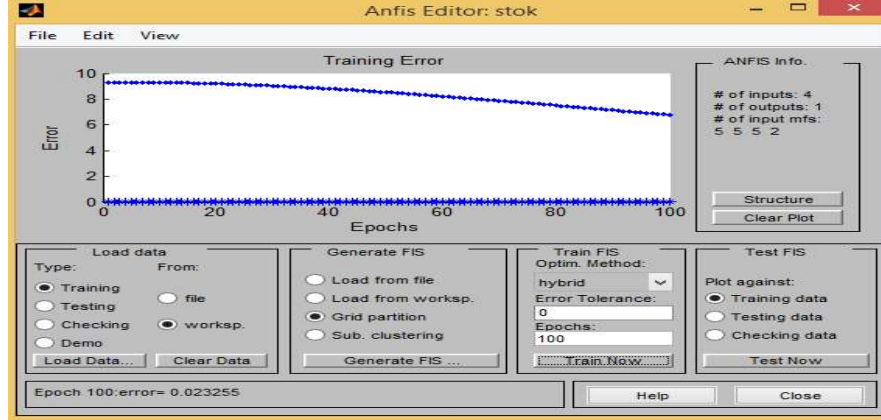


Şekil 4.4. Alternatif üyelik fonksiyonu tipleri

4.3.4.4. Modelin eğitilmesi

Şekil 4.5.'de görülebileceği gibi, en küçük kareler yöntemi ve geri yayımlı (en dik iniş) yönteminin birleşimi olan bir melez ağ yardımıyla öğrenme işlemi

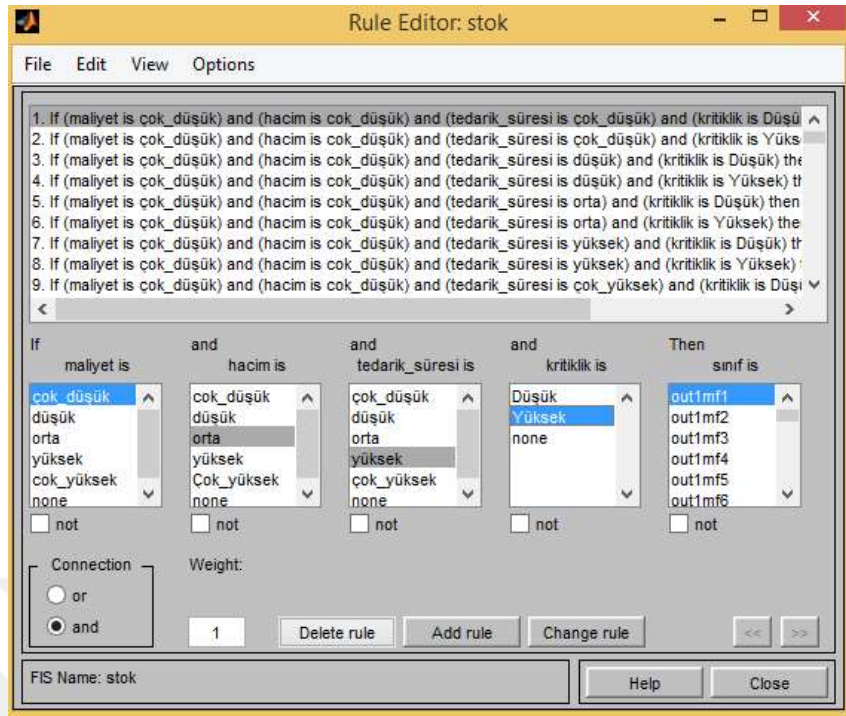
gerçekleştirilmiş ve bu işleme tahminleme hatası minimize edilinceye kadar devam edilmiştir.



Şekil 4.5. Verilerin eğitimi

4.3.4.5. Bulanık kuralların oluşturulması

Eğitimi tamamlanan modelin değişken aralıklarını ve bulanık kuralları ANFIS otomatik olarak belirlenmektedir. Kural editörü, bulanık çıkarım sistem editöründe tanımlanan girdi ve çıktı değişkenlerine bağlı olarak kuralları otomatik olarak oluşturmaktadır. Şekil 4.6.'da, bu kurallardan ilk 9 tanesi görülebilir. Ayrıca ANFIS modelleri, kullanıcılara değişken aralıkları ve kurallar üzerinde, istedikleri ekleme ya da çıkarmaları yapabilmelerine olanak sağlamaktadır.

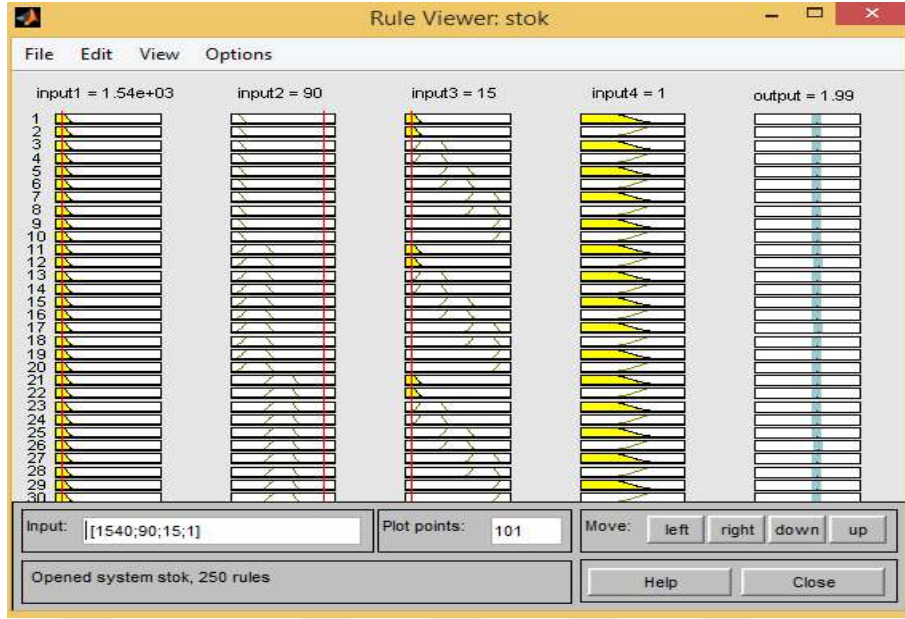


Şekil 4.6. Bulanık Kurallar

Bu kurallar oluşturulduktan sonra bulanık çıkarım sistemi tanımlanmış olur ve sistem kontrol edilmek istendiğinde kural izleyici kullanılır. Kural izleyici ile oluşturulan kural tabanına uygun olarak girişlerdeki değerlerin değişimine göre çıkışlarda meydana gelen değişim incelenebilir. Kural sayısı Formül 4.1 kullanılarak elde edilmektedir.

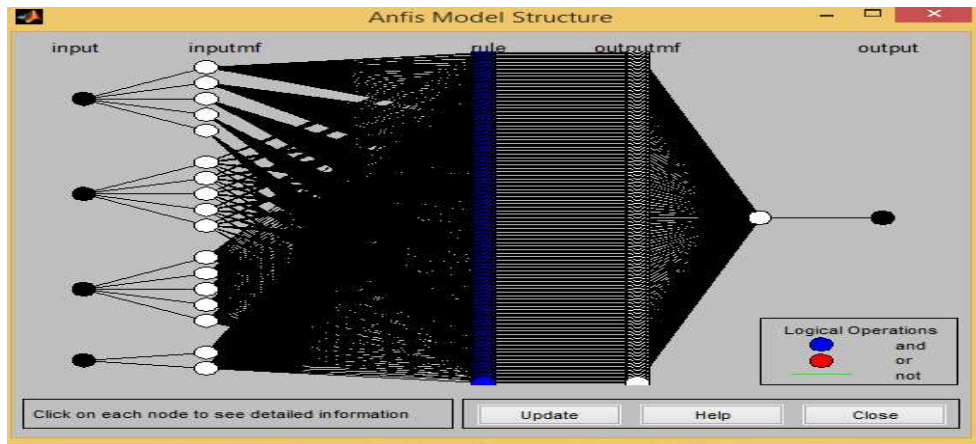
$$\text{Kural sayısı} = \text{Üyelik fonksiyonu sayısı} \wedge \text{Girdi sayısı} \quad (4.1)$$

ANFIS, 4 girdi ve her bir girdi için belirlediğimiz üyelik fonksiyon aralığı için 250 ($5^3 * 2^1$) tane kural oluşturmuştur. Aşağıda da bu 250 kuraldan 30'u grafiksel olarak görülmektedir.



Şekil 4.7. Kural izleyici

Kural numaraları her satırın sol tarafında gösterilmektedir. İlk dört sütun öncül üyelik fonksiyonlarını, son sütun ise verilen çıkarım sistemi için ağırlıklı ortalama sonucunu göstermektedir. Durulaştırılmış çıktı bu alan üzerinde kalın dikey bir çizgi olarak görüntülenir. Bulanık kuralların grafiksel gösterimi aslında bütün bulanık çıkarım süreçlerinin bir yol haritasını ve özetini teşkil etmektedir. Grafikteki her bir satır kural tabanındaki bir kurala karşılık gelmekte, girdi ve çıktıların üyelik fonksiyonlarını vermektedir. Son olarak dört girdi, bir çıktı ve 250 kuraldan oluşan ANFIS modelinin yapısı Şekil 4.8.'de gösterildiği gibi elde edilmiştir.



Şekil 4.8. ANFIS yapısı

4.3.4.4. Model çıktılarının elde edilmesi

Uygulamanın sonunda kullanıcının yer alan yapıyı kullanarak tek tek sonuçları ortaya koyması zaman alacaktır. Bu sebeple ANFIS modelinin çıktılarını bir liste halinde ortaya koyma adına çalışmada evalfis komutu kullanılmıştır. evalfis komutunun kullanımı evalfis (girdi dosyası adı, ANFIS modeli) şeklindedir. Komutu uygulamak için öncelikli olarak sadece girdileri içeren verinin çalışma alanına yeni bir değişken olarak yüklenmesi gerekmektedir.

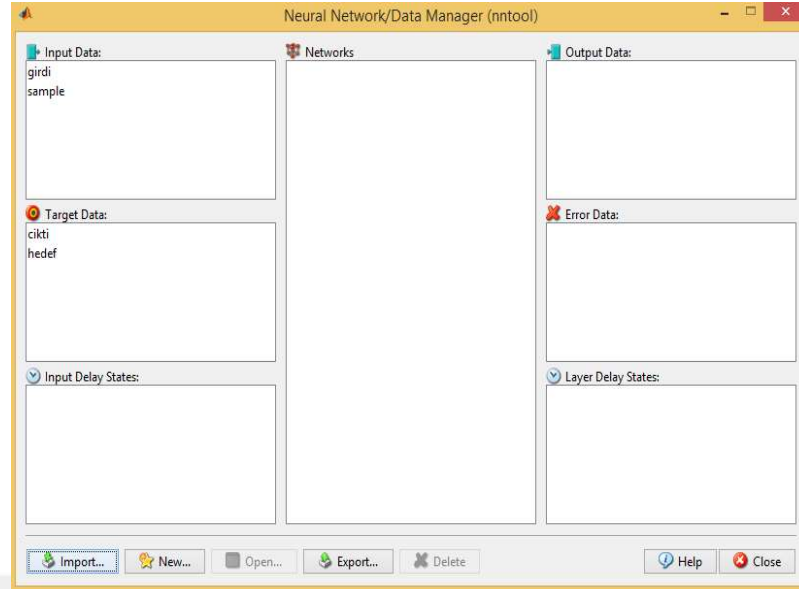
Komutun ikinci kısmını uygulama adına kurulan ANFIS modelinin çalışma alanına kaydedilmesi gerekmektedir. evalfis (input, model) kodu komut satırına yazılıp uygulandıktan sonra satır satır 276 adet verinin çıktı değerleri liste halinde MATLAB komut penceresinde oluşmaktadır. Bu sonuçlar Tablo 4.8.'de gösterilmektedir.

4.3.5. Yapay sinir ağları kullanılarak yeni bir tahmin modelinin oluşturulması

Bu bölümde çalışmada önerilmekte olan birleştirilmiş FCM-ANFIS yönteminin performansının karşılaştırılması amacı ile yapay sinir ağları kullanılarak envanter sınıflandırma modeli oluşturulacaktır.

FCM-ANFIS modelini oluştururken kullanılan envanter birimleri (Tablo 4.1), aynı şekilde YSA modelini oluşturmak için de kullanılacaktır. MATLAB programının yapay sinir ağlarının kullanımı için oluşturduğu platformda (Neural network/ Data manager) model geliştirilmeye başlanmıştır.

Modelin giriş verileri olarak, Tablo 4.1.'de gösterilen başlangıç veri seti kullanılmıştır. Tablo 4.5.'te gösterilen FCM algoritmasından elde edilen sonuçlar da modelinin hedef verileri olarak belirlenmiştir. Öncelikle verilerin normalize edilmesi gerekmektedir, daha sonra veriler çalışma alanına yüklenerek ağa tanıtılmıştır.

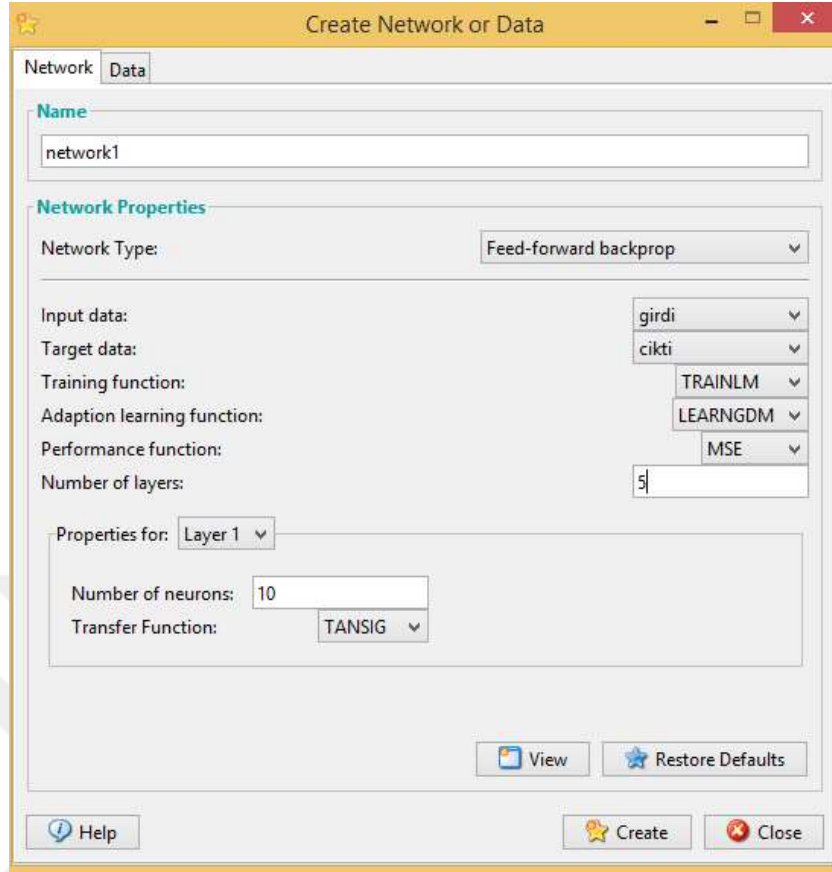


Şekil 4.9. YSA MATLAB arayüzü

Bu işlemlerin ardından ağ oluşturulmuş ve eğitim algoritması, transfer fonksiyonu tipi, nöron sayısı ve katman sayısı gibi parametreler tanımlanmıştır.

Tasarlanan yapay sinir ağı gizli katmanlarda 10 tane nöron bulunan 5 adet katmandan oluşmaktadır. MATLAB programının yapay sinir ağı modülünde yapılan deneme yanılma çalışmalarında en olumlu sonuçların; hiperbolik tanjant ve doğrusal fonksiyonlu aktivasyon fonksiyonuna sahip 10 nöron ve 5 katmandan oluşan ağlarda alındığı tespit edilmiştir. Ağda hatanın geriye doğru yayılarak düzeltilmesi (backpropagation) modeli temel alınmıştır.

Bu modelde eğitim algoritması olarak Trainlm optimizasyonu kullanılmıştır. Bu yöntemlerin bir arada kullanılmasıyla YSA'ya ait ağırlık değerleri epoch ismi verilen döngüler içinde hesaplanır. Eğitim işlemi; döngülerin her iterasyonunda çıkıştan elde edilen sonuçlar ile beklenen değerler arasındaki fark değerlerinin (hata) en aza indirgenmesi için ağırlıkların yeniden belirlenmesi çalışmasıdır. Hata azaltma fonksiyonu olarak ortalama karesel hata (MSE) fonksiyonu kullanılmıştır.



Şekil 4.10. Kullanılan parametreler

Gerekli parametreler tanımlandıktan sonra, ağ oluşturulmuş ve eğitime başlatılmıştır. Eğitim sonucunda istenilen tahmin değerleri elde edilmiştir. Bu değerler Tablo 4.8’de gösterilmektedir.

4.3.6. Amaçlanan hibrit model ve yapay sinir ağları modelinin performanslarının karşılaştırılması

FCM-ANFIS ve yapay sinir ağları kullanılarak oluşturulan modellerden elde edilen tahmin sonuçları Tablo 4.8.’de gösterilmektedir.

Tablo 4.8. FCM-ANFIS ve YSA modellerinden elde edilen sonuçlar

Parça kodu	FCM-ANFIS	YSA	Parça kodu	FCM-ANFIS	YSA
S1	1,991845812	1,99898	S36	0,969332965	1,000002075
S2	1,062364292	1,000001941	S37	2,002804678	1,9991
S3	1,000011622	1,000000771	S38	1,999996863	1,97462
S4	2,000680168	1,999	S39	0,999336585	1,0999
S5	1,000290041	1,99902	S40	1,999044845	1,9989
S6	1,999996904	1,99934	S41	2,999996887	3,1099985
S7	2,9999	3,99988	S42	0,999996894	1,000001729
S8	1,999994227	1,99902	S43	1,999431132	1,99886
S9	1,999988098	1,99618	S44	2,026000614	1,99902
S10	3,04739568	3,99997	S45	0,999999056	1,000000507
S11	2,999902984	3,0209889	S46	2,999996899	2,48992
S12	1,000447046	1,000000901	S47	1,994700257	1,99894
S13	2,999984081	3,99997	S48	1,985491503	1,9989
S14	1,999993076	1,99618	S49	0,298426861	1,000001608
S15	1,07816602	1,000001656	S50	0,004670963	1,000000876
S16	1,001687075	1,0018401	S51	2,4785999	3,000181
S17	1,984372641	1,99896	S52	1,9999598	1,99654
S18	0,999987339	1,000002116	S53	1,996911785	1,98557
S19	0,999998058	1,000001426	S54	1,136357754	1,000001234
S20	2,999991737	3,99997	S55	2,0000915	1,99902
S21	1,999990995	1,99886	S56	2,999908617	2,985998
S22	2,90428335	3,99994	S57	1,9998589	1,000031953
S23	1,99999696	1,98826	S58	1,973524906	1,99886
S24	2,000588312	1,99896	S59	2,997919094	2,799899
S25	1,99999796	1,741347	S60	2,884497453	1,3795899
S26	1,997078082	1,999	S61	1,929730095	1,99898
S27	1,000016334	1,000002456	S62	2,092438083	1,999588
S28	3,000015739	3,99997	S63	2,012116253	1,99904
S29	2,000562671	1,99888	S64	1,6944424	1,99604
S30	2,000005994	1,99862	S65	2,7099985	2,1599859
S31	2,999996201	3,2789	S66	3,009733474	3,2008
S32	1,99999987	1,99748	S67	1,179749871	1,00000177
S33	2,999578455	2,9998599	S68	1,975087148	1,99886
S34	3,000089859	3,10009	S69	2,999587706	3,000889
S35	1,954952372	1,99862			

Daha önce de bahsedildiği gibi verilerin elde edildiği işletmenin belirlediği envanter sınıf sayısı üç olarak belirlenmiştir. Tablo 4.8.'de görülebileceği gibi, oluşturulan modellerden elde edilen sonuçlar 1 ve 3 arasında değişmektedir. Elde edilen sonuçları 3 sınıfa ayırmak için literatürde daha önce yapıldığı gibi (Rezaei & Dowlatshahi, 2010; Tuna, 2015) eşik değerler belirlenmiştir. Sınıflandırma yapılırken çıkış değerlerimiz olan 1, 2 ve 3 değerlerinin orta noktaları eşik değer olarak belirlenmiştir. Sınıflar; sınıf 1 (çok önemli), sınıf 2 (önemli) ve sınıf 3 (az önemli) olarak isimlendirilmiştir (Tablo 4.9.).

Tablo 4.9. Eşik değerler

Eşik Değerler	Sınıf Adı
1 - 1,66	Sınıf 1
1,67 - 2,32	Sınıf 2
2,33 - 3	Sınıf 3

Sınıflandırmalar belirtilen aralıklara göre yapılmıştır. Örneğin; önerilen modelden elde edilen sonuçlara göre, 1 numaralı envanter birimi Tablo 4.8.'de görülebileceği gibi 1,9918 değerini almıştır. Tablo 4.9.'a göre, 1 numaralı envanter birimi sınıf 2'ye dahildir çünkü 1,9918 değeri 1,67 - 2,32 aralığında bulunmaktadır. Diğer envanter birimleri de aynı şekilde sınıflara ayrılmıştır.

Bir tahminleyici modelin performansı genellikle giriş değerlerine karşılık modelin ürettiği çıkış ve aynı girişe karşılık gelen gerçek çıkış arasındaki fark üzerinden belirlenmektedir. Bu amaç için ise genellikle ortalama karesel hata (MSE) kriteri tercih edilmektedir. Bu yüzden, gerçekleştirilen deneylerde ANFIS-FCM ve YSA modellerinin sınıflandırma performanslarını ölçmek için aşağıdaki eşitlikte gösterilen MSE performans değerlendirme kriteri kullanılmıştır:

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - f_i^*)^2 \quad (4.2)$$

Burada f_i inci giriş değerlerine karşılık gelen gerçek çıkış değeri ve f_i^* ise aynı giriş değerleri için ANFIS-FCM ve YSA modellerinin tahmin ettiği değerdir. Bu değerler Excel kullanılarak hesaplanmıştır.

MSE'nin yanında toplam sınıflandırma başarısı da her iki model için de hesaplanmıştır. Toplam sınıflandırma doğruluğu Formül 4.3 kullanılarak hesaplanmıştır.

$$\text{Sınıflandırma başarısı} = \text{Doğru tahmin sayısı} / \text{Toplam tahmin sayısı} \quad (4.3)$$

Belirtilen iki istatistiksel performans değerlendirme kriterine göre hesaplamalar yapılmış ve Tablo 4.10.'da gösterilmekte olan sonuçlar elde edilmiştir.

Tablo 4.10. Performans değerlendirme sonuçları

İstatistiksel Parametreler	ANFIS	ANN
MSE	0,051208	0,15372
Yanlış tahmin sayısı	5	12
Toplam başarı	0,927	0,82608

Tablo 4.10.'da açıkça görülebileceği gibi, ANFIS-FCM modelinin çıktıları kullanılarak elde edilen MSE değeri yaklaşık 0,0512 iken, YSA modelinin çıktıları kullanılarak elde edilen MSE değeri yaklaşık 0,153'tür. ANFIS-FCM modelinin sınıflandırma başarısı 0,927 ve YSA modelinin sınıflandırma başarısı 0,82 olarak hesaplanmıştır. Bu sonuçlara göre önerilen hibrit modelin YSA ile oluşturulan modelden çok daha başarılı olduğunu kolaylıkla söyleyebiliriz.

BÖLÜM 5. SONUÇLAR

Literatür araştırmasında da görülebileceği gibi, geçmişten günümüze kadar, çok kriterli envanter sınıflandırma probleminin çözümüne yönelik pek çok çalışma yapılmıştır. Bu çalışmalar birçok açıdan eleştirilmekle birlikte, farklı güçlü ve zayıf yönleri sahiptirler.

Geliştirilmiş çok kriterli envanter sınıflandırma yöntemleri; kalitatif veriler ile çalışamama, sübjektif olma ve yeni envanter kalemi eklendiğinde modelin tekrar oluşturulması zorunluluğu gibi pek çok açıdan eleştirilere maruz kalmaktadırlar. Çalışmada bu eleştirileri yok edebilecek, aynı zamanda tahmin, öğrenme ve sınıflandırma yeteneğine sahip çok kriterli bir envanter sınıflandırma modeli geliştirilmiştir. Önerilen bu yeni hibrit model geliştirilirken iki farklı yapay zekâ tekniğinden faydalanılmıştır. Bu yöntemler; FCM ve ANFIS'tir. Bu modelin oluşturulması için dört adım izlenmiştir; FCM algoritmasının optimize edilmesi, verilerin FCM kullanılarak kümelenebilmesi, ANFIS sınıflandırma modelinin oluşturulması ve son olarak YSA kullanılarak önerilen modelin performansının değerlendirilmesi.

FCM ve ANFIS metotları pek çok kez bir araya getirilmiş fakat daha önce envanter sınıflandırma problemleri için kullanıldığına literatürde rastlanmamıştır. FCM ve ANFIS metotları birleştirilerek daha iyi ve hızlı öğrenebilen bir model elde edilmiş ve bulanık çıkarım sistemi optimize edilmiştir.

ANFIS'in bileşenlerinden olan yapay sinir ağları sayesinde, geliştirilen model sınıflandırmanın yanında tahmin edebilme özelliğine de sahiptir. Bu model diğer modellerden farklı olarak, yeni bir envanter dahil edildiğinde modelin tekrar oluşturulması zorunluluğunu ortadan kaldırmaktadır. Ayrıca, ANFIS yapısındaki

bulanık eđer-ise kuralları sayesinde, bir sistemdeki proses bilgisi ve aynı zamanda insani deneyimler, ANFIS modellerinde kolaylıkla kullanılabilir. Bۆylelikle ۆnerilen model, hem kalitatif hem de kantitatif kriterleri ele alabilme kapasitesine sahiptir.

Tۆm bunların yanı sıra, ANFIS yۆntemi, verilen veri setini ۆğrendikten sonra, kuralları kendiliğinden oluřturmaktadır. Manuel olarak da kullanıcılara kural ekleme veya deęiřtirme olanaęı saęlamaktadır. YSA ve ANFIS modellerinin en ۆnemli farklarından biri de budur. YSA modelleri kullanıcı mۆdahalesine izin vermezken, ANFIS modellerinde kullanıcı kendi kurallarını modele ekleyebilmektedir. ANFIS modelleri, birçok tahmin probleminde yapay sinir aęlarına uzman gۆrüşlerinden faydalanma imkânı tanıdığı için, ortalama hata kareler (MSE) kriterine gۆre daha iyi sonuçlar elde edilmesini mۆmkün kılmaktadır

Son ařamada yapılan performans deęerlendirmede gۆrۆldüğü üzere ANFIS-FCM modelinin performansı, YSA ile oluřturulan modelin performansından, hem MSE hem de sınıflandırma doęruluęu kriterleri açasından çok daha başarılıdır.

Uygulama sonucunda elde edilen performans deęerlendirme sonuçlarına bakarak, ۆnerilen hibrit modelin her sektörde envanter sınıflandırma problemlerinin çۆzümünde, kolaylıkla uygulanabilecek ve verimlilięi artıracak etkili bir model olduęunu sۆylemek mۆmkündür.

KAYNAKLAR

- Abdulshahed, A. M., Longstaff, A. P., Fletche, S., & Myers, A. 2015. Thermal error modelling of machine tools based on ANFIS with fuzzy c-means clustering using a thermal imaging camera. *Applied Mathematical Modelling*. 39(7), 1837–1852.
- Alata, M., Molhim, M., & Ramini, A. 2013. Using GA for Optimization of the Fuzzy C-Means Clustering Algorithm. *Research Journal of Applied Sciences, Engineering and Technology*, 5, 695-701.
- Badri, A., Ameli, Z., & Birjandi, A. 2012. Application of Artificial Neural Networks and Fuzzy logic Methods for Short Term Load Forecasting. 2011 2nd International Conference on Advances in Energy Engineering (ICAEE), Bangkok, 1883–1888.
- Barak, S., Dahooie, J. H., & Tichý, T. 2015. Wrapper ANFIS-ICA method to do stock market timing and feature selection on the basis of Japanese Candlestick. *Expert Systems With Applications*, 42(23), 9221–9235.
- Baraldi, A., & Blonda, P. 1999. A survey of fuzzy clustering algorithms for pattern recognition. *IEEE Trans. Systems, Man, and Cybernetics*, 29(6), 778-801.
- Bezdek, J. C., Ehrlich, R., & Full, W. 1984. FCM: The Fuzzy C-means Clustering Algorithm. *Computers & Geosciences*, 10(3), 191-203.
- Bhattacharya, A., Sarkar, B., & Mukherjee, S. 2007. Distance-based consensus method for ABC analysis. *International Journal of Production Research* 45(15), 3405–3420.
- Cakır, O., & Canbolat, M. 2008. A web-based decision support system for multi criteria inventory classification using fuzzy AHP methodology. *Expert Systems with Applications* 35(3), 1367–1378.
- Cemil, Ç. 2015. AHP VE Dematel Tabanlı ANFIS ile Sıcaklık Tahmininin Modellenmesi. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Chen J-X. 2012. Multiple criteria ABC inventory classification using two virtual items. *International Journal of Production Research* 50(6), 1702–1713.

- Chu, C., & G.S. Liang, C. L. 2008. Controlling inventory by combining ABC analysis and fuzzy classification. *Computers & Industrial Engineering* 55, 841–851.
- Cohen, M. A., & Ernst, R. 1988. Multi-item classification and generic inventory stock control policies. *Production and Inventory Management Journal* 29(3), 6–8.
- Çeliknalça, O. E., Demirci, R., & Elmas, Ç. 2014. Renkli Görüntülerin Üç Boyutlu Histogram Yardımıyla Ayrıştırılması. *Journal of Advanced Technology Sciences*, 3(1), 38-44.
- Darlane, A., & Azimi, S. 2016. Forecasting streamflow by combination of genetic input selection algorithm and wavelet transform using ANFIS model. *Hydrological Sciences Journal*, 30-61.
- Dickie, H. F. 1951. ABC Inventory Analysis Shoots for Dollars, Not Pennies. *Factory Management and Maintenance*, 109, 92-94.
- Doğantekin, E., Avcı, E., & Erkuş, O. 2013. Automatic RNA virus classification using the Entropy-ANFIS method. *Digital Signal Processing*, 23(4), 1209–1215.
- Erel, E., & Guvenir, H. 1998. Multicriteria inventory classification using a genetic algorithm. *European Journal of Operational Research*, 105, 29–37.
- Ernst, R., & Cohen, M. (1986) Operations Related Groups (ORGs): A Clustering Procedure for Production/Inventory Systems. Decision Sciences Working Paper. University of Pennsylvania, Pennsylvania, USA.
- Fariman, H. J., Ahmad, S. A., Marhaban, M. H., & Jan, M. A. 2015. Simple and computationally efficient movement classification approach for EMG-controlled prosthetic hand: ANFIS vs. ANN. *Intelligent Automation & Soft Computing*, 21(4), 559–573.
- Flores, B., & Whybark, D. (1986) Multiple criteria ABC analysis. *Int.J.Oper.Prod. Manag.*, 6(3), 38–46.
- Ghorabae, M.K, Zavadskas, E.K., Olfat L. & Turksis Z. 2015. Multi-criteria Inventory Classification Using a New Method of Evaluation Based on Distance From Average Solution (EDAS). *Informatica*, 26(3), 435-451.
- Hadi-Vencheh, A. 2010. An improvement to multiple criteria ABC inventory classification. *European Journal of Operational Research*, 201(3), 962–965.
- Hadi-Vencheh, A., Mohamadghasemi, A. 2011. A fuzzy AHP-DEA approach for multiple criteria ABC inventory classification. *Expert Systems with Applications*, 38, 3346–3352.

- Ho, W.-H., Chen, J.-X., Lee, N., & Su, H.-C. 2011. An ANFIS-based model for predicting adequacy of vancomycin regimen using. *Expert Systems with Applications*, 38(10), 13050–13056.
- İnan, G. & Ubeyli, E. D. 2005. Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients. *Journal of Neuroscience Methods*, 148(2), 113-121.
- Jang, J. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE*, 23(3), 665-685.
- Kaufmanna, M., Meierb, A., & Stoffelc, K. 2015. IFC-Filter: Membership function generation for inductive fuzzy classification. *Expert Systems with Applications*, 42(21), 8369–8379.
- Keskin, G. A., & Özkan, C. 2013. Multiple Criteria ABC Analysis with FCM Clustering. *Journal of Industrial Engineering*, 50-57.
- Ketkar M. & Vaidya 2014. Developing ordering policy based on multiple inventory classification schemes. *Procedia - Social and Behavioral Sciences*, 133, 180 – 188.
- Kiris, S. 2013. Multi-Criteria Inventory Classification by Using a Fuzzy Analitic Network Process (ANP) Approach. *Informatica*, 24(2), 199-217.
- Kumar, S., & Balaji, K. 2014. Multicriteria Inventory ABC Classification in an Automobile Rubber Components Manufacturing Industry. *Procedia CIRP*, 17, 463 – 468.
- Kutbay, U. 2011. Sayısal görüntü segmentasyonunda bulanık c-mean kümelendirmesi ile level set yaklaşımı. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Eletronik Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Laurene, F. 1994. *Fundamentals of neural networks*, 1. Cilt. Prentice Hall Yayınları.
- Lei, Q., Chen, J., & Zhou, Q. 2005. Multi criteria inventory classification based on principal components analysis and neural network. *Advances in neural networks*, 3498, 1058-1063.
- Lolli, F., Ishizaka, A., & Gamberini, R. 2014. New AHP-based approaches for multi-criteria inventory classification . *Int. J. Production Economics*, 156, 62–74.
- López, D., Yacout, S., & Bello, F. A. 2016. Root cause analysis of familiarity biases in classification of inventory tems based on logical patterns recognition. *Computers & Industrial Engineering*, 93, 121–130.
- Mahmut Hekim, U. O. 2011. Bulanık c-means kümeleme yöntemine çıkarımlı yaklaşım. *İTÜ Dergisi*, 10(1), 11-17.

- Mehmet Fatih, T. 2006. Önleyici bakım politikası altında optimum stok miktarının bulanık mantık yöntemiyle belirlenmesi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Ng, W. L. 2007. A simple classifier for multiple criteria ABC analysis. *European Journal of Operational Research*, 177, 344–353.
- Park, J., Bae, H., & Bae, J. 2014. Cross-evaluation-based weighted linear optimization for multi-criteria ABC inventory classification. *Computers and Industrial Engineering*, 76, 40-48.
- Partovi, F.Y., & Anandarajan, M. 2002. Classifying inventory using an artificial neural network approach. *Comput. Ind. Eng.*, 41 (4), 389–404.
- Partovi, F. Y., & Burton, J. 1993. Using the analytic hierarchy process for ABC analysis. *International Journal of Operations & Production Management*, 13(9), 29–44.
- Özdemir, A., & Özveri, O. 2004. Çok kriterli envanter sınıflandırmasında, analitik hiyerarşi süreci analizinin uygulanması. *D.E.Ü.İ.İ.B.F. Dergisi*, 19(2), 137-154.
- Ramanathan, R. 2006. ABC inventory classification with multiple criteria using weighted linear optimization. *Computers & Operations Research*, 33(3), 695 - 700.
- Rezaei, J., & Dowlathshahi, S. 2010. A rule-based multi-criteria approach to inventory classification. *International Journal of Production Research*, 48(23), 7107–7126.
- Saedi, S., Kundakcioglu, O. E., & Henry, A. C. 2015. Mitigating the impact of drug shortages for a healthcare facility: An inventory management approach. *European Journal of Operational Research*, 251(1), 1-17.
- Sangaiah, A. K., Thangavelu, A. K., Gao, X. Z., Anbazhagan, N., & Durai, M. S. (2015) An ANFIS approach for evaluation of team-level service climate in GSD projects using Taguchi-genetic learning algorithm. *Applied Soft Computing* 30:628–635
- Soylu, B., & Akyol, B. 2014. Multi-criteria inventory classification with reference items. *Computers and Industrial Engineering*, 69, 12-20.
- Stanford, R., & Martin, W. 2007. Towards normative model for inventory cost management in a generalized ABC classification system. *Journal of the Operational Research Society*, 58(7), 922-928.

- Saraç, E. 2012. Bir Çağrı Merkezindeki Projelerin ANFIS Metodu ile Değerlendirilmesi ve Seçimi . Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Staub, S., Karaman, E., Kaya, S., Karapınara, H., & Güven, E. 2015. Artificial Neural Network and Agility. *Procedia - Social and Behavioral Sciences*, 195, 1477-1485.
- Sumathi, S., Paneerselvam, S. 2010. *Computational Intelligence Paradigms: Theory & Applications using MATLAB*. CRC Press Yayınları, 1-821.
- Tang, J., Zhang, G., Wanga, Y., Wang, H., & Liu, F. 2015. A hybrid approach to integrate fuzzy c-means based imputation method with genetic algorithm for missing traffic volume data estimation. *Transportation Research*, 51, 29-40.
- Torabi, S., Hatefi, S., & Pay, B. S. 2012. ABC inventory classification in the presence of both quantitative and qualitative criteria. *Computers & Industrial Engineering*, 63(2), 530–537.
- Tsai, C.-Y., & Yeh, S.-W. 2008. A multiple objective particle swarm optimization approach for inventory classification. *International Journal of Production Economics*, 114(2), 656–666.
- Tuna, İ. 2015. Borsa İstanbul (BIST) 30’da Kayıtlı Sanayi Şirketlerinin Sermaye Artırımlarının Tahmini. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 12, 31-45.
- Verma, H., & Sharan, A. A. 2015. An Improved Intuitionistic Fuzzy C-means Clustering Algorithm Incorporating Local Information For Brain Image Segmentation. *Applied Soft Computing Journal*.
- Wali, W., Al-Shamma, A., Hassan, K. H., & Cullen, J. 2012. Online genetic-ANFIS temperature control for advanced microwave biodiesel reactor. *Journal of Process Control* 22 (7), 1256– 1272.
- Wikaisuksakul, S. 2014. A multi-objective genetic algorithm with fuzzy c-means for automatic data clustering. *Applied Soft Computing*, 24, 679–691.
- Wu, J.-D., & Kuo, J.-M. 2010. Fault conditions classification of automotive generator using an adaptive neuro-fuzzy inference system. *Expert Systems with Applications*, 37(12), 7901–7907.
- Wu, R.-N., Chung, I.-H., & Chang, C.-k. (2014) Classification of partial discharge patterns in GIS using adaptive neuro-fuzzy inference system. *Journal of the Chinese Institute of Engineers* 37(8), 1043–1054.

- Yıldız, K., Çamurcu, Y., & Doğan, B. 2010. Veri Madenciliğinde Temel Bileşenler Analizi ve Negatifsiz Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi. Akademik Bilişim Konferansı, Muğla, 207-213.
- Yuan, Z., Wang, L.-N., & Ji, X. 2014. Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS. *Advances in Engineering Software*, 67, 156–163.
- Yücel, A., & Güneri, A. F. 2010. Application Of Adaptive Neuro Fuzzy Inference System To Supplier Selection Problem . *Journal of Engineering and Natural Sciences*, 224-234.
- Zadeh, L. A. 1965. Fuzzy sets. *Information and Control*, 8(3), 338–353.
- Zadeh, L. A. 2009. Toward extended fuzzy logic - A first step. *Fuzzy Sets and Systems*, 160, 3175 – 3181.
- Zapata, J., Vilar, R., & Ruiz, R. 2010. An adaptive-network-based fuzzy inference system for classification of welding defects. *NDT&E International*, 43(3), 191–199.
- Zheng, H., Jiang, B., & Lu, H. 2011. An adaptive neural-fuzzy inference system (ANFIS) for detection of bruises on Chinese bayberry (*Myrica rubra*) based on fractal dimension and RGB intensity color. *Journal of Food Engineering*, 104(4), 663–667.
- Zhou, P. and Fan, L., 2007. A note on multi-criteria ABC inventory classification using weighted linear optimization. *European Journal of Operational Research*, 182 (3), 1488–1491.
- Zhou, K., & Yang, S. 2016. Exploring the uniform effect of FCM clustering: A data distribution perspective. *Knowledge-Based Systems*, 96, 76-83.

ÖZGEÇMİŞ

Elif İsen, 25.07.1991'de Sakarya'da doğdu. İlk, orta ve lise eğitimini Sakarya'da tamamladı. 2009 yılında Arifiye Anadolu Öğretmen Lisesi'nden mezun oldu. 2009 yılında başladığı Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nü 2014 yılında bitirdi. 2014 yılında başladığı Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nde yüksek lisans eğitimine halen devam etmektedir.

