



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ZOOTEKNİ ANABİLİM DALI

**TARIMSAL VERİLERİN DOĞRUSAL OLMAYAN
ÇOK DEĞİŞKENLİ BULANIK REGRESYON
YÖNTEMİ İLE ANALİZİ**

Aslı AKILLI

DOKTORA TEZİ

KIRŞEHİR / 2019



T.C.
KIRŞEHİR AHİ EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ZOOTEKNİ ANABİLİM DALI

**TARIMSAL VERİLERİN DOĞRUSAL OLMAYAN
ÇOK DEĞİŞKENLİ BULANIK REGRESYON
YÖNTEMİ İLE ANALİZİ**

Ash AKILLI

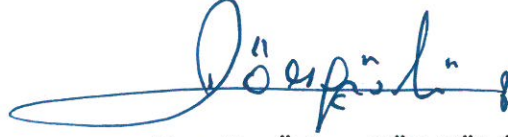
DOKTORA TEZİ

DANIŞMAN
Doç. Dr. Özkan GÖRGÜLÜ

KIRŞEHİR / 2019

“Tarımsal verilerin doğrusal olmayan çok deęişkenli bulanık regresyon yöntemi ile analizi” adlı bu çalışma 03/01/2019 tarihinde aşığıdaki jüri tarafından Zootečni Anabilim Dalında Doktora tezi olarak kabul edilmiştir.

Tez Jürisi



Doç. Dr. Özkan GÖRGÜLÜ
Kırşehir Ahi Evran Üniversitesi
Tıp Fakültesi



Prof. Dr. Kamile ŞANLI KULA
Kırşehir Ahi Evran Üniversitesi
Fen Edebiyat Fakültesi



Prof. Dr. Ufuk KARADAVUT
Kırşehir Ahi Evran Üniversitesi
Ziraat Fakültesi



Prof. Dr. Soner ÇANKAYA
Ondokuz Mayıs Üniversitesi
Yaşar Doęu Spor Bilimleri Fakültesi



Doç. Dr. Taner TUNÇ
Ondokuz Mayıs Üniversitesi
Fen Edebiyat Fakültesi

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Bu çalışma Ahi Evran Üniversitesi Bilimsel Araştırma Projeleri biriminin PYO_TIP.4003/2.14.002 numaralı projesi ile desteklenmiştir.

Aslı AKILLI

ÖNSÖZ

Tez çalışmamın gerçekleşmesinde gerekli bilgi, yardım ve desteklerini sunan, rehberliği ile bana yol gösteren, kendisini her zaman örnek aldığım, eğitim ve meslek hayatımda çok önemli bir yere sahip olan değerli danışman Hocam Sayın Doç. Dr. Özkan Görgülü'ye sonsuz teşekkürlerimi sunarım. Doktora öğrenimimin Ege Üniversitesi'nde geçen sürecinde, ders ve yeterlilik dönemlerimde danışmanlığımı yürüten, tüm akademik hayatımda desteğini her daim yanımda hissettiğim, saygıdeğer Hocam Sayın Prof. Dr. Hülya Atıl'a teşekkürlerimi sunarım.

Tez İzleme Komitesi'nde yer alan, değerli bilgilerini paylaşan kıymetli hocalarım Sayın Prof. Dr. Kamile Şanlı Kula ve Sayın Prof. Dr. Ufuk Karadavut'a teşekkürlerimi sunarım.

Tez çalışmamın araştırma sürecinde sağladığı desteklerden dolayı çok değerli büyüğüm, ağabeyim Erdal Akıllı'ya teşekkürlerimi sunarım. Tez çalışmasında kullanılan veri setinin temin edilmesinde büyük yardımları olan kıymetli amcam Haydar Akkaptan ve canım babam Hüseyin Akkaptan'a şükranlarımı sunarım.

Bugünlere gelmemde emeklerini asla ödeyemeyeceğim aileme; hayatımın her aşamasında tükenmeyen sabrı ve inancı ile her zaman yanımda olan beni yetiştiren ve okumamı sağlayan canım anneme sonsuz teşekkürler.

Birlikte ilerlediğimiz bu zorlu yolda; her daim hissettiğim anlayışı, saygısı ve sonsuz sevgisi ile karanlığa düştüğüm zamanlarda bana ışık tutan ve her zaman destek olan; akademisyen kimliği ve çalışkanlığı ile bilim dünyasına ve bana örnek olan hayat arkadaşım, canım, Erman Akıllı'ya sonsuz teşekkürlerimi ve şükranlarımı sunarım. Bu çalışmamı tüm kalbimle kendisine armağan ediyorum.

Ocak, 2019

Aslı AKILLI

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	xii
SİMGE VE KISALTMA LİSTESİ	xvi
ÖZET	xvii
ABSTRACT	xix
1. GİRİŞ	1
2. LİTERATÜR İNCELEMESİ	5
3. MATERYAL VE YÖNTEM.....	24
3.1. Klasik Regresyon Analizi.....	24
3.1.1. Klasik Doğrusal Regresyon Analizi.....	24
3.1.2. Klasik Doğrusal Olmayan Regresyon Analizi.....	27
3.2. Klasik Regresyon Analizi Kapsamında Kullanılan Fonksiyon Yapıları.....	33
3.2.1. Logistic Model	35
3.2.2. Compartmental Model	35
3.2.3. McNally Model.....	36
3.2.4. Gamma Model	36
3.3. Bulanık Kümeler	37
3.4. Bulanık Sayı Kavramı	41
3.5. Bulanık Regresyon Analizi	49
3.5.1. Bulanık Doğrusal Regresyon Analizi	49
3.5.1.1. Bulanık Doğrusal Regresyon Analizi ve "h" değeri.....	52
3.5.1.2. Bulanık Doğrusal Regresyon Analizinde Parametre Tahmin Yöntemleri.....	55
3.5.2. Bulanık Doğrusal Olmayan Regresyon Analizi.....	70
3.5.2.1. Yapay Sinir Ağları.....	71

3.5.2.2. Yapay Sinir Ağları Kallanılarak Bulanık Doğrusal Olmayan Regresyon Modellemesi	100
3.5.2.3.En Küçük Kareler Destek Vektör Makineleri	106
3.5.2.4. En Küçük Kareler Destek Vektör Makinelerine Dayalı Doğrusal Olmayan Bulanık Regresyon Analizi.....	110
4. ARAŞTIRMA BULGULARI.....	115
4.1. Tek Değişkenli Klasik Doğrusal Olmayan Regresyon Analizi Uygulama Sonuçları.....	115
4.2. Çok Değişkenli Klasik Doğrusal Olmayan Regresyon Analizi Uygulama Sonuçları.....	120
4.3. Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları.....	122
4.4. Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları.....	135
4.5. En Küçük Kareler Destek Vektör Makinelerine Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları	150
4.6. En Küçük Kareler Destek Vektör Makinelerine Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları	180
5. SONUÇ VE ÖNERİLER.....	194
KAYNAKLAR.....	204
ÖZGEÇMİŞ	225

ŞEKİL LİSTESİ

	Sayfa No
Şekil 3.1. Normal (a) ve Normal Olmayan (b), Dışbükey (c) ve Dışbükey Olmayan (d) Bulanık Kümeler.....	39
Şekil 3.2. Üçgen ve Yamuk Bulanık Sayılar.....	41
Şekil 3.3. Bulanık Sayılarda Toplama İşlemi Gösterimi.....	44
Şekil 3.4. Bulanık Sayılarda Çıkarma İşlemi Gösterimi.....	44
Şekil 3.5. Bulanık Sayılarda Çarpma İşlemi Gösterimi.....	45
Şekil 3.6. Bulanık Sayılarda Bölme İşlemi Gösterimi.....	45
Şekil 3.7. M Bulanık Sayısına İlişkin Gösterim.....	46
Şekil 3.8. Simetrik Olmayan (a) ve Simetrik (b) Üçgensel Bulanık Sayı.....	48
Şekil 3.9. \tilde{A}_j Bulanık Katsayısının Üyelik Fonksiyonu.....	51
Şekil 3.10. Bulanık Çıktı Gösterimi.....	51
Şekil 3.11. h Değeri İncelemesi.....	53
Şekil 3.12. Farklı h Değerleri için $ L^{-1}(h) $ Değişimleri.....	54
Şekil 3.13. Biyolojik Sinir Hücresi.....	74
Şekil 3.14. Yapay Sinir Hücresi.....	74
Şekil 3.15. Sign Aktivasyon Fonksiyonu (a), Step Aktivasyon Fonksiyonu (b).....	76
Şekil 3.16. Sigmoid Aktivasyon Fonksiyonu (a), Doğrusal Aktivasyon Fonksiyonu (b).....	77
Şekil 3.17. Hiperbolik Tanjant Aktivasyon Fonksiyonu (a), Sinus Aktivasyon Fonksiyonu (b).....	78
Şekil 3.18. Yapay Sinir Ağının Genel Görünümü.....	79
Şekil 3.19. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları.....	79
Şekil 3.20. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları.....	80
Şekil 3.21. Danışmanlı Öğrenme Yapısı.....	82
Şekil 3.22. Danışmansız Öğrenme Yapısı.....	83
Şekil 3.23. Takviyeli Öğrenme Yapısı.....	84
Şekil 3.24. Adaline Yapısı.....	86
Şekil 3.25. Madaline Yapısı.....	86

Şekil 3.26. Çok Katmanlı İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağının Şekilsel Gösterimi.....	89
Şekil 3.27. Tek Katmanlı N Nöronlu Hopfield Ağı.....	93
Şekil 3.28. Jordan Ağı Yapısı.....	94
Şekil 3.29. Elman Ağı Gösterimi	95
Şekil 3.30. Kohonen Modeli.....	96
Şekil 3.31. LVQ Ağı Yapısı	98
Şekil 3.32. ART Yapısı	100
Şekil 4.1. Günlük Ölçülmüş Gözlemlenen Değerler ve Lojistik Model Tahmin Sonuçları.....	117
Şekil 4.2. Günlük Ölçülmüş Gözlemlenen Değerler ve Compartmental Model Tahmin Sonuçları.....	117
Şekil 4.3. Günlük Ölçülmüş Gözlemlenen Değerler ve McNally Model Tahmin Sonuçları.....	117
Şekil 4.4. Günlük Ölçülmüş Gözlemlenen Değerler ve Gamma Model Tahmin Sonuçları.....	118
Şekil 4.5. Haftalık Ölçülmüş Gözlemlenen Değerler ve Logistic Model Tahmin Sonuçları.....	119
Şekil 4.6. Haftalık Ölçülmüş Gözlemlenen Değerler ve Compartmental Model Tahmin Sonuçları.....	119
Şekil 4.7. Haftalık Ölçülmüş Gözlemlenen Değerler ve McNally Model Tahmin Sonuçları.....	120
Şekil 4.8. Haftalık Ölçülmüş Gözlemlenen Değerler ve Gamma Model Tahmin Sonuçları.....	120
Şekil 4.9. Günlük Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi Sonuçları.....	122
Şekil 4.10. Haftalık Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi Sonuçları.....	122
Şekil 4.11. Günlük Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	125

Şekil 4.12. Günlük Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	127
Şekil 4.13. Haftalık Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	130
Şekil 4.14. Haftalık Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	131
Şekil 4.15. Günlük Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	139
Şekil 4.16. Günlük Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	140
Şekil 4.17. Haftalık Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	144
Şekil 4.18. Haftalık Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	146
Şekil 4.19. Günlük Ölçülmüş Test Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	152
Şekil 4.20. Günlük Ölçülmüş Geçerlilik Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	154
Şekil 4.21. Haftalık Ölçülmüş Test Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	157
Şekil 4.22. Haftalık Ölçülmüş Geçerlilik Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	158

Şekil 4.23. Günlük Ölçülmüş Test Verileri için Polinomiyal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	163
Şekil 4.24. Günlük Ölçülmüş Geçerlilik Verileri için Polinomiyal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.....	165
Şekil 4.25. Haftalık Ölçülmüş Test Verileri için Polinomiyal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	167
Şekil 4.26. Haftalık Ölçülmüş Geçerlilik Verileri için Polinomiyal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.....	168
Şekil 4.27. Günlük Ölçülmüş Test Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	172
Şekil 4.28. Günlük Ölçülmüş Geçerlilik Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	174
Şekil 4.29. Haftalık Ölçülmüş Test Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	177
Şekil 4.30. Haftalık Ölçülmüş Geçerlilik Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	178
Şekil 4.31. Günlük Ölçülmüş Test Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.....	184
Şekil 4.32. Günlük Ölçülmüş Geçerlilik Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları	185
Şekil 4.33. Haftalık Ölçülmüş Test Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.....	189

Şekil 4.34. Haftalık Ölçülmüş Geçerlilik Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları 191



TABLO LİSTESİ

	Sayfa No
Tablo 3.1. Biyolojik Sinir Hücresi ile Yapay Sinir Hücresi İşlevsel Karşılaştırması	74
Tablo 3.2. İstatistiksel Hata Kriterleri	106
Tablo 3.3. Kernel Fonksiyonları	110
Tablo 4.1. Günlük Ölçülmüş Veriler için Tek Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları	116
Tablo 4.2. Haftalık Ölçülmüş Veriler için Tek Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları	118
Tablo 4.3. Günlük Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları	121
Tablo 4.4. Haftalık Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları	121
Tablo 4.5. Günlük Ölçülmüş Veriler için Sinir Ağlarına Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	123
Tablo 4.6. Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	128
Tablo 4.7. Günlük Ölçülmüş Veriler için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri	132
Tablo 4.8. Haftalık Ölçülmüş Veriler için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri	133
Tablo 4.9. Günlük Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	134
Tablo 4.10. Günlük Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	134
Tablo 4.11. Haftalık Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	134
Tablo 4.12. Haftalık Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	134

Tablo 4.13. Günlük Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	136
Tablo 4.14. Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	142
Tablo 4.15. Günlük Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.....	147
Tablo 4.16. Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.....	147
Tablo 4.17. Günlük Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	148
Tablo 4.18. Günlük Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	148
Tablo 4.19. Haftalık Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	149
Tablo 4.20. Haftalık Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	149
Tablo 4.21. Günlük Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.....	150
Tablo 4.22. Haftalık Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.....	155
Tablo 4.23. Günlük Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	159
Tablo 4.24. Haftalık Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	160
Tablo 4.25. Günlük Ölçülmüş Test Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	160
Tablo 4.26. Günlük Ölçülmüş Geçerlilik Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	160

Tablo 4.27. Haftalık Ölçülmüş Test Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	161
Tablo 4.28. Haftalık Ölçülmüş Geçerlilik Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	161
Tablo 4.29. Günlük Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	161
Tablo 4.30. Haftalık Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları	161
Tablo 4.31. Günlük Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	169
Tablo 4.32. Haftalık Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	169
Tablo 4.33. Günlük Ölçülmüş Test Seti için Polynomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	170
Tablo 4.34. Günlük Ölçülmüş Geçerlilik Seti için Polynomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	170
Tablo 4.35. Haftalık Ölçülmüş Test Seti için Polynomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	170
Tablo 4.36. Haftalık Ölçülmüş Geçerlilik Seti için Polynomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	170
Tablo 4.37. Günlük Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.....	171
Tablo 4.38. Haftalık Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.....	171
Tablo 4.39. Günlük Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	175

Tablo 4.40. Haftalık Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.....	175
Tablo 4.41. Günlük Ölçülmüş Test Seti için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	179
Tablo 4.42. Günlük Ölçülmüş Geçerlilik Seti için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	179
Tablo 4.43. Haftalık Ölçülmüş Test Seti için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	179
Tablo 4.44. Haftalık Ölçülmüş Geçerlilik Seti için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları	179
Tablo 4.45. Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin HKO Değerleri.....	181
Tablo 4.46. Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMYH Değerleri.....	181
Tablo 4.47. Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMH Değerleri.....	182
Tablo 4.48. Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin HKO Değerleri.....	186
Tablo 4.49. Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMYH Değerleri.....	186
Tablo 4.50. Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMH Değerleri.....	187
Tablo 4.51. Günlük Ölçülmüş Test Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	191
Tablo 4.52. Günlük Ölçülmüş Geçerlilik Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	191
Tablo 4.53. Haftalık Ölçülmüş Test Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	192
Tablo 4.54. Haftalık Ölçülmüş Geçerlilik Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.....	192

SİMGE VE KISALTMA LİSTESİ

Kısaltmalar	Açıklama
HKO	: Hata Kareler Ortalaması
OMYH	: Ortalama Mutlak Yüzde Hata
OMH	: Ortalama Mutlak Hata
BR	: Bayesian Regularization
LM	: Levenberg-Marquardt
SCG	: Scaled Conjugate Gradient
GD	: Gradient Descent
GDM	: Gradient Descent with Momentum
GDX	: Gradient Descent with Momentum and Adaptive Learning Rate
CGF	: Conjugate Gradient Backpropagation with Fletcher-Reeves Updates
CGB	: Conjugate Gradient Backpropagation with Powell-Beale Restarts
BFG	: Brayde Fletcher Gold Farlo Shanno Quasi Newton Backpropagation
OSS	: One Step Secant Algorithm
DVM	: Destek Vektör Makineleri
EKK-DVM	: En Küçük Kareler Destek Vektör Makineleri
RBF	: Radial Basis Function
FRBFN	: Fuzzified Radial Basis Function Network
YP	: Yumurta Performansı
YA	: Yumurta Ağırlığı

ÖZET

DOKTORA TEZİ

TARIMSAL VERİLERİN DOĞRUSAL OLMAYAN ÇOK DEĞİŞKENLİ BULANIK REGRESYON YÖNTEMİ İLE ANALİZİ

Ash AKILLI

Kırşehir Ahi Evran Üniversitesi

Fen Bilimleri Enstitüsü

Zootekni Anabilim Dalı

Danışman: Doç. Dr. Özkan GÖRGÜLÜ

Gerçek dünya ve içinde karşılaşılan problemler karmaşık ve belirsizliklerle doludur. Bulanık mantık ve ilişkili yöntemler, araştırmacılara doğaya uygun bakış açıları sunmakta ve belirsizliği sayısallaştırabilmek adına geliştirilmiş dinamik yöntemler arasında yer almaktadır. Tez çalışması kapsamında incelenen doğrusal olmayan regresyon problemine ilişkin sistem yapısında doğada belirgin olmayan olguların var olduğu tespit edilmiştir. Tarımsal alanda oldukça yeni kullanılmaya başlanan bulanık regresyon yöntemi ile literatüre yeni bir bakış açısı kazandırılarak, klasik yöntemlere göre gerçeğe daha yakın tahminler yapabilecek bir modelin oluşturulması hedeflenmiştir. Yumurta performansı ve yumurta ağırlığı değişkenlerine ilişkin bulanık verilerin, tek ve çok değişkenli doğrusal olmayan bulanık regresyon analizleri yapay sinir ağları ve en küçük kareler destek vektör makineleri ile entegreli olarak yapılandırılmıştır. Doğrusal olmayan bulanık regresyon tahmin sonuçları, hem tek değişkenli hem de çok değişkenli doğrusal olmayan klasik regresyon analizi sonuçları ile karşılaştırmalı olarak incelenmiştir. Bu noktada bulanık karakterlere sahip bir zeki sistemin, geleneksel yöntemlere göre daha iyi performans gösterdiği belirlenmiştir. Analiz sonuçları çok değişkenli doğrusal olmayan bulanık

regresyon analizinin, klasik doğrusal olmayan regresyon analizine alternatif bir araç olarak kullanılabileceğini göstermektedir.

Ocak 2019, 228 Sayfa.

Anahtar Kelimeler: Doğrusal olmayan bulanık regresyon, yapay sinir ağları, en küçük kareler destek vektör makineleri, klasik regresyon.



ABSTRACT

Ph.D. THESIS

ANALYSIS OF AGRICULTURAL DATA WITH MULTIVARIATE NONLINEAR FUZZY REGRESSION METHOD

Aslı AKILLI

**Kirsehir Ahi Evran University
Science and Engineering Institute
Zootechnics Department**

Supervisor: Assoc. Prof. Dr. Özkan GÖRGÜLÜ

The problems encountered in the real world and within are filled with complexity and uncertainty. Fuzzy logic and its related methods provide researchers with appropriate views on nature and are among the dynamic methods developed to quantify uncertainty. It is determined that there are some nonspecific phenomena in the structure of the system related to the nonlinear regression problem examined within the scope of the thesis study. It is aimed to create a model that can make more accurate estimations according to the classical methods by giving a new perspective to the literature with the fuzzy regression method, which has been started to be used in agricultural field. The univariate and multivariate nonlinear fuzzy regression analyses of fuzzy data related to egg performance and egg weight variables are structured to be integrated with artificial neural networks and least squares support vector machines. The results of nonlinear fuzzy regression estimates are compared with the results of both univariate and multivariate nonlinear classical regression analysis. It has been determined that an intelligent system with fuzzified characters at this point performs better than conventional methods. The results of the analysis show that multivariate nonlinear fuzzy regression analysis can be used as an alternative to classical nonlinear regression analysis.

January 2019, 228 Pages.

Keywords: Nonlinear fuzzy regression, artificial neural networks, least squares support vector machines, classical regression.



1. GİRİŞ

İnsan beyninin çalışma prensipleri ve düşünce yapısı yüzyıllar boyunca çeşitli araştırmalara konu olmuştur. Sayısal işlemlerin kısa süreler içinde yapılmasını sağlayan ve son 50 yıl içerisinde büyük gelişmeler kaydeden bilgisayar teknolojilerinin insan beyninden ayrıldığı en önemli nokta, algılama ve sezinleme gibi yeteneklere sahip olmamasıdır. Gelişen teknoloji ile birlikte bilgisayar yazılımları, insan beyninin çalışma yapısını taklit edebilmekte ve karşılaşılan farklı problem yapıları için çeşitli yöntemler üretebilmektedir. Yapay zeka yöntemleri olarak da bilinen bu yöntemler; tahmin, sınıflandırma, örüntü tanıma ve çıkarım yapma gibi bir çok farklı işlevi yerine getirirken aynı zamanda geleneksel yöntemlere alternatif olarak da kullanılmaktadır. Günümüzde bilgisayar teknolojilerindeki gelişmeler, doğrusal ve doğrusal olmayan klasik regresyon analizine alternatif yapay zeka yöntemleri ve bulanık mantık tabanlı yöntemlerin kullanımında önemli artışlar sağlamıştır. Yapay zeka oldukça büyük bir araştırma alanıdır. Ekonomi, felsefe, matematik, sinir bilimi, dil bilimi, yaşam bilimleri, psikoloji, bilgisayar mühendisliği ve sibernetik gibi birçok farklı bilim dalında yapay zekâ çalışmaları gün geçtikçe artmaktadır. Yapay zeka çalışmalarının bilimsel açıdan hedefi insanların sahip olduğu algılama ve sonuç çıkarma gibi yeteneklerin makinelere belirli ölçülerde kazandırılması ve bu amaçla çeşitli yöntemlerin üretilmesidir. Bu bağlamda yapay zeka temelli yöntemler içerisinde yapay sinir ağları; bulanık mantık, destek vektör makineleri, genetik algoritmalar ve uzman sistemler bilimsel araştırmalarda en fazla kullanılan yöntem olarak öne çıkmaktadır.

Belirsizlik gerçek hayatta karşılaşılan olaylarda mevcuttur. Özellikle ölçmenin getirdiği sınırlamalar ile ölçme işlemi sırasında karşılaşılan hataların birleşiminden belirsizlik kaynaklanmaktadır. Klasik matematiksel yöntemler, belirsizlik içeren sistemlerde mevcut bilginin kesin olmayışı ve çevresel unsurlardan etkileniyor olmasından dolayı tatmin edici sonuçlar üretemeyebilir. Bu durumda, günümüzde sistem yapısındaki belirsizliğin ifade edilmesi amacıyla bulanık modellemeye ilişkin çeşitli yaklaşımlar geliştirilmiştir (Çelikyılmaz ve Türkşen, 2009; Türkşen, 2015). Gerçek hayatta karşılaşılan belirsizlik içeren problemlerin çözümünde oldukça yaygın olarak kullanılan bulanık mantığın, bilim

dünyasına kazanımı Lotfi A. Zadeh isimli bilim insanı tarafından “Fuzzy Sets” başlıklı makale ile sağlanmıştır. Bulanık mantık klasik mantığa göre gerçek hayatta karşılaşılan olaylara çok daha uygun ve esnek bir bakış açısı kazandırmakta, insanlara karar alma ve tahmin süreçlerinde büyük kolaylıklar sağlamaktadır (Zadeh 1965). Bulanık mantık, bulanık küme teorisi ve üyelik fonksiyonları aracılığı ile dilsel değişkenlerin analiz edilmesinde kullanılmaktadır. Sistem yapısındaki bulanıklık ve belirsizlik, geleneksel yöntemlere göre daha esnek ve doğal hayata daha uygun bir bakış açısının benimsenmesini gerektirmiştir. Gerçek hayatta karşılaşılan problemlerin büyük bir bölümü karmaşıktır ve bulanıklık içermektedir. Bu durumun en temel sebebi insanların düşünce yapısının ve ifade ediş biçiminin sözel nitelikte olmasıdır. Dilsel değişkenlerin regresyon analizinde kullanımı klasik regresyon analizinin kapsamı dışında yer almaktadır (Cheng ve Lee, 2001). Bulanık mantığın klasik regresyon analizine uyarlandığı yöntemlerden birisi olan bulanık regresyon analizi, değişkenler arası ilişkilerin belirsizlik niteliği taşıdığı ve klasik regresyon analizinin varsayımlarının sağlanamadığı durumlarda, bulanık verilerin modellenmesi amacıyla sunulmuş yeni bir tahmin yaklaşımıdır. Bulanık regresyon analizi ilk olarak Tanaka ve diğ., (1982) tarafından ortaya konulmuştur. Bulanık regresyon analizini klasik regresyon analizinden ayıran en önemli özelliklerden birisi parametrelerin kesin sayı olarak değil, bulanık sayı şeklinde aralık olarak ifade edilmesidir. Burada bağımlı değişkenin gözlem değerleri için bir alt ve bir de üst sınır olmak üzere aralık tahmini gerçekleştirilir. Bir başka önemli husus klasik regresyon analizinde sapmalar gözlemlenen ve tahmin edilen değerler arasındaki farktır. Bulanık regresyon analizinde ise sapma değerleri sistemin yapısında var olan belirsizlikten, sistem parametrelerinin bulanıklığından kaynaklıdır. Sistem yapısındaki bulanıklık Lotfi A. Zadeh tarafından ortaya konulmuş “genişletme prensibi” ile tanımlanan bulanık fonksiyonlarca açıklanmaktadır. Bulanık regresyon analizi ile ilgili bir diğer ayrıntı, girdi ve çıktılarının hem kesin sayı hem de bulanık sayı olarak modelde yer alabilmesidir. Klasik regresyon analizinde ise sadece gerçel sayılar olarak analizlere dahil edilebilmektedirler (Tanaka ve diğ., 1982; Tanaka ve diğ., 1989; Chang ve Lee, 1994).

Klasik regresyon analizinde olduğu gibi bulanık regresyon analizinde de değişkenler arası ilişkiler doğrusal ve doğrusal olmayan formlarda olabilir. Literatürde doğrusal bulanık regresyon analizinde parametrelerin tahmini için kullanılan çeşitli yöntemler bulunmaktadır. Tez çalışması kapsamında matematiksel programlamaya dayalı parametre tahmin yöntemleri (Tanaka ve diğ.,1982; Savic ve Pedrycz, 1991; Sakawa ve Yano, 1992;

Peters, 1994; Sakawa, 2013) ve en küçük kareler yöntemine dayalı parametre tahmin yöntemleri (Diamond, 1988; Diamond ve Tanaka, 1998; Wang ve Tsaur, 2000a) incelenmiş ve yöntemlere ilişkin teorik bilgilere yer verilmiştir.

Bulanık doğrusal regresyon analizinde değişkenler arasındaki fonksiyonel ilişkinin tanımlanmasında model doğrusallık varsayımı altında ele alınır. Ancak veriler doğrusal olmayan bir yapıya sahip olduğunda bu varsayım modelleme hatalarına yol açabilmektedir. Bu nedenle bulanık doğrusal regresyon yöntemlerinin eksiklerinin üstesinden gelebilmek için bulanık doğrusal olmayan regresyon yöntemleri önerilmektedir. Değişkenler arası ilişkiler doğrusal olmayan bir yapıda olduğunda fonksiyonel ilişkilerin tanımlanması zorlaşmaktadır. Bu nedenle güçlü tahmin yeteneğine sahip, etkili optimizasyon algoritmaları ile geliştirilen ve sezgisel olarak yorumlanabilen regresyon modelleri üretilmektedir (Zhang ve diğ., 2005). Doğrusal olmayan bulanık regresyon analizi uygulamada oldukça yeni bir yöntemdir. Bulanık çıktıların elde edilmesi sürecinde doğrusal olmayan bulanık regresyon analizi çözümlemeleri için yapay sinir ağları ve destek vektör makineleri gibi yapay zeka temelli yöntemler tercih edilebilmektedir. Literatürde özellikle canlı materyal ile çalışan bilim dallarında kısıtlı sayıda uygulamaya yönelik bilimsel çalışmalar mevcuttur.

Doğrusal olmayan klasik regresyon analizi, uygulamalı bilim dallarının bir çoğunda olduğu gibi, tarım ve hayvancılık alanında da oldukça önemli bir araçtır. Tarımsal ürünlerin işlenmesinde, çeşitli toprak analizlerinde, yemlerin besin madde içerikleri ile hayvanların büyüme, laktasyon ve yumurta verimlerinin modellenmesi gibi konularda doğrusal olmayan model yapıları kullanılmaktadır. Doğrusal olmayan modeller, bahsi geçen veri yapılarını doğrusal yapıdaki modellere göre daha iyi temsil edebilmektedir. Doğrusal olmayan regresyon analizinin çalışma sürecinde, doğrusal modellere göre, birden fazla adımın dikkatli bir şekilde izlenmesi gerekliliği ve her adımda üzerinde durulması gereken önemli noktaların olduğu görülmektedir.

Tez çalışması kapsamında tek ve çok değişkenli doğrusal olmayan bulanık regresyon analizi, yumurta performansı ve yumurta ağırlığı değişkenleri için bulanık tahmin aralığı oluşturmak üzere, yapay sinir ağları ve en küçük kareler destek vektör makineleri ile birlikte ele alınmıştır. Bu bağlamda analiz sonuçları altı farklı başlık altında ele alınmıştır. Bu başlıklar: Tek ve çok değişkenli klasik doğrusal olmayan regresyon analizi, yapay sinir ağlarına dayalı tek ve çok değişkenli doğrusal olmayan bulanık regresyon analizi, en küçük

kareler destek vektör makinalarına dayalı tek ve çok deęişkenli doğrusal olmayan bulanık regresyon analizi tahmin sonuçları şeklinde bildirilmiştir. Bulanık alt ve üst sınırların elde edilmesinde kullanılan bu yöntemler belirsizlik ortamında tahmin işleminin gerçekleştirilmesinde oldukça önemli bir yere sahiptir.

Bu çalışmada, ülkemizde yaşam bilimleri alanında oldukça yeni olan doğrusal olmayan bulanık regresyon analizi yöntemine ilişkin temel bilgiler sunulmuş ve doğrusal olmayan bulanık regresyon analizinin tarımsal alanda uygulanabilirliği araştırılmış, klasik yöntemlere göre farklı bakış açıları sunan ve daha düşük hata payları ile başarılı tahminler gerçekleştiren yeni yöntemlerin kazanımı amaçlanmıştır. Bu amaç doğrultusunda, hayvancılıkta doğrusal olmayan regresyon analizi kapsamında ele alınan problem yapılarından yumurta üretim eğrilerinin modellenmesi amacıyla, elde edilen veri setlerine doğrusal olmayan bulanık regresyon analizi tek ve çok deęişkenli olarak uygulanmıştır. Araştırmaya konu olan veri setlerine, literatür alan biliminde kabul görmüş doğrusal olmayan klasik regresyon modellerinin uygulamaları da gerçekleştirilmiştir. Elde edilen sonuçlar karşılaştırmalı olarak değerlendirmeye alınmıştır.

Çalışmanın literatür incelemesi bölümünde, tarımsal alanda ve diğer yaşam bilimleri alanlarında doğrusal ve doğrusal olmayan bulanık regresyon analizi kullanılarak yapılan çalışmalara ilişkin literatür bilgileri yer almaktadır.

Materyal ve yöntem bölümünde bulanık kümeler, bulanık sayı kavramı, doğrusal ve doğrusal olmayan bulanık regresyon analizi ile doğrusal ve doğrusal olmayan klasik regresyon analizine ilişkin teorik bilgiler sunulmuştur.

Araştırma bulguları bölümünde, araştırmaya ilişkin analiz sonuçları yer almaktadır.

Son bölümde analiz sonuçları yorumlanmış, benzer çalışmaların sonuçları ile değerlendirmeler yapılmış ve önerilerde bulunulmuştur.

2. LİTERATÜR İNCELEMESİ

Zadeh (1965), bulanık bir kümeyi sürekli üyelik derecelerine sahip bir nesnelere kümesi olarak tanımlamıştır. Çalışmada, bulanık kümeler her nesneye $[0, 1]$ aralığında üyelik derecesi atayan üyelik fonksiyonları tarafından nitelendirilmektedir. Bulanık kümeler ile ilgili kapsama, birleşim, kesişim ve bir kümenin tümleyeni gibi kavramlar ile cebirsel işlemler açıklanmıştır.

Dubois ve Prade (1979), çalışmalarında bulanık sayılara ilişkin cebirsel işlemler ile ilgili bilgi sunmuşlar ve L-R tipli bulanık sayıları incelemişlerdir.

Tanaka ve diğ., (1982), çalışmalarında bulanık regresyon analizine ilişkin ilk uygulamayı gerçekleştirmişlerdir. Bulanık doğrusal fonksiyonları Zadeh'in genişletme prensibine göre tanımlamışlardır. Araştırmacılar regresyon analizinde yer alan gözlenen ve tahmin edilen değerler arasındaki sapmaların, bulanık regresyon analizinde sistem yapısında bulunan belirsizlikten kaynaklı olduğunu belirtmişlerdir. Parametrelerin üçgensel bulanık sayı olarak ifade edildiği bu çalışmada, prefabrik evlerin fiyat mekanizması üzerine bir örnek uygulama sunulmuştur.

Tanaka (1987), çalışmasında bulanık aralık analizini kullanmıştır. Bulanık sayılardan oluşan bulanık çıktılarının tahminine ilişkin alt ve üst tahmin değerlerini doğrusal programlama probleminin çözümü ile elde etmiştir. Çalışmada bildirilen yöntemin karmaşık olması ve artıklar için en iyi uyum ölçümünün bildirilmemiş olması olumsuzluk teşkil etmektedir.

Diamond (1988a), çalışmasında bağımsız değişkenin kesin, bağımlı değişkenin ise üçgensel bulanık sayı olduğu bulanık regresyon modelinde en küçük kareler optimizasyon problemini çözümlenmeyi amaçlamıştır.

Diamond (1988b), çalışmasında doğrusal bulanık regresyon analizi için en çok olasılık tahminleyicisini kullanmıştır.

Tanaka ve Watada (1988), çalışmalarında bulanık regresyon analizini, bulanık sayıların kullanıldığı aralık analizini içeren yeni bir yöntem ile geliştirmişlerdir. Buna göre veri

setinin büyüklüğü doğrultusunda h değerinin farklı seçimlerine ilişkin öneride bulunmuşlardır. Veri seti yeterli büyüklükte olduğu takdirde h değerinin “0”; ideal seviyeden küçük olması halinde ise h değerine daha büyük değerlerin verilmesi gerektiğini belirtmişlerdir.

Bardossy (1990), çalışmasında Tanaka ve diğ., (1982) tarafından sunulan bulanık regresyon analizi ile ilgili ilk çalışmayı genelleştirmiştir. Bulanık regresyon çözümlemesinde farklı belirsizlik seviyeleri en iyi tahmini elde etmek üzere tanımlanmış ve bununla ilgili iki farklı sayısal örnek çözümüne yer vermiştir.

Ishibuchi ve Tanaka (1990), çalışmalarında amaç fonksiyonu aralık katsayılarından oluşan bir matematiksel programlama problemini incelemişler ve bununla ilgili sayısal örneklere yer vermişlerdir.

Celmins (1991), çalışmasında doğrusal olmayan bulanık regresyon analizine ilişkin bir yöntem önermiştir. Sunulan çalışmada, Celmins (1987a) ve Celmins (1987b) tarafından yapılan çalışmaların sonuçları genel regresyon problemi şeklinde ele alınmıştır. Burada model eşitlikleri doğrusal olmayan yapıdadır ve modelin yanı sıra verilerin de bulanık sayı olduğu belirtilmiştir. Uygulanan modelleme prosedüründe, veri türü ve parametre bulanıklığı konik (conical) üyelik fonksiyonları ile sınırlandırılarak elde edilmiştir. Araştırmacı, terminal balistik ile ilgili sayısal bir örnek üzerine bulanık regresyon uygulanmasını gerçekleştirmiştir. Araştırma sonuçları başarılı bulunmuş, önerilen yöntemin gerçek yaşamda karşılaşılan problemlere uygulanabileceği belirtilmiştir.

Savic ve Pedrycz (1991), minimum bulanıklık kriterini geliştirerek doğrusal regresyon analizini iki aşamada inceleyen bir model önermişlerdir. Araştırmacılar bulanık regresyon analizinin incelenen problemin amacı ve uygulamanın doğasından oldukça etkilendiğini bildirmişlerdir. Ayrıca doğru modelin seçiminin farklı belirsizlik seviyelerinde oldukça karmaşık olduğunu da belirtmişlerdir.

Ishibuchi ve Tanaka (1992), bulanık regresyon analizi için sinir ağlarını kullanarak yeni bir yöntem tanıtmışlardır. Sinir ağlarının doğrusal olmayan model yapılarının çözümlenmesinde oldukça etkili bir yöntem olduğunu belirten araştırmacılar yöntemin karmaşıklık içeren sistemlerin çözümünde doğrusal programlama yöntemlerine göre daha başarılı olduğunu belirtmişlerdir. Bu amaçla inceledikleri yöntemleri kullanarak kalite değerlendirme problemine ilişkin bir uygulama gerçekleştirmişlerdir.

Sakawa ve Yano (1992), çalışmalarında girdi ve çıktıların bulanık sayı olduğu çok amaçlı bulanık regresyon analizinin çözümlemesini gerçekleştirmek üzere üç farklı algoritma tanımlamışlardır. Bunlar yinelemeli, karar vericiyle etkileşime dayanan ve etkileşimli algoritma şeklindedir. Çalışmada, yöntemlerin uygunluğunu ve etkinliğini göstermek üzere sayısal örneklere de yer verilmiştir.

Bardossy ve diğ., (1993), çalışmalarında farelerde tümör gelişim olasılığı ile buna etki eden bir maddenin arasındaki ilişkiyi doğrusal olmayan bulanık regresyon analizini kullanarak modellemişlerdir. Araştırmaya konu olan doz-etki modellerini altı adet veri göstergesi ile incelemişlerdir. Regresyon parametreleri doğrusal olmayan amaç fonksiyonunun minimize edilmesi ile elde edilmiştir. Kullandıkları yöntemin klasik regresyon analizine alternatif olarak uygulanabileceğini bildirmişlerdir.

Peters (1994), çalışmasında Tanaka ve diğ., (1982) tarafından önerilen yaklaşıma dayanan yeni bir doğrusal bulanık regresyon modeli tanıtmıştır. Çalışmada önerilen bulanık regresyon analizi bulanık aralıkları içermektedir. Ayrıca araştırmacının önerdiği modelin Tanaka'nın önerdiği modelin geliştirmesinde ve gerçek verilere uygulanmasında oldukça faydalı olduğu da belirtilmiştir.

Chang ve Lee (1994), çalışmalarında üçgensel bulanık sayıları kullanarak bulanık doğrusal regresyon analizini doğrusal ve doğrusal olmayan veri yapıları üzerinde modellemişlerdir. Burada Tanaka ve diğ., (1982) tarafından geliştirilen modele ilişkin eksikleri giderebilmek amacıyla bulanık sayıların yayılımları iki farklı eğilime göre değerlendirilmiştir.

Ishibuchi ve diğ., (1995) bulanık ve gerçek girdi vektörleri ile bulanık çıktı vektörlerinin kullanılabilirdiği üç katmanlı bulanık sinir ağı mimarisi önermişlerdir. Önerilen bulanık sinir ağında birimlere ilişkin girdi-çıkıtı ilişkisi Zadeh'in genişletme prensibi ile tanımlanmıştır. Araştırmacılar h seviye kümesini belirlemek amacıyla bir maliyet fonksiyonu belirlemişlerdir. Simetrik üçgensel bulanık ağırlıkların parametreleri için maliyet fonksiyonundan türetilen bir öğrenme algoritma geliştirmişlerdir. Araştırmacılar bulanık girdi ve bulanık çıktının yer aldığı bulanık sinir ağlarının öğrenme algoritmalarının türetildiği ilk çalışma olan bu çalışmada, sayısal örnekler üzerinde gerçekleştirdikleri simülasyonlarla türetilen algoritmaların oldukça başarılı olduğunu bildirmişlerdir.

Kim ve diğ., (1996), çalışmalarında veri setinin klasik regresyon analizi için yetersiz olduğu durumlarda, bulanık regresyon analizinin klasik regresyon analizine regresyon parametrelerini tahminlemek üzere alternatif olabileceğini bildirmişlerdir.

Chang ve Lee (1996), çalışmalarında genelleştirilmiş bulanık ağırlıklandırılmış en küçük kareler yöntemini bulanık regresyon analizi için önermişlerdir. Yöntem veri setinde yer alan aykırı değerler varlığında üyelik derecelerini kullanarak ağırlıklandırma yapmakta ve kullanıcı ile etkileşime dayanmaktadır. Analiz sonuçlarına göre araştırmacıların önerdikleri yöntemin bulanık regresyon analizi için etkili bir hesaplama aracı olduğu görülmektedir.

Ishibuchi ve Nii (1996a), çalışmalarında simetrik olmayan üçgen ve yamuk bulanık katsayıları kullanarak bulanık regresyon analizinin gelişimine katkıda bulunmuşlardır. Ayrıca araştırmacılar bulanık doğrusal regresyon analizi ile ilgili bazı eksikliklere de dikkat çekmişlerdir. Çalışmalarının sonunda inceledikleri üç farklı bulanık regresyon yönteminden, doğrusal olmayan bulanık regresyon analizi için bulanıklaştırılmış sinir ağları yöntemini önermişlerdir.

Ishibuchi ve Nii (1996b), çalışmalarında simetrik olmayan sayı ağırlıkları ve bulanık sinir ağlarını kullanarak bulanık doğrusal olmayan regresyon analizine ilişkin üç farklı yöntem tanıtmışlardır.

Diamond ve Körner (1997), çalışmalarında Diamond (1988a) tarafından önerilen yöntemi negatif yayılımların oluşumunu önlemek amacıyla revize etmişlerdir.

Tanaka ve Lee (1997), çalışmalarında kuadratik programlama yaklaşımına dayanan iki bulanık regresyon modelini incelemişlerdir. Bunlar tahminlenen çıktı merkezleri ile gözlenen çıktı merkezleri arasındaki uzaklığı minimize eden yaklaşım ile tahminlenen çıktıların yayılımlarını minimize eden yaklaşımdır. Ayrıca bu yaklaşımlara ilişkin sayısal bir örnek de çalışmalarında yer almıştır. Uygulama sonucunda amaç fonksiyonun ağırlıklarını değiştirerek araştırmacıların tahmin işleminde farklı bakış açılarına sahip olabileceğini ayrıca veri setinde yer alan aykırı değerlere karşı oldukça başarılı olunabileceğini belirtmişlerdir.

Yang ve Ko (1997), çalışmalarında bulanık kümeleme tekniklerini bulanık regresyon analizinde kullanmayı amaçlamışlardır. Bu çerçevede iki aşamalı ağırlıklandırılmış bulanık regresyon ve bir aşamalı genelleştirilmiş bulanık regresyon olmak üzere iki farklı yaklaşım incelemişlerdir. Çalışma kapsamında yapılan uygulama sonuçları incelenen bulanık

regresyon analizi için tek aşamalı prosedürü önermektedir.

Acton (1998), çalışmasında görüntü güçlendirme amacıyla doğrusal olmayan bulanık regresyon analizini kullanmıştır.

Kim ve Bishu (1998), üyelik fonksiyonlarını karşılaştırmalı olarak inceleyerek bulanık regresyon modellerini değerlendirmişlerdir. Burada gözlenen ve tahmin edilen bulanık sayılar arasındaki farkı en az seviyeye indirmek amacıyla bulanık regresyon analizi için öneride bulunmuşlardır. Mevcut model ve önerilen model bulanık tahminleri karşılaştırmak amacıyla iki farklı sayısal örnek üzerinde incelenmiştir.

Cheng ve Lee (1999), çalışmalarında Sugeno çıkarım modeline dayanan bir bulanık çıkarım sistemini bulanık regresyon analizi için formüle etmişlerdir. Araştırmacıların önermiş oldukları “Bulanık uyarlamalı ağ” modeli daha önce literatürde yer alan “Bulanık radyal tabanlı fonksiyon ağı” yaklaşımı ile karşılaştırmalı olarak incelenmiştir. Analiz sonucunda doğruluk ve yakınsama oranları açısından bulanık uyarlamalı ağın daha iyi sonuçlar verdiği belirtilmiştir.

Buckley ve Feuring (2000), çalışmalarında bulanık girdi ve bulanık çıktılar için bir doğrusal olmayan regresyon yöntemi sunmuşlardır. Çalışmada bulanık regresyon model fonksiyonları dört farklı formda incelenmiştir. Bunlar doğrusal, polinomial, eksponansiyel ve logaritmik şeklindedir. Analizleri gürültülü ve gürültülü olmayan veri setleri için ayrı ayrı karşılaştırmalı olarak yorumlamışlardır. Veriyi en iyi açıklayan fonksiyon için oluşturulan veri kaynağında arama yapmak üzere evrimsel bir algoritma geliştirilmiştir. Deney sonuçları geliştirilen yöntemin oldukça başarılı olduğunu göstermektedir.

Özelkan ve Duckstein (2000), çalışmalarında çok amaçlı bulanık regresyon tekniğini incelemişlerdir. Bu çalışmada tahminde belirsizlik ve aykırı değerler arasındaki dengeye dayanan ve dominant olmayan çözümü belirlemek amacıyla karar verici ile etkileşime dayanan bir yöntem söz konusudur. Çalışmalarının sonunda çok amaçlı bulanık regresyon tekniğinin mevcut bulanık regresyon tekniğine göre daha iyi sonuçlar verdiğini belirlemişlerdir. Bu çerçevede yağış-akış modellemesine ilişkin sayısal bir örneğe yer verilmiştir.

Xu ve diğ., (2000), çalışmalarında yazılım modüllerinde hata aralığını tahmin etmek üzere bulanık doğrusal olmayan regresyon analizini kullanmışlardır. Bulanık mantık ve sinir

ağlarının birlikte kullanıldığı bu çalışmada analiz sonuçlarının yazılım modüllerinde hata aralığının tahmin edilmesinde oldukça yararlı olduğunu bildirmişlerdir.

Chang ve Ayyub (2001), çalışmalarında klasik regresyon analizi ile bulanık regresyon analizi arasındaki temel farklılıkları incelemişlerdir. Minimum bulanıklık kriterine dayanan bulanık regresyon analizi, uyum kriteri olarak en küçük hata kareleri (least squares of error) kullanan bulanık regresyon analizi ve aralık regresyon analizi olmak üzere üç farklı bulanık regresyon yaklaşımı tanımlanmıştır. İncelenen bulanık regresyon yaklaşımlarına ilişkin sayısal örnekler ile grafik gösterimleri, klasik en küçük kareler regresyonu ile olan farklılıkları ve özellikleri açısından değerlendirmişlerdir.

Chang (2001), çalışmasında melez bulanık en küçük kareler regresyonu için bir yöntem geliştirmişlerdir. Bu amaçla simetrik ve simetrik olmayan üçgensel bulanık sayıları iki değişkenli ve çoklu regresyon modelleri üzerinde kullanmış, modellerin güvenilirlik ölçütlerini klasik regresyon analizi ve diğer bulanık regresyon analizi yöntemleri ile karşılaştırmalı olarak incelemiştir.

Chen (2001), çalışmasında aykırı değer probleminin çözümü için bulanık sayı olmayan girdi ve bulanık sayı olan çıktıları kullanarak bir bulanık regresyon modeli önermiştir. Çalışmada problemin niteliğine göre belirlenen önceden atanmış (pre-assigned) k-limit değerleri yorumlanmıştır. Sonuçlar önerilen yaklaşımın normal olmayan değerlerin tespit edilmesinde ve gözlemlenen değer ile tahmin değerleri arasındaki uzaklığın incelenmesinde oldukça etkili olduğunu ortaya koymaktadır.

Chen ve diğ., (2012) en küçük kareler destek vektör makinalarını heyelan zarar tahmini amacıyla kullanmışlardır. Destek vektör makinaları, en küçük kareler destek vektör makinaları ve bulanık en küçük kareler destek vektör makinaları olmak üzere üç farklı yöntem ile gerçekleştirilen deney sonuçları en düşük hata kriterlerinin bulanık en küçük kareler destek vektör makinaları tarafından sağlandığını göstermektedir.

Ishibuchi ve Nii (2001), çalışmalarında simetrik üçgensel bulanık sayı ile çalışan bulanık regresyon analizini geliştirmek amacıyla simetrik olmayan üçgensel sayılar ile yamuk bulanık sayıları kullanmışlardır. Bu amaçla bulanıklaştırılmış sinir ağlarının doğrusal olmayan bulanık regresyon analizinde kullanımını incelemişlerdir. Araştırmacılar bulanıklaştırılmış sinir ağlarının bulanık bağlantı ağırlıklarının, doğrusal bulanık regresyon analizindeki bulanık katsayılarla karşılık geldiğini bildirmişlerdir. Çalışmalarında inceledikleri model ile ilgili Tip 1 ve Tip 2 üyelik fonksiyonlarını kullanarak bilgisayar simülasyonu ile bir uygulama gerçekleştirmişlerdir.

Lee ve Chen (2001), çalışmalarında girdi ve çıktılarının bulanık sayı olduğu, genelleştirilmiş bulanık doğrusal regresyon analizi yöntemini iş gücünü tahminlemek amacıyla kullanmışlardır. Ayrıca bulanık parametreleri ve onların belirsizliklerini tanımlamak üzere doğrusal olmayan programlama modeli sunmuşlardır.

Xu ve Khoshgoftaar (2001), telekomünikasyon sistemlerinde yazılım kalite tahmini yapmak üzere doğrusal olmayan bulanık regresyon analizini kullanmışlardır. Analiz sonuçlarını çoklu doğrusal regresyon analizi ile karşılaştırmalı olarak incelemişler ve önerdikleri yöntemin oldukça başarılı olduğunu belirtmişlerdir.

D'urso ve Gastaldi (2002), çalışmalarında tahmini yayılımlar ve merkezler (modlar) arasındaki olası etkileşimlerini dikkate almaya müsait polinomial regresyon modeli bulanık bağımlı değişken ve kesin bağımsız değişken arasındaki ilişkiyi açıklamak amacıyla sunmuşlardır.

Yang ve Lin (2002), çalışmalarında bulanık girdi ve bulanık çıktı arasındaki ilişkiyi değerlendirmek amacıyla bulanık doğrusal en küçük kareler regresyon çözümlemesine dayanan iki farklı bulanık regresyon yöntemi önermişlerdir. Heterojen nitelikte veriler ve içerisindeki aykırı değerleri belirlemek üzere kümeleme analizini kullanmışlardır. Araştırmacılar önerdikleri yöntemlerin parametre tahmininde oldukça etkili olduğunu belirtmişler ve yöntemleri karşılaştırmalı olarak incelemişlerdir.

Nasrabadi ve diğ., (2005), çalışmalarında aykırı değerlerden kaynaklı sorunları azaltmak amacıyla çok amaçlı bulanık doğrusal regresyon modeli geliştirmişlerdir.

Kandala ve Prajneshu (2004), çalışmalarında bulanık regresyon analizi hakkında bilgiler sunmuş ve istiridyelerde büyüme üzerine bir uygulama gerçekleştirmişlerdir.

Hojati ve diğ., (2005), çalışmalarında bulanık regresyon analizi için basit ve iyi sonuçlar veren yeni bir hesaplama yöntemi geliştirmeyi hedeflemişlerdir. Araştırmalarını sadece bağımsız değişkenlerin bulanık olduğu ve hem bağımsız hem de bağımlı değişkenlerin bulanık olduğu durumlar olmak üzere iki farklı açıdan ele almışlardır.

Şanlı (2005), çalışmasında regresyon model tahminlerini elde etmek üzere klasik en küçük kareler, Huber, Hampel, Andrews ve Tukey M yöntemleri ile önermiş olduğu bulanık robust yöntemleri karşılaştırmalı olarak incelemiştir.

Zhang ve diğ., (2005) makalelerinde çok boyutlu LR tipli bulanık sayılar ile çalışan bulanıklaştırılmış radyal tabanlı fonksiyon ağlarını (FRBFN) parametrik olmayan doğrusal olmayan bulanık regresyon probleminin çözümünde kullanmışlardır. Araştırmacılar ayrıca FRBFN ile ele alınan doğrusal olmayan bulanık regresyonun doğrusal olmayan matematiksel programlama problemi olarak formüle edilebildiğini de bildirmişlerdir. FRBFN ile bulanıklaştırılmış çok katmanlı algılayıcı sinir ağlarının karşılaştırmalı olarak incelendiği çalışmada araştırmacılar iki aşamalı algoritma ve geri yayılım algoritması olmak üzere iki farklı eğitim algoritması kullanmışlardır. Simülasyon çalışmaları sonuçların etkili ve başarılı olduğunu göstermektedir.

Yapıcı Pehlivan ve Apaydın (2005), çalışmalarında bulanık doğrusal programlama problemini simpleks yöntemi ve yapay sinir ağları yaklaşımlarını kullanarak çözümlenmişler, sonuçları karşılaştırmalı olarak incelemişlerdir. Araştırma sonucunda yapay sinir ağları yaklaşımının oldukça faydalı olduğunu ve incelenen diğer yöntemlere alternatif olabileceğini bildirmişlerdir.

Guo ve Tanaka (2006) girdilerin kesin sayı ve çıktılarının bulanık sayı olduğu veri analizi için üst ve alt regresyon modelleri (doğrusal ve doğrusal olmayan dual possibilistic modeller) önermişlerdir.

Hong ve diğ., (2006), çalışmalarında bulanık çok değişkenli doğrusal olmayan regresyon analizi çözümlemesinde, yerel ağırlıklı en küçük kareler destek vektör makinaları regresyonunu temel alan bir yöntem önermişlerdir. Araştırmacılar yerel ağırlığın eğitim ve test verileri arasındaki pozitif metrik uzaklıktan elde edildiğini belirtmişlerdir.

Hong ve Hwang (2006), çalışmalarında bulanık çok değişkenli doğrusal olmayan regresyon modeli için bulanık girdi ve bulanık çıktı verilerini kullanarak yeni bir yöntem geliştirmişlerdir. Çalışmada hataların minimum değerli olması amaçlanmış ve optimizasyon problemini çözmek üzere kullanılan yöntem, en küçük kareler destek vektör makinalarına dayandırılmıştır. Araştırmacılar analiz sonuçlarının oldukça başarılı olduğunu belirtmişlerdir.

Tekşen (2008), çalışmasında yapay sinir ağları, en küçük kareler destek vektör makinaları ve bulanık en küçük mutlak sapma regresyonu olmak üzere üç farklı yöntemi doğrusal olmayan bulanık regresyon analizi için kullanmış ve karşılaştırmalı olarak incelemeye tabi

tutmuştur. Analiz sonuçları yapay sinir ağı yönteminin tahmin başarısının diğer yöntemlere göre daha yüksek olduğunu göstermiştir.

Tseng (2008), çalışmasında olası satış hacmini tahminlemek amacıyla kuadratik aralık Gompertz modeli ve kuadratik aralık lojistik model geliştirmek için üç farklı veri seti üzerinde bulanık regresyon analizini kullanmışlardır.

Seng ve diğ., (2009), çalışmalarında gürültülü bulanık veri veya örneklem büyüklüğünün küçük olduğu durumlarda bireysel farmokinetik parametreleri tanımlamak için bulanık doğrusal olmayan regresyon yöntemini incelemiştir. Klasik regresyon analizinde kullanılan en küçük kareler ve bulanık en küçük kareler yöntemlerini örneklem büyüklüklerine göre karşılaştırmaya tabi tutmuşlardır. Az sayıda örnekle çalışıldığı takdirde bulanık en küçük kareler regresyonu, klasik en küçük kareler regresyonuna göre daha güçlü olduğunu belirtmişlerdir.

Karadavut ve diğ., (2009), çalışmalarında mısır bitkisine ilişkin büyüme eğrisi parametrelerini tahminlemek üzere doğrusal olmayan bulanık regresyon analizini kullanmışlardır. Bu amaçla hataları minimum değerli optimizasyonunu elde etmek üzere en küçük kareler destek vektör makinalarından faydalanmışlardır. Ele alınan problemde girdi ve çıktılar bulanık sayı şeklinde analize dahil edilmiştir.

Kula ve diğ., (2010), çalışmalarında bağımlı değişkenin simetrik bulanık sayı olduğu regresyon model tahmini için bulanık çıkarsama sistemine dayalı uyarlamalı ağı (ANFIS) ve bulanık robust regresyona dayalı bir algoritma kullanmışlardır. Analiz sonuçlarını Diamond (1988a)'in önerdiği yöntem kullanılarak elde edilen sonuçlar ile karşılaştırmışlardır.

Tekşen ve Genç (2011), çalışmalarında en küçük kareler destek vektör makinaları yöntemini doğrusal olmayan bulanık regresyon analizinde kullanmışlardır. Çalışmada girdi ve çıktılar bulanık sayı olarak modele dahil edilmiştir. Doğrusal ve doğrusal olmayan bulanık regresyon modelleri üzerinde araba satış fiyatlarına ilişkin iki farklı uygulama gerçekleştirmişlerdir.

Feng (2011), kendinden uyarımlı eşiksel otoregresif model ile bulanık kümeleme regresyon yöntemlerini finansal türde verileri kullanarak tahmin performanslarını karşılaştırmalı olarak incelemiştir.

Lin (2012), çalışmasında deprem durumunda köprünün potansiyel kırılma potansiyelini değerlendirilmesini amaçla bulanık regresyon analizinden faydalanmıştır. Çalışmasında, yapısal model simülasyonlarına dayanan köprülerin sismik güvenlik açığı değerlendirilmesi için Tayvan'ın Nantou İlçesindeki Mao-Luo-Hsi Köprüsü için bulanık regresyon karar sistemleri geliştirilmiş ve uygulamalar yapılmıştır. Araştırma sonuçları, bulanık regresyon modellerinin yüksek belirleme katsayılarına sahip olduğunu ve köprünün potansiyel kırılma potansiyelinin değerlendirilmesinde oldukça başarılı olduğunu göstermektedir.

Tekşen ve Evren (2012), çalışmalarında yapay sinir ağları ve entropi yaklaşımını kullanarak bulanık doğrusal olmayan regresyon analizi için model geliştirmişlerdir.

Kula ve diğ., (2012) çalışmalarında sigortacılık alanında bağımlı ve bağımsız değişkenler arasındaki ilişkiyi tanımlamak amacıyla bulanık robust regresyon modelini hem sıradan en küçük kareler regresyonuna hem de klasik robust regresyon analizine alternatif olarak önermişlerdir. Bulanık robust regresyon ile gerçekleştirilen analiz sonuçları, robust yöntemlerle elde edilen sonuçlarla aynı işaret ve neredeyse aynı büyüklüğe sahip olduğunu göstermektedir.

Lin (2012) bulanık regresyon analizini köprü yapısının depremlere karşı olası hasar görebilmesinin değerlendirilmesi amacıyla kullanmıştır. Yapısal modelde yer alan belirsizlikler ve dalgacık filtreleme tarafından önışleme tabii tutulan çevresel titreşim verileri nedeniyle bulanık regresyon analizi yöntemi uygulamıştır. Çalışmada araştırmacı tarafından köprü uyarı karar sistemleri geliştirilmiştir. Köprünün olası depremlere karşı hassasiyetini değerlendirmek amacıyla kullanılan bulanık regresyon analizinin başarılı olduğu elde edilen belirleme katsayısı değerlerine göre bildirilmiştir.

Roldan ve diğ., (2012) minimum bulanıklık kriterine dayalı bulanık regresyon analizinin formüle edildiği yeni bir yaklaşım önermişlerdir; bu yöntem, biyokütle üretiminde doğrusal olmayan bir problem yapısına uygulanmıştır.

Yongqi (2012) ağırlık vektörüne bulanık küme prensibini uygulayarak belirsizlik içeren verileri tahmin etmek amacıyla en küçük kareler destek vektör makineleri regresyon modelini önermiştir. Araştırmacı çalışmasında ağırlık vektörü ve sapma terimini belirlemek amacıyla, karmaşık hesaplamalar gerektiren karesel programlama yerine bir dizi doğrusal denklem kullanmıştır. En küçük kareler destek vektör makinelerine dayalı

bulanık regresyon modeli, arařtırmaya konu olan veri setinde bulunan aykırı deęerlere raęmen doęrusal olmayan yapıda modeli oldukça başarılı bir řekilde tahmin etmiřtir.

Liu ve Chen (2013), alıřmalarında simetrik üçgensel bulanık sayılarla minimum bulanıklık kriterini kullanarak optimize edilmiř h deęerleri için bulanık regresyon analizini gerekleřtirmek üzere bir yaklařım önermiřlerdir. Bu amala farklı h seviyelerinde üretilen bulanık regresyon modellerinin performans deęerlendirmesini toplam güvenirlilik seviyesine göre yapmıřlardır. alıřma kapsamında gerekleřtirilen uygulama sonuçları önerilen yaklařımın optimal “ h ” deęerinin belirlenmesinde oldukça etkili olduęunu göstermektedir.

Hung ve Lin (2013), alıřmalarında uzun vadeli ekonomik dalgalanmaları tahminlemek amacıyla genetik algoritmali en küçük kareler destek vektör makinaları, sezgisel bulanık destek vektör regresyonu, bulanık destek vektör regresyonu, en küçük kareler destek vektör regresyonu, destek vektör regresyonu ve ARIMA yaklařımını kullanmıřlardır. Analiz sonuçları genetik algoritmali sezgisel bulanık en küçük kareler destek vektör regresyonun dięer yöntemlere göre daha yüksek tahmin başarısına sahip olduęunu göstermektedir. Arařtırmacılar önerilen yöntemin ekonomik dalgalanma için uzun vadeli ve güvenilir tahminleri etkili bir řekilde yapabileceęini belirtmiřlerdir.

Chou ve dię., (2013) Tayvan’da uluslararası hava kargo pazarını incelemiř, bu alanda belirsizlikten kaynaklı problemleri farklı açılardan ele alarak hava kargo ihracat hacim tahminini gerekleřtirmek üzere bulanık regresyon analizini kullanmıřlardır. Simetrik olmayan üçgensel bulanık sayıların kullanıldıęı alıřmada arařtırmacılar modelin tahmin doęruluęunun oldukça başarılı olduęunu bildirmiřlerdir.

Honarbaksh ve dię., (2013) arařtırmalarında esnek hesaplama yaklařımlarından bulanık kural tabanı, bulanık regresyon ve yapay sinir aęlarının günlük buharlařma tahmini için uygunluęunu incelemiřler ve sonuçları referans ürün (im) bazında lizimetre ile ölçülen gerek verilerle karřılařtırmıřlardır. Hata istatistikleri kullanılarak gerekleřtirilen karřılařtırmalar bulanık kural tabanının incelenen problem yapısına daha uygun bir yöntem olduęunu göstermektedir.

Höglund (2013) muhasebe ve finans alanında gerekleřtięi alıřmasında kazanç yönetimini incelemiřtir. Alan literatüründe yer alan Jones modelini sıradan en küçük kareler modeli ve bulanık regresyon modeli ile iliřkilendirerek karřılařtırmalı olarak ele almıřtır. Bulanık

regresyon analizini özellikle küçük örneklem ile çalışma konusunda sağlamış olduğu avantajdan dolayı tercih eden araştırmacı, farklı uzunlukta zaman serileri ile çalışmıştır. Analiz sonuçları bulanık regresyon analizinin, alan literatüründe klasik yöntem başlığı altında ele alınan en küçük karelere dayalı Jones Modeline göre iyi bir alternatif olduğunu ortaya koymaktadır.

Shakouri ve Nadimi (2013) çalışmalarında veri setinde yer alan aykırı değerleri tespit etmek amacıyla, bulanık olmayan girdi ve bulanık olmayan çıktılar kullanarak bulanık regresyon analizini ele almışlardır.

Chen ve diğ., (2013) bulanık regresyon modeli oluşturmak amacıyla uzaklık kavramına dayalı iki aşamalı bir yaklaşım önermişlerdir. Bulanık gözlemler durulaştırma yöntemi kullanılarak elde edilmiş sonrasında ise geleneksel en küçük kareler tekniği kullanılarak bulanık regresyon modeli içinde regresyon katsayıları kesin sayı olarak belirlenmiştir. Önerilen model kesin regresyon katsayılarının yanı sıra bulanık tahmin hatasını azaltmak için bulanık düzenleme değişkeni içermektedir. Bu değişken bulanık gözlemlerden gelen bulanıklığın üstesinden gelmek için modele dahil edilmiştir. Araştırmacılar çalışmalarında önerilen bulanık regresyon modelinde pozitif katsayıların yanı sıra negatif katsayıları çözüm sürecine dahil etmişlerdir. Gerçek veri seti üzerinde gerçekleştirilen uygulamada önerilen yöntemin yüksek açıklama gücüne sahip olduğu bildirilmiştir.

Su ve diğ., (2013) girdiler ve model yapı parametrelerinin kesin sayı olduğu, çıktıların bulanık sayı olduğu doğrusal olmayan regresyon problemlerinde Kernel stratejisini bulanık regresyon analizinde ele almışlardır. Çalışmalarında incelenen yöntemi bir elektrik santralinde ölçülmemiş parametreleri izlemek için kullanmışlardır.

Lin ve Pai (2010), çalışmalarında ekonomik dalgalanma indeksine ilişkin tahmin değerleri için bulanık alt ve üst sınırları hesaplamak amacıyla bulanık destek vektör regresyonunu kullanmışlardır. Çalışmada dört farklı değerde h seviyesi kullanılmıştır. Araştırmacılar incelenen yöntemin tahmin başarısının oldukça etkili olduğunu ve alternatif bir yöntem olarak kullanılabileceğini bildirmişlerdir.

Pandit (2014), çalışmasında yapay sinir ağları yöntemini kullanarak doğrusal olmayan bulanık regresyon analizini tanıtmışlardır. İncelenen yöntemde, mahsul verimliliğine etki eden farklı değişkenler arasından bir alt problem olarak ele alınan sıcaklığın buharlaşma üzerine etkisi tahmin edilmek istenmiştir. Yöntemin işleyişinde ortalama değerler yerine

bulanık sayıların kullanılması minimum ve maksimum değerlerin desteklenmesi açısından daha uygun bulunmuştur.

Chan ve diğ., (2014) müşteri tercih modeli geliştirmek amacıyla bulanık regresyon analizini kullanmışlardır. İncelenen alanda müşteri tercihlerinde yer alan bulanıklık ve rasgelelikten kaynaklı belirsizliği giderebilmek amacıyla bu yöntemi tercih eden araştırmacılar çay yapımına ilişkin bir tasarımla ilgili deneysel veriler üzerinde analizlerini gerçekleştirmişlerdir. Analiz sonuçları geliştirilen yöntemin başarılı olduğu göstermektedir.

Gaeta ve diğ., (2014) çalışmalarında doğrusal olmayan regresyon problemlerinde Bulanık Fonksiyonel Ağları (Fuzzy Functional Network) tanımlamışlar ve sayısal bir örnek sunmuşlardır. Simüle edilmiş veriler ve literatür verileri temel alınarak yapılan sayısal örnekler, ele alınan yöntemin başarılı olduğunu göstermektedir.

Kumar ve diğ., (2014) çalışmalarında kirpik kanatlı soğan böceklerine ilişkin önceden ikaz edilme amacıyla bulanık regresyon modeli geliştirmişlerdir. Geliştirilen bulanık regresyon modelleri, çeşitli karakterler için hava durumu indekslerinin yer aldığı regresyon modelleri ile karşılaştırılmıştır. Modeller bitkilerin ekim günleri dikkate alınarak geliştirilmiştir. Bunun için kirpik kanatlı soğan böceklerinin ortaya çıkış ve popülasyon değerleri ile ilgili üç farklı bağımlı değişken ile çalışmışlardır. Araştırma sonunda h değerinin sıfır olarak kabul edildiği bulanık regresyon analizinin doğrusal regresyon analizine göre daha etkin bulunduğu belirtilmiştir.

Rattanalertnusorn ve diğ., (2014), Chen ve Hsueh (2009) tarafından gerçekleştirilen çalışmada belirtilen modeli geliştirmişlerdir. Çalışmalarında model parametrelerini tahmin edilen toplam hatayı minimize edecek şekilde tahmin etmişlerdir. Girdi ve çıktılar yamuk bulanık sayı şeklinde modelde yer almaktadır. Model parametreleri hepsi pozitif; bir kısmı pozitif bir kısmı negatif ve hepsi negatif sayı olacak şekilde üç farklı örnek yapısında tahmin edilmiştir. Kesin girdi-bulanık çıktı ve bulanık girdi-bulanık çıktı olmak üzere iki farklı model sayısal örnekler üzerinde incelenmiştir. Araştırmacılar önerdikleri yaklaşımın alternatif bir yöntem olabileceğini ve oldukça yararlı sonuçlar elde ettiklerini bildirmişlerdir.

Zolfaghari ve diğ., (2014) 36 farklı çeşitte kızarmış çöreğin genel kabulü ve duyuşal özellikleri arasındaki ilişkiyi modellemek için bulanık regresyon analizini sunmuşlardır.

İncelenen duyuşsal zellikler aroma, yzey rengi, gzeneklilik, sertlik, yaęlılık ve lezzet Őeklinindedir. Bulanık regresyon modelinde girdiler kesin sayı ve ıktıyı ęensel bulanık olarak ele alınmıřtır. Analizlerde bulanık sayıların simetrik, sabit asimetric, artan asimetric ve azalan asimetric hallerinden en iyi uyumu simetrik bulanık parametrelerin saęladıęı bildirilmiřtir. Duyusal zelliklerin her birinin genel kabul grme zerindeki etkisi ayrı ayrı deęerlendirilmiřtir. Arařtırmacılar alıřmalarında bulanık regresyon analizi ynteminin klasik yntemlere gre ok daha etkin ve uygun olduęunu belirtmiřlerdir.

Liu ve dię., (2014) mřteri gereksinimi ve kalite fonksiyon yayılımını konu alan alıřmalarında kompensasyon derecesini modellemek amacıyla geleneksel bulanık doęrusal regresyon analizine dayalı bir bulanık doęrusal olmayan regresyon modeli geliřtirmiřlerdir. Simetrik ęensel bulanık sayıların kullanıldıęı analizde minimum bulanıklık kriteri esas alınmıřtır. Beř farklı rn zerinde yrtlen alıřmada bulanık regresyon analizinin mřteri tatminini belirlemede, kullanılan geleneksel ynteme gre daha gereki ve doęru sonular verdięi belirtilmiřtir.

Gonzalez-Gonzalez ve dię., (2014) inřaat sektrnde kullanılan yapı elemanlarına iliřkin bazı kaplama trlerinin gvenirlięi zerine bir alıřma gerekleřtirmiřlerdir. alıřmalarında verilere iliřkin ekstrapolasyon srecini gerekleřtirmek ve bulanık olasılık teorisinin uyumunu belirlemek zere doęrusal olmayan bulanık regresyon modeli sunmuřlardır. Arařtırmacılar nerdikleri Weibull bulanık gvenirlik modeli tahmin performansının geleneksel yntemlere gre daha bařarılı olduęunu bildirmiřlerdir.

Leksakul ve dię., (2015), alıřmalarında Kuzey Tayland blgesinde retilen bir aęa trnn arz fazlasını tahminlemek zere sinir aęları, bulanık sinir aęları, destek vektr regresyonu ve bulanık destek vektr regresyonunu kullanmıřlardır. Arařtırmada kullanılan algoritmaların etkinlik ve verimliliklerinin deęerlendirilmesinde gerek veri setleri kullanılmıřtır. Analiz sonuları bulanık destek vektr regresyonu tahmin teknięinin dięer yntemlere gre daha etkili olduęunu gstermektedir.

İen ve Gnay (2015) alıřmalarında Trkiye'de iřsizlik oranı tahmini iin iki farklı bulanık regresyon modelini ele almıřlardır. Bulanık model parametrelerine iliřkin nemlilik hipotez testi ile test edilmiřtir. Analizler bulanık doęrusal programlama, bulanık en kk kareler yntemi ve sistem parametrelerinin bulanıklařtırılması yntemlerine gre farklı h deęerleri ile gerekleřtirilmiřtir.

Sarkar ve diğ., (2015) elektrik talebine ilişkin minimum tahmin aralığını bir alt ve bir üst sınır ile birlikte hesaplamak amacıyla bulanık regresyon analizini kullanmışlardır. Sıcaklık ve yıllık tüketici sayısı parametreleri ile çalışan araştırmacılar tahmin doğruluğunu ortalama mutlak yüzde hata kriteri ile belirlemişlerdir. Analiz sonuçları %1.24 şeklinde hesaplanan ortalama mutlak yüzde hata değerinin kabul edilebilir olduğunu göstermektedir.

Song ve Sun (2015) şehir nakliye hacminin belirlenmesi ile ilgili gerçekleştirdikleri çalışmada klasik yöntemler ile iki farklı bulanık regresyon modelini karşılaştırmalı olarak incelemişlerdir. Araştırmacılar bulanık doğrusal regresyon modeli sayesinde yük hacmi verisinin dinamik işlenmesinde, yük hacmi değişim aralığı ve değişim eğilimini kolayca tahmin edilebileceğini bildirmişlerdir. Çalışmada her iki bulanık regresyon modelinin de pratik ve başarılı sonuçlara sahip olduğu görülmektedir.

Megri ve diğ., (2016) çalışmalarında termal konfor endekslerini tahmin etmek üzere parçacık sürü optimizasyonu ile entegreli çalışan bulanık destek vektör regresyonu yaklaşımını önermişlerdir. Çalışmada parçacık sürü optimizasyonu yöntemi bulanık destek vektör makineleri içinde hiper parametreleri optimize etmek ve seçmek global optimize edici olarak kullanılmıştır. Kernel seçimi radyal tabanlı fonksiyon şeklindedir. Farklı veri setlerinde simetrik olmayan üçgensel bulanık sayılar ile çalışan araştırmacılar tahmin sonuçlarının oldukça başarılı olduğunu belirtmişlerdir.

Neshat (2015) bulanık regresyon analizine dayalı bir yapay sinir ağı modelini, belirsizlik içeren durumlar ile doğrusal olmayan fonksiyonların yer aldığı tahmin problemlerinin çözümü amacı ile önermişlerdir.

Suharjito ve Marimin (2015) tarımsal alanda tedarik zincirine ilişkin bir fiyatlandırma modeli oluşturmuşlardır. Bu amaçla bulanık regresyon yaklaşımını kullanarak risk fayda fonksiyonu türetilmiştir. Araştırmacılar çalışmalarında doğrusal olmayan bulanık regresyon analizini fiyat değişimi içinde yer alan her katılımcı için tedarik zincirinin risk fayda değerini tahmin etmek amacıyla kullanmışlardır.

Chachi ve diğ., (2016) çok değişkenli uyarlamalı regresyon uzanımlarını (Multivariate Adaptive Regression Splines) kullanarak yeni bir bulanık regresyon modeli önermek istemişlerdir. Hidroloji alanında gerçekleştirilen uygulamada gerçek veri setleri kullanılmıştır. Literatürde yer alan iki farklı bulanık regresyon modeli ile önerilen yöntem

karşılaştırmaya tabi tutulmuştur. Analiz sonuçları karşılaştırılan diğer yöntemlere göre önerilen yöntemin daha başarılı olduğunu ve doğa bilimlerinde kullanımının oldukça uygun olduğunu göstermektedir.

Chen ve diğ., (2016), çalışmalarında Liu ve Chen (2013) tarafından kullanılan bulanık regresyon modelinin gelişimine katkıda bulunmuşlardır. Araştırmacılar çalışmalarında simetrik olmayan üçgensel bulanık sayılarla sistem güvenilirliğini maksimize ederek h değerini optimize etmeyi amaçlamışlardır.

Choi ve Abdullah (2016) Malezya'da karbondioksit emisyonunu tahmin etmek üzere klasik regresyon analizi ile bulanık regresyon analizini karşılaştırmalı olarak incelemişlerdir. Araştırma sonucunda klasik regresyon analizinin bulanık regresyon analizine göre daha iyi sonuçlar verdiği bildirilmiştir.

Ciavolino ve Calcagni (2016) genelleştirilmiş maksimum entropiye dayalı yeni bir bulanık regresyon yapısı sunmuşlardır. Bu amaçla Monte Carlo deneyleri ile gerçek veriler üzerinde çalışmalarını gerçekleştirmişlerdir. Araştırmacılar gerçek vakalarda özellikle güçlü değişken seçimi gibi konularda önerilen yöntemin oldukça yararlı olduğunu bildirmişlerdir.

İçen ve Cattaneo (2016) Monte Carlo yöntemi ile bulanık doğrusal regresyon parametrelerinin tahmini için en iyi uzaklık ölçüsünü belirlemeyi amaçlamışlardır. Araştırmacıların çalışmalarında önerdikleri ve literatürde yer alan uzaklık ölçüleri kullanılarak tahmini doğruluklar simülasyon çalışması ile karşılıklı olarak incelenmiştir.

İçen ve Demirhan (2016) bulanık regresyon analizinde parametre tahmini için Monte Carlo simülasyon yaklaşımını altı farklı hata ölçüsü ile ele almışlardır. Simülasyon çalışmasının tasarımında bulanık girdi- bulanık çıktı ve kesin girdi- bulanık çıktı olmak üzere iki farklı durum dikkate alınmıştır. Tahmin doğruluklarını incelemek üzere hata ölçüleri karşılaştırmaya tabi tutulmuş, en iyi ve en kötü ölçü birimleri belirlenmiştir.

Ji ve diğ., (2016) çalışmalarında sıcak metal desülfirizasyon süreci ile ilgili bir mühendislik uygulamasını çoklu doğrusal bulanık regresyon analizini kullanarak gerçekleştirmişlerdir. Araştırmacılar analiz sonuçlarının, incelenen yöntemin bahsi geçen alanda karar verici birimlere oldukça kolaylıklar sağladığını bildirmişlerdir.

Kitsikoudis ve diğ., (2016) geleneksel bulanık regresyon analizi ve hedef programlamaya

dayalı bulanık regresyon analizini ilgili literatürde yayınlanan verilere bağlı olarak partikül hareketinin başladığı bölgeyi açıklamak amacıyla kullanmışlardır. Çalışmanın amacı ve orijinalliği ise kritik kalkan stresinin taban ve tavan limitlerini açıklamak ve böylece, zayıf çökelti transferi ve genel harekete yarar sağlamaktır.

Liu ve diğ., (2016) bulanık regresyona dayalı ve ileri beslemeli sinir ağları ile bağlantılı olan ekstrem öğrenme makinesi ile ilgili bir yöntem önermişlerdir. Yöntemde girdi ve çıktılar üçgensel bulanık sayı olarak ele alınmışlardır. Sayısal simülasyonlar ile gerçekleştirilen analiz sonuçları önerilen yöntemin oldukça etkili olduğunu göstermektedir. Sonuçlar hata tahminleri ve ele alınan sinir ağlarının eğitim zamanlarının karşılaştırılması ile değerlendirilmiştir.

Patil ve Mudholkar (2016) çalışmalarında diz osteoartrit hastalığına ait tanıyı belirlemek amacıyla bulanık regresyon uygulaması gerçekleştirmişlerdir. Araştırmalarının sonunda bulanık regresyon analizinin hastalık tanısını belirlemede uygun bir yöntem olduğunu bildirmişlerdir.

Pehlivan ve Apaydın (2016) girdi ve çıktılarının simetrik ve simetrik olmayan bulanık sayı olarak yer aldığı bulanık regresyon modelinde tahmin değerlerinin elde edilmesi amacıyla bulanık radyal tabanlı fonksiyon ağları ile ilgili bir yöntem önermişlerdir. Önerilen yöntemde radyal tabanlı fonksiyon ağının ağırlıkları bulanıklaştırılmaktadır. Üç farklı sayısal örnek performans karşılaştırmasında kullanılmıştır. Elde edilen sonuçlar önerilen yöntemin, literatürde yer alan diğer bulanık regresyon modellerine etkili bir alternatif olduğunu göstermektedir.

Tzimopoulos ve diğ., (2016) kesin girdiler ve bulanık çıktının yer aldığı üç farklı bulanık regresyon modelini kullanmışlardır. Araştırmacılar Yunanistan'ın kuzey bölgesinde yer alan iki yağış istasyonu ile çalışmışlar ve hidroloji alanında bir uygulama gerçekleştirmişlerdir. Çalışmada Tanaka ve diğ., (1982) ile Savic ve Pedrycz (1991) tarafından geliştirilen modeller ile en küçük karelere dayalı bulanık regresyon modeli ayrı ayrı incelenmiş ve uygulamaya konu olan unsurun tahmininde başarılı olunduğu belirtilmiştir.

Yabuuchi ve diğ., (2016) doğrusal programlamaya dayalı bulanık regresyon, bulanık robust regresyon ve klasik regresyon analizi tekniklerini kullanarak sağlık bakım harcamaları ve beslenme arasındaki ilişkiyi araştırmışlardır. Analiz sonucunda elde edilen

regresyon katsayıları üzerinden, sağlık bakım harcamaları ve beslenme ile ilgili modelde yer alan göstergelerin etkisi yorumlanmıştır.

Wieszczy ve diğ., (2016) Trutschnig uzaklık ölçüsüne dayalı bir kayıp fonksiyonunun uygulamasına ilişkin yeni bir yöntem önermişlerdir. Önerilen yöntem destek vektör makinalarına dayalı bulanık regresyon modelinin tahmininde kullanılmaktadır. Araştırmacılar destek vektör makinalarına dayalı bulanık regresyon analizinde üçgensel bulanık sayıların kullanıldığı çalışmaları genelleştirmek istemiş ve bu amaçla yamuk bulanık sayıları ele almışlardır. Çalışmalarının sonunda klasik bulanık regresyon araçlarına göre önerdikleri yöntemin önemli derecede daha iyi sonuç verdiğini belirtmişlerdir.

Gonzalez-Gonzalez ve diğ., (2016) çalışmalarında inşaat yapılarında bozulma sürecinde zamana bağlı materyal kaybına ilişkin bir uygulama gerçekleştirmişlerdir. Ekstrapolasyon sürecinde hata tahmini ölçümleri için kalibrasyon regresyon yöntemi kullanılarak bileşenlerin bozulma zamanını tahmin etmişlerdir. Analizlerde yamuk bulanık sayılar kullanılmıştır. Polimerik kaplamaların bozulma zamanının tahminlenmesinde önerilen modelin oldukça başarılı olduğu belirtilmiştir.

He ve diğ., (2016) sinir ağları ile birlikte geliştirilen doğrusal olmayan bulanık regresyon analizinde kullanılmak üzere, gradyan tabanlı modellerde yer alan bazı olumsuzlukları önlemek amacıyla hızlı ve yüksek genelleştirme yeteneğine sahip yeni bir öğrenme algoritması önermişlerdir. Rassal ağırlık ağları olarak nitelendirilen yöntemde ağ ağırlıklarının iteratif düzenlenmesine ihtiyaç duyulmamaktadır. Girdi ve çıktılar üçgensel bulanık sayı olarak alınmıştır. Araştırmacılar deney sonuçlarının etkinlik ve uygulanabilirlik açısından, geri yayımlı ve radyal tabanlı sinir ağları ile çalışan doğrusal olmayan bulanık regresyon modellerine göre çok daha olumlu sonuçlar verdiğini belirtmişlerdir.

Başer ve Demirhan (2017) bulanık regresyon fonksiyonları ile destek vektör makinelerini güneş radyasyonunun tahminini gerçekleştirmek üzere bir yaklaşım önermişlerdir. Farklı Kernel fonksiyonları, uyarlanabilir bulanık sinir sistemi ve coplot destekli genetik programlama yaklaşımlarını ele alan sayısal bir örnek üzerinde uygulama yapmışlardır. Araştırma sonuçlarında, Gaussian Kernel'in kullanıldığı destek vektör makineleri ile çalışan bulanık regresyon fonksiyonlarının en yüksek tahmin doğruluğuna sahip olduğu belirtilmiştir.

He ve diğ., (2018) girdi ve çıktı deęişkenlerinin yamuk bulanık sayı olduęu rassal ağırlık aęlarına dayalı doğrusal olmayan bulanık regresyon modeli önermişlerdir. İki farklı veri seti üzerinde yaptıkları çalışmalarında, dört farklı doğrusal olmayan bulanık regresyon modeli ile karşılaştırmalı deęerlendirmeler yapmışlardır. Önerdikleri yöntemin dięer yöntemlere göre oldukça başarılı olduğunu bildirmişlerdir.

Rafique ve diğ., (2018) çalışmalarında yenilenebilir enerji üretimi (rüzgar ve güneş) ve yük tahmini için bulanık tahmin yöntemi geliştirmişlerdir. Araştırmalarında öncelikle Takagi-Sugeno tipi bulanık sistem birçok evrimsel optimizasyon algoritması ile eğitilmiş ve aralık tahmin doğruluęunu kontrol etmek için kapsama alanı sınıf göstergesi oluşturmuştur. Daha sonra Pekin'de bulunan yenilenebilir mikrogrid test tertibatı için bir rüzgar, güneş ve yük tahmincisi geliştirilmiştir. Araştırmacılar, bulanık tahmin aralıklarını; rüzgar, güneş ve yük için gerçek zamanlı deęerleri kullanarak günlük tahmin için oluşturmuşlardır ve analiz sonuçları oldukça başarılı bulunmuştur.

3. MATERYAL VE YÖNTEM

Tez çalışmasında tek ve çok değişkenli analizleri gerçekleştirmek üzere kullanılan veri seti 20 haftalıktan 90 haftalık yaşa kadar kaydı alınmış 100 yumurtacı tavuğun yumurta performans (YP) ve yumurta ağırlık (YA) değerlerinden oluşmaktadır. Çalışmada günlük ve haftalık olarak kayıt edilmiş veri setleri ayrı ayrı analiz edilmiştir. Eğitim seti tüm veri setinin %60'ı olacak şekilde belirlenmiştir. Veri seti İzmir ilinde üretim yapan özel bir yumurtacı işletmeden temin edilmiştir. Araştırma kapsamında değerlendirilen verilerin kullanımına ilişkin gerekli yazılı izinler alınmıştır. Analizler Matlab (R2016a) programı kullanılarak gerçekleştirilmiştir.

3.1. Klasik Regresyon Analizi

3.1.1. Klasik Doğrusal Regresyon Analizi

Regresyon analizi çeşitli bilim dallarında bağımlı ve bağımsız değişkenler arasındaki ilişkinin araştırılmasında başarı ile uygulanan istatistiksel analiz yöntemlerinden birisidir. Regresyon analizinde amaç bağımlı ve bağımsız değişken arasındaki ilişkiyi en iyi açıklayan denklemi bulmaktır. Bağımsız değişken “X”, bağımlı değişken “Y” ile ifade edilmektedir. Bağımsız değişken belli bir değeri almışken, şans değişkeni olan bağımlı değişken bu duruma karşılık bir değer almaktadır. Yani bağımsız değişkenin aldığı değer bağımlı değişkenin aldığı değeri etkilemektedir. Bu durum Y'nin X'e olan bağımlılığını ortaya koymaktadır. Burada bağımlı değişkende oluşan değişimin, bağımsız değişken(ler) tarafından açıklanma miktarı araştırılmaktadır. Böylece bağımlı değişken olarak kabul edilen değişken değerinin diğer bağımsız değişkenlerce ne derece etkilendiği anlaşılmış olur. Bağımsız değişkenin tüm değerleri için, bağımlı değişkenin gözlemlenen ve tahmin edilen değerleri arasındaki fark tahmin hatası veya artık olarak ifade edilir. Çalışma verilerinin içinden en yakın şekilde geçtiği kabul edilen doğrunun denklemi çözümlendiğinde hataların karesini minimum yapan regresyon doğrusu elde edilmiş olur (Tabachnick ve Fidell, 2015).

Doğrusal regresyon analizinde β parametrelerinin üssü “1” olmaktadır. Doğrusal modellerde β parametreleri modelde üssel veya diğer parametreler ile çarpım-bölüm halinde olmamaktadır, parametrelerin modele katkısı toplamsaldır. Regresyon yapıları, grafikleri doğrusal görünümde olmadığı durumlarda da model olarak doğrusal nitelikte olabilir. Tek başına regresyon grafiğine bakılarak modelin doğrusal olup olmadığına karar verilmemelidir. Örneğin bir regresyon modeli parabol denklemi olabilmektedir ve grafiksel gösterimi incelendiğinde doğrusal bir görünüme sahip olmadığı görülecektir. Bu durum grafiksel olarak doğrusal olmayan, model yapısı açısından doğrusal bir yapıya örnek teşkil etmektedir (Alpar 2011).

$$Y = X\beta + \varepsilon \quad (3.1)$$

Eşitlik 3.1’de doğrusal bir ilişkinin var olduğu görülmektedir. Doğrusal ilişkiyi ortaya koymak amacıyla bulunan regresyon modeline ait eşitlik X ’in belirli değerleri için hesaplanabilir. Verilen X değerleri dışındaki değerlerde hesaplama yapılırsa yanlış sonuçta ulaşılabilir, hassasiyet azalabilir veya ilişkinin şekli değişebilir. Bağımlı ve bağımsız değişken arasındaki ilişki Eşitlik 3.2’de yer alan model yardımıyla açıklanmaktadır. Bu model basit doğrusal regresyon modeli olarak adlandırılmaktadır. Bunun nedeni tek bir bağımsız değişkenin modelde yer almasıdır.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (3.2)$$

Eşitlik 3.2’de yer alan model, çalışma verilerinin içinden geçtiği kabul edilen doğruyu temsil etmektedir. β_0 ve β_1 basit doğrusal regresyon modelinde regresyon parametreleri olarak adlandırılır. Burada;

β_0 : Doğrunun Y eksenini kesme noktasıdır ve sabit değerlidir. $X = 0$ olduğunda Y ’nin aldığı değerdir.

β_1 : Regresyon doğrusunda eğimdir. X ’in kendi birimi cinsinden bir birim değişmesine karşılık, Y ’de kendi birimi cinsinden beklenen değişme miktarıdır.

ε : Tesadüfi hata terimidir (Atıl, 1991; İkiz ve diğ. 2006).

Bağımsız değişkenin gözlem değerlerine karşılık bağımlı değişkenin olasılık dağılımının ortalaması: $E(Y|X) = \beta_0 + \beta_1 X$, varyansı: $Var(Y|X) = Var(\beta_0 + \beta_1 X + \varepsilon) = \sigma^2$ olarak ifade edilir.

β_0 ve β_1 parametrelerini tahminlemek amacıyla en küçük kareler ve en çok olabilirlik yöntemleri arařtırmacılar tarafından tercih edilmektedir. En küçük kareler yönteminde amaç bağımlı deęişkenin gözlem deęerleri ile tahmin deęerleri arasındaki sapmaların kareler toplamının en düşük deęerini elde etmektir. Bu çerçevede β_0 ve β_1 'in doğrusal yansız tahminleyicileri hesaplanmış olur. Böylece kullanılan yöntemin tahmin başarısı olabildiğince yüksek, hatası ise minimum deęerli şekilde elde edilecektir (Montgomery ve dię. 2012). En küçük kareler yönteminde hataların normal dağıldığı kabul edilir. Alternatif bir yöntem olan en yüksek olabilirlik yönteminde ise olabilirlik fonksiyonunun alabileceği en yüksek deęer hesaplanmaktadır. Bir başka ifade ile bağımlı deęişkenin gözlem deęerlerini elde etme olasılığını maksimize etmek amaçlanmaktadır (Gujarati, 1999).

Bağımsız deęişkenlerin iki veya daha fazla olması ve deęişkenler arası ilişkinin doğrusal olması durumunda regresyon modeli çoklu doğrusal regresyon modeli olarak adlandırılır. Burada bağımlı deęişken birden fazla bağımsız deęişken tarafından etkilenmektedir. Y bağımlı deęişken olmak üzere, k tane bağımsız deęişkenli çoklu regresyon modeli Eşitlik 3.3'de verilmiştir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad j = 1, 2, \dots, k. \quad (3.3)$$

Basit doğrusal regresyona benzer şekilde $\beta_0, \beta_1 \dots \beta_k$ parametreleri regresyon parametreleri şeklinde ifade edilir. Eşitlik 3.3'de hata teriminin beklenen deęerinin sıfır olduđu varsayılır. β_0 parametresi regresyon düzlemini kesen noktadır. β_1 parametresi X_2 sabit tutulduğunda, X_1 'de bir birimlik deęişime karşılık gelen Y bağımlı deęişkeninde beklenen deęişimini; β_2 ise X_1 sabit tutulduğunda, X_2 'de bir birimlik deęişime karşılık gelen Y bağımlı deęişkeninde beklenen deęişimi temsil etmektedir. β_j ($j = 0, 1, \dots, k$) olarak tanımlı parametreler kısmi regresyon katsayıları olarak adlandırılırlar (Alpar, 2011; Montgomery ve dię. 2012). Çoklu doğrusal regresyonda model parametrelerinin tahmini en küçük kareler ve en çok olabilirlik tahmin yöntemleri ile gerçekleştirilebilmektedir. Model parametrelerinin ($\beta_0, \beta_1, \beta_2$) en küçük kareler yöntemi ile tahminleri b_0, b_1 ve b_2 deęerleri olmaktadır. Hata kareler toplamının ($\sum \varepsilon^2 = (Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2 - \dots - \beta_k X_k)^2$) en küçük deęerine ulaşmak için β_0, β_1 ve β_2 için ayrı ayrı kısmi türevler alınıp sıfıra eşitlenir. Burada elde edilen normal eşitlikler çözümlenir. Böylece b_0, b_1 ve b_2 deęerleri elde edilmiş olunur. Bu hesaplamalara ilişkin çözümler matrisler yardımıyla gerçekleştirilebilmektedir. Bağımlı deęişkende var olan toplam varyasyonun model tarafından açıklanan kısmı belirleme katsayısı ile elde edilebilmektedir. Gözlenen

varyasyon regresyon kareler toplamı (RKT), hata kareler toplamı (HKT) ve genel kareler toplamı (GKT) şeklinde kısımlara ayrıldığında belirleme katsayısı $R^2 = RKT/GKT$ şeklinde hesaplanabilmektedir. Modelin genel yeterliliği ve modele dahil edilmek istenen bağımsız değişkenlerden hangilerinin önemli görüldüğünün araştırılmasında hipotez testlerinden yararlanır. Bu testler rastgele hataların bağımsız olmaları, $E(\varepsilon_i) = 0$ ve $Var(\varepsilon_i) = \sigma^2$ ile normal dağılımları kuralını gerektirir (Alpar, 2011).

3.1.2. Klasik Doğrusal Olmayan Regresyon Analizi

Regresyon analizinde, k adet X bağımsız değişkeni ile Y bağımlı değişkeni arasındaki ilişkilerin matematiksel gösterimi Eşitlik 3.4'teki gibi ifade edilebilmektedir.

$$Y_i = f(\underline{X}_i, \underline{\theta}) + e_i, \quad i = 1, 2, \dots, n. \quad (3.4)$$

Burada;

e_i : Deneysel hata

$\underline{\theta}$: k boyutlu parametre vektörü,

$\underline{X} = (X_1, X_2, \dots, X_k)$: Bağımsız değişkenlerin vektörünü ifade etmektedir.

$f(\underline{X}_i, \underline{\theta})$: Değişkenler arasında var olduğu sayılan ilişkinin matematiksel ifadesini göstermek üzere, parametreler doğrusal veya doğrusal olmayan nitelikte olabilirler. Burada f fonksiyonu $\underline{\theta}$ parametre vektörünün bileşenleri açısından doğrusal olmayan bir formda olduğu takdirde incelenen model doğrusal olmayan regresyon modeli olarak adlandırılır (Bates ve Watts, 1988). Doğrusal modeller genel olarak Eşitlik 3.5'de yer alan ifade ile gösterilebilir.

$$Y_i = \sum_{j=1}^k X_{ij}\theta_j + e_i, \quad i = 1, 2, \dots, n. \quad j = 1, 2, \dots, k. \quad (3.5)$$

Eşitlik 3.5'de belirtilen forma uymayan herhangi bir regresyon modeli ise doğrusal olmayan regresyon modeli olarak adlandırılır. Eşitlik 3.6- 3.8'de tek değişkenli doğrusal olmayan regresyon modellerine örnekler verilmiştir.

$$Y_i = \theta_1 \cdot e^{\theta_2 X_i + e_i} \quad (3.6)$$

$$Y_i = \exp(\theta_1 + \theta_2 \cdot X_i^2 + e_i) \quad (3.7)$$

$$Y_i = \frac{\theta_1}{\theta_1 - \theta_2} [e^{-\theta_2 X_i} - e^{-\theta_1 X_i}] + e_i \quad (3.8)$$

Doğrusal olmayan modelde tahmin edilecek parametreler θ ile belirtilir. Burada e hata terimidir. Hataların bağımsız, aynı dağılımlı, beklenen değerlerinin sıfır ve eşit varyanslı olduğu varsayılmaktadır. Bu ifadenin matematiksel gösterimi $E(e_i) = 0$ ve $V(e_i) = \sigma^2$ şeklinde olmaktadır. Doğrusal olmayan regresyon modellerinin bir kısmının transformasyonlar yardımıyla doğrusal forma getirilmesi mümkündür. Örneğin Eşitlik 3.9'da belirtilen doğrusal olmayan regresyon modelinde e tabanına göre logaritma alındığında Eşitlik 3.10'da belirtilen forma dönüştürülmüş ve parametreler açısından doğrusal hale getirilmiştir. Bu tip modellere “doğrusallaştırılabilir doğrusal olmayan modeller” denir

$$Y_i = \exp(\theta_1 + \theta_2 X_i^2 + e_i) \quad (3.9)$$

$$\ln Y_i = \theta_1 + \theta_2 \cdot X_i^2 + e_i \quad (3.10)$$

Buna karşın Eşitlik 3.11-3.13'de tanımlı modellerin doğrusal şekle getirilmesi mümkün değildir. Bu tip modellere “doğrusal olmayan modeller” denilmektedir.

$$Y_i = \theta_1 + \theta_2 e^{X_i \theta_3} + e_i \quad (3.11)$$

$$Y_i = \theta_1 + \theta_2 \cos(\theta_4 X_i) + \theta_3 \sin(\theta_4 X_i) + e_i \quad (3.12)$$

$$Y_i = \frac{\theta_1}{\theta_1 - \theta_2} \cdot e^{-\theta_2 X_i} - \frac{\theta_1}{\theta_1 - \theta_2} \cdot e^{-\theta_1 X_i} + e_i \quad (3.13)$$

Çok değişkenli doğrusal olmayan regresyon modeli M tane tek değişkenli doğrusal olmayan regresyon modeli ele alınarak Eşitlik 3.14'de yer alan denklem dizileri ile ifade edilebilir (Gallant, 1987; Genç, 1997).

$$Y_{at} = f_a(\underline{x}_t, \underline{\theta}_a) + e_{at}, \quad a = 1, 2, \dots, M. \quad t = 1, 2, \dots, n. \quad (3.14)$$

$$Y_{1t} = f_1(\underline{x}_t, \underline{\theta}_1) + e_{1t}, \quad t = 1, 2, \dots, n.$$

$$Y_{2t} = f_2(\underline{x}_t, \underline{\theta}_2) + e_{2t}, \quad t = 1, 2, \dots, n.$$

⋮

$$Y_{Mt} = f_M(\underline{x}_t, \underline{\theta}_M) + e_{Mt}, \quad t = 1, 2, \dots, n.$$

Eşitlik 3.14'de ifade edilen M tane denklem dizisinin matris formunda matematiksel gösterimi aşağıda verilmiştir.

$$Y_{M \times n} = \begin{bmatrix} Y_{11} & Y_{12} & \dots & Y_{1n} \\ Y_{21} & Y_{22} & \dots & Y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{M1} & Y_{M2} & \dots & Y_{Mn} \end{bmatrix} = \begin{bmatrix} Y'_1 \\ Y'_2 \\ \vdots \\ Y'_M \end{bmatrix},$$

$$f_{M \times n}(\underline{x}, \underline{\theta}) = \begin{bmatrix} f_1(\underline{x}_1, \underline{\theta}_1) & f_1(\underline{x}_2, \underline{\theta}_1) & \dots & f_1(\underline{x}_n, \underline{\theta}_1) \\ f_2(\underline{x}_1, \underline{\theta}_2) & f_2(\underline{x}_2, \underline{\theta}_2) & \dots & f_2(\underline{x}_n, \underline{\theta}_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_M(\underline{x}_1, \underline{\theta}_M) & f_M(\underline{x}_2, \underline{\theta}_M) & \dots & f_M(\underline{x}_n, \underline{\theta}_M) \end{bmatrix} = \begin{bmatrix} f'_1(\underline{x}, \underline{\theta}_1) \\ f'_2(\underline{x}, \underline{\theta}_2) \\ \vdots \\ f'_M(\underline{x}, \underline{\theta}_M) \end{bmatrix},$$

$$e_{M \times n} = \begin{bmatrix} e_{11} & e_{12} & \dots & e_{1n} \\ e_{21} & e_{22} & \dots & e_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ e_{M1} & e_{M2} & \dots & e_{Mn} \end{bmatrix} = \begin{bmatrix} e'_1 \\ e'_2 \\ \vdots \\ e'_M \end{bmatrix},$$

$$\theta_{M \times p} = \begin{bmatrix} \theta_{11} & \theta_{12} & \dots & \theta_{1p_1} \\ \theta_{21} & \theta_{22} & \dots & \theta_{2p_2} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{M1} & \theta_{M2} & \dots & \theta_{Mp_M} \end{bmatrix} = \begin{bmatrix} \theta'_1 \\ \theta'_2 \\ \vdots \\ \theta'_M \end{bmatrix},$$

$$Y_{M \times n} = f_{M \times n}(\underline{x}, \underline{\theta}) + e_{M \times n}.$$

Eşitlik 3.14'de $a = 1, 2, \dots, M$ ve $t = 1, 2, \dots, n$ olmak üzere Y_{at} tek değişkenli tepki değeridir. \underline{x}_t , k boyutlu girdi vektörü; $\underline{\theta}_a$, p_a boyutlu bilinmeyen parametre vektörü; $\underline{\theta}_a^0$ ise bilinmeyen $\underline{\theta}_a$ 'nın gerçek değerini ifade etmektedir. e_{at} ise deneysel hatayı temsil etmektedir. \underline{e}_t hata vektörüne ilişkin varsayımlar; $\underline{e}_1, \underline{e}_2, \dots, \underline{e}_M$ hata vektörlerinin bağımsız ve aynı dağılımlı, ortalaması sıfır ve bilinmeyen varyans-kovaryans matrisine sahip olması şeklindedir. Bahsi geçen varsayımların matematiksel gösterimi Eşitlik 3.15'de yer almaktadır.

$$e_t = \begin{bmatrix} e_{1t} \\ e_{2t} \\ \vdots \\ e_{Mt} \end{bmatrix}, \quad E(e_t) = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad (3.15)$$

$$Cov(\underline{e}_t) = \Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1M} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{M1} & \sigma_{M2} & \dots & \sigma_{MM} \end{bmatrix}, \quad t = 1, 2, \dots, n.$$

Gallant (1987) ve Genç (1997)'de belirtildiği üzere hatalara ilişkin varyans-kovaryans matrisi ile hata kareler toplamını elde etmek amacıyla aşağıda belirtilen işlemler uygulanmaktadır. Çok değişkenli doğrusal olmayan regresyon modeli için denklemlere göre gruplanmış vektör formu Eşitlik 3.16'da verilmektedir. M tane tek değişkenli doğrusal olmayan model olduğu varsayılmaktadır.

$$\underline{Y}_a = \begin{bmatrix} Y_{a1} \\ Y_{a2} \\ \vdots \\ Y_{an} \end{bmatrix}_{n \times 1}, \quad \underline{f}_a(\underline{\theta}_a) = \begin{bmatrix} f_a(x_1, \underline{\theta}_a) \\ f_a(x_2, \underline{\theta}_a) \\ \vdots \\ f_a(x_n, \underline{\theta}_a) \end{bmatrix}_{n \times 1}, \quad \underline{e}_a = \begin{bmatrix} e_{a1} \\ e_{a2} \\ \vdots \\ e_{an} \end{bmatrix}_{n \times 1}, \quad (3.16)$$

$$\underline{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_M \end{bmatrix}, \quad \underline{f}(\underline{\theta}) = \begin{bmatrix} \underline{f}_1(\underline{\theta}_1) \\ \underline{f}_2(\underline{\theta}_2) \\ \vdots \\ \underline{f}_M(\underline{\theta}_M) \end{bmatrix}, \quad \underline{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_M \end{bmatrix},$$

$$\underline{Y} = \underline{f}_a(\underline{\theta}_a^0) + \underline{e}_a \quad a = 1, 2, \dots, M.$$

Burada $\underline{\theta}_1, \underline{\theta}_2, \dots, \underline{\theta}_M$, $\underline{\theta}$ parametre vektörünün bileşenlerini temsil etmektedir. Bu bileşenlerden bazıları aynı olabileceğinden dolayı ortak bileşenler $\underline{\theta}$ vektöründe bir kez yer almaktadır. $\underline{\theta}$ 'nin boyutu $\underline{\theta}_1, \underline{\theta}_2, \dots, \underline{\theta}_M$ vektörlerinin boyutları toplamından daha küçük olabilmektedir (Genç, 1997). Hatalar birbirinden bağımsız olmak üzere $a, \beta = 1, 2, \dots, M$ için kovaryans matrisine ilişkin bilgiler Eşitlik 3.17'deki gibi sunulmaktadır.

$$Cov(e_a, e'_\beta) = \begin{bmatrix} Cov(e_{a1}, e_{\beta 1}) & \dots & Cov(e_{a1}, e_{\beta n}) \\ \vdots & \ddots & \vdots \\ Cov(e_{an}, e_{\beta 1}) & \dots & Cov(e_{an}, e_{\beta n}) \end{bmatrix} \quad (3.17)$$

$$Cov(e_a, e'_\beta) = \begin{bmatrix} \sigma_{a\beta} & 0 & \dots & 0 \\ 0 & \sigma_{a\beta} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{a\beta} \end{bmatrix} = \sigma_{a\beta} I_n$$

$$Cov(\underline{e}) = \begin{bmatrix} \sigma_{11} I_n & \sigma_{12} I_n & \dots & \sigma_{1M} I_n \\ \sigma_{21} I_n & \sigma_{22} I_n & \dots & \sigma_{2M} I_n \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{M1} I_n & \sigma_{M2} I_n & \dots & \sigma_{MM} I_n \end{bmatrix} = \Sigma \otimes I$$

Hata kareler toplamı Eşitlik 3.18’de yer almaktadır.

$$S(\underline{\theta}, \Sigma) = (\underline{Y} - \underline{f}(\underline{\theta}))'(\Sigma \otimes I)^{-1}(\underline{Y} - \underline{f}(\underline{\theta})) \quad (3.18)$$

Doğrusal olmayan modellerde parametrelerin en küçük kareler tahminlerini bulmak için, doğrusal modelde olduğu gibi fonksiyonun parametrelere göre kısmi türevleri alınır ve bu yolla elde edilen denklem sistemlerinin çözümüne çalışılır. Ancak bu denklem sistemlerinin çözümü genellikle güç olup, birçoğunun ise analitik çözümü bulunmamaktadır. Eşitlik 3.19’da yer alan doğrusal olmayan çok değişkenli modelin $\underline{\theta}$ ve Σ parametrelerine ilişkin tahmin en küçük kareler tekniği ile yapılmak istenmektedir. \underline{e} hataları bağımsız, aynı dağılımlı ve bilinmeyen Σ varyans-kovaryans matrisli olduğu varsayılmaktadır.

$$\underline{Y} = \underline{f}(\underline{x}, \underline{\theta}) + \underline{e} \quad (3.19)$$

Denklemlere göre gruplanmış çok değişkenli doğrusal olmayan regresyon modelinde, tek değişkenli doğrusal olmayan her bir model için $n \times p_a$ boyutlu Jacobian matrisi Eşitlik 3.20’de belirtilmiştir.

$$F_a(\underline{\theta}_a) = \frac{\partial}{\partial \theta_a'} \underline{f}_a(\underline{\theta}_a), a = 1, 2, \dots, M. \quad (3.20)$$

$$S_a(\underline{\theta}_a) = [\underline{Y}_a - \underline{f}_a(\underline{\theta}_a)]' [\underline{Y}_a - \underline{f}_a(\underline{\theta}_a)] \quad a = 1, 2, \dots, M. \quad (3.21)$$

En küçük kareler tahminleme yönteminde $\hat{\underline{\theta}}_a^\#$ tahmin değeri, $S_a(\underline{\theta}_a)$ 'yı minimize eden $\underline{\theta}_a$ değeridir. Matematiksel gösterimi Eşitlik 3.21’de yer almaktadır. Her model için \underline{e} hata teriminin tahmini olan $\hat{\underline{e}}_a$ Eşitlik 3.22’de yer alan ifade ile elde edilmektedir. Varyans-kovaryans matrisi tahmini ise $\hat{\Sigma} = \frac{1}{n} \hat{E}' \hat{E}$ şeklinde hesaplanabilmektedir.

$$\hat{\underline{e}}_a = \underline{Y}_a - \underline{f}_a(\hat{\underline{\theta}}_a^\#), a = 1, 2, \dots, M. \quad (3.22)$$

$$\hat{E} = [\hat{\underline{e}}_1 \quad \hat{\underline{e}}_2 \quad \dots \quad \hat{\underline{e}}_M]$$

$\hat{\underline{\theta}}_a^\#$ 'nın ve varyans-kovaryans matrisi tahmininin elde edilmesi sürecinde $S_a(\underline{\theta}_a)$ karesel formun minimize edilmesi amacıyla bir başka ifade ile parametre tahmini amacıyla kullanılan sayısal yöntemlerden bazıları Gauss-Newton, Levenberg-Marquardt, en dik iniş

(steepest descent), Powell ve Hartley şeklindedir (Gallant, 1987; Seber ve Wild, 1989; Genç, 1997).

θ 'nın en küçük kareler tahmini ayrıca en çok olabilirlik tahminine karşı gelmektedir. Tanımlanan model için en çok olabilirlik fonksiyonu Eşitlik 3.23'de yer almaktadır.

$$L(\theta, \sigma^2) = (2\pi\sigma^2)^{-n/2} e^{-S(\theta)/2\sigma^2} \quad (3.23)$$

Burada σ^2 bilindiği için $L(\theta, \sigma^2)$ 'nin θ 'ya göre maksimize edilmesi, hata kareler toplamının minimize edilmesine eşdeğerdir. θ 'nın en küçük kareler tahmininin bulunabilmesi için hata kareler toplamının θ 'ya göre kısmi türevlerinin alınması gerekmektedir. Kısmi türevlerin alınıp sifıra eşitlenmesi ile p tane normal eşitlik elde edilir. Ancak elde edilen bu eşitliklerden tek bir parametre ile dahi $\hat{\theta}$ 'nın çekilmesi oldukça zordur. Parametre sayısı arttığında normal eşitliklerin çözümü güçleşmekte ve parametrelerin tahmini için iterasyona dayalı yöntemlere gereksinim duyulmaktadır.

İterasyona dayalı tüm yöntemlerde bir başlangıç noktasının verilmesi gerekmektedir. Doğrusal olmayan regresyon modellerine kareler toplamı için birden fazla minimum bulunabileceğinden başlangıç noktalarının seçimi dikkatlice yapılmalıdır. İyi seçilmiş başlangıç noktaları iterasyon sayısını azaltacağı gibi mutlak minimum yerine lokal minimumlardan birisinin bulunması olasılığını da azaltır. Doğrusal olmayan regresyon analizinde parametrelerin başlangıç değerlerinin belirlenmesi kısmen araştırmacının ilgili konudaki analiz tecrübesine bağlı olabilmektedir. Başlangıç değerlerinin belirlenmesi sürecinde, grafiksel ve görsel açıdan değerlendirmeler de araştırmacılara yardımcı olabilir. Bir diğer bakış açısı ise parametre tahminlerine ilişkin bir aralık belirlenebilir ve artıkların kareler toplamları hesaplanarak en küçük değere sahip olan başlangıç değerleri seçilebilir (Ritz ve Streibig, 2008).

Doğrusal olmayan regresyon analizinde uyum iyiliğinin belirlenmesi ve model varsayımlarının incelenmesi, modelin veri yapısına uygunluğu ve parametre tahminlerinin etkinliğinin yorumlanmasında oldukça önemlidir. Doğrusal regresyon analizinde geçerli olan varsayımların büyük bir çoğunluğu, doğrusal olmayan regresyon analizi için de kullanılabilir. Artıkların normal dağılımı ve bağımsızlığı ile değişen varyanslılığa ilişkin varsayımlar bunların en önemlileridir. Artıkların analiz sürecinde normallik araştırması Q-Q grafiğinin incelenmesi ve artıklara Kolmogorow-Smirnov, Shapiro-Wilk ve Jarque-Bera testlerinin uygulanması sonucu elde edilen test istatistiklerinin

değerlendirilmesi ile gerçekleştirilebilir. Artıkların bağımsız olup olmadığının tespiti Durbin-Watson testi ile değişen varyanslılık durumu ise Breusch-Pagan ve White testleri kullanılarak araştırılabilmektedir (Gujarati, 1999).

3.2. Klasik Regresyon Analizi Kapsamında Kullanılan Fonksiyon Yapıları

Hayvan yetiştirme ve besleme alanında gerçekleştirilen çeşitli uygulamalarda bağımlı değişken zamana bağlı olarak değişebilmektedir. Araştırma uygulamalarının büyüme veya laktasyon süreçleri üzerindeki etkilerini belirlemek veya zaman içinde nasıl bir değişim gösterdiğini incelemek amacıyla zamana bağlı verilerin analiz ve yorumlamaları yapılmaktadır. Genellikle zamana bağlı değişen veriler doğrusal olmayan fonksiyonlar tarafından temsil edilebilmekte ve eğrisel bir yapıya sahip olabilmektedir. Son yıllarda teknolojik gelişmelerle birlikte, doğrusal olmayan regresyon analizinde hesaplama olanaklarına ilişkin sınırlılıklar gittikçe azalmıştır. İstatistiksel paket programlarında oldukça büyük ilerlemeler kaydedilmiş ve doğrusal olmayan işlevlerin kullanım olanakları artmıştır.

Doğrusal olmayan regresyon modelleri biyolojik bilimler başta olmak üzere, birçok farklı bilim dalında farklı uygulamalara konu olmaktadır. İncelenen problemin içeriğine uygun olarak farklı model yapıları zaman içinde geliştirilmiştir. Örneğin sigmoidal fonksiyonlar mikrobiyal büyüme üzerine gerçekleştirilen çalışmalarda maksimum spesifik büyüme hızı ve gecikme zamanı gibi tanımlayıcı büyüme parametrelerinin tahmin edilmesine olanak sağlamaktadır (Zwietering ve diğ. 1990; McMeekin ve diğ. 1993; Peleg, 1997; López ve diğ. 2004). Hayvancılıkta doğrusal olmayan regresyon analizinin bir başka kullanım alanı yem sindirimi ile ilgili gaz üretim eğrilerinin modellenmesidir. Bu amaçla kullanılan model yapıları gaz üretim profilini ortaya koymaktadır (France ve diğ. 2000).

Hayvancılıkta oldukça geniş bir kullanım alanına sahip büyüme eğrileri ile ilgili doğrusal olmayan regresyon analizi kapsamında çeşitli model yapıları türetilmiştir. Literatürde çok sayıda büyüme fonksiyonları çeşitli araştırmacılar tarafından bildirilmiştir (Turner ve diğ. 1976; Ricker, 1979; Parks, 1982; Ratkowski, 1983; Simondon ve diğ. 1992; Gill ve Oldham, 1993; Zeide, 1993; France ve diğ. 1996; López ve diğ. 2000; Sainz ve Baldwin, 2003; Seber ve Wild, 2003; Wellock ve diğ. 2004). Büyüme fonksiyonlarının kullanım amacı, hayvanların bedensel büyüme eğrileri ve ilgili diğer büyüme özelliklerini türeterek biyolojik anlamda yorumlanmasını sağlamaktır. Modelde yer alan parametreler aracılığı ile büyümeye etki eden faktörler açıklanabilmekte böylece farklı koşullar altında karşılaşılan

benzer problem yapılarına çözüm üretilebilmektedir. Araştırmacılar genetik ve çevresel faktörlerin büyüme özellikleri üzerindeki etkisini, et üretim verimliliğini artırmak için alternatif stratejilerin belirlenmesini, et hayvanlarının büyüme potansiyelinin değerlendirilmesini, hayvanların beklenen günlük kilo artışına dayalı olarak besin gereksinimlerini tahmin etmek için genetik ve çevresel faktörlerin anlaşılmasında büyüme eğrisi modellerinden kapsamlı şekilde yararlanmaktadır (Lopez, 2008).

Doğrusal olmayan regresyon analizi kapsamında incelenen süt verim eğrileri veya laktasyon eğrileri süt üretimi yapan işletmeler açısından ekonomik anlamda çok büyük bir öneme sahiptir. Laktasyon eğrileri, tarımsal alanda başarı ile uygulanan matematiksel model yapılarından birisidir ve laktasyon süresi boyunca süt üretiminin görsel ve matematiksel gösterimini sağlamaktadır (Macciotta ve diğ. 2011). Modellemedeki temel amaç, en düşük hata ile laktasyon günlerindeki süt verimini ve bazı önemli performans özelliklerine ilişkin tahminleri elde etmektir (Marek ve diğ. 2015). Süt sığırcılığı alanında yapılan çalışmalarda ekonomik açıdan oldukça büyük öneme sahip laktasyon eğrilerinin modellenmesinde doğrusal olmayan regresyon analizi teknikleri yaygın şekilde kullanılmaktadır. Polinomial yapıda olan fonksiyonlar Nelder, Singh ve Gopal, Ali-Schaeffer; Eksponansiyel yapıda olanlar Gaines (Brody), Cobby-LeDudouble, Wilmink, Morant- Gnanasakthy, Pollont; Gamma fonksiyon yapısında olanlar, Wood, Jenkins-Ferrel, Dhanoa, Sauvant- Fehr ve Schneeberger şeklindedir (Brody ve diğ. 1923b; Brody ve diğ. 1924; Wood, 1967; Cobby ve Le Du, 1978; Ali ve Schaeffer, 1987; Wilmink, 1987; Rook ve diğ. 1993; Pollott, 2000). Literatürde laktasyon eğrileri ile ilgili çalışmaların büyük bir çoğunluğunun süt verimine yönelik gerçekleştiği görülmektedir. Ancak bunun yanı sıra protein, yağ ve somatik hücre gibi süt verimine ilişkin diğer özellikler de modellenmektedir (Buttchereit ve diğ. 2010; Golebiewski ve diğ. 2011; Hossein-Zadeh 2016a; Hossein-Zadeh 2016b). Ayrıca yağ asidi kompozisyonu ve su alımı üzerine süt besin kalitesi ile ilgili özellikler laktasyon eğrileri çalışmalarına konu olmuştur (Craninx ve diğ. 2008; Kramer ve diğ. 2009b). Son yıllarda laktasyon eğrilerinin modellenmesinde, geleneksel yöntemlerin yanı sıra zaman serisi analizleri (Deluyker ve diğ. 1990; Macciotta ve diğ. 2002; Berberoğlu, 2010) ile yapay sinir ağları (Grzesiak ve diğ. 2006) gibi yapay zeka temelli yöntemler alternatif olarak kullanılmaktadır.

Yumurta tavukçuluğunda yumurta üretim süreci doğrusal olmayan regresyon analizi ile modellenilebilmektedir. Yumurta üretim eğrisi kanatlı hayvanlarda sürünün ortalama üretim oranının göstergesidir. Eğride zirve noktasına kadar artış ve ardından gelen üretim sürecini

sonlandıran düzenli düşüş görülebilmektedir. Laktasyon eğrilerine benzer şekilde yumurta verim eğrilerinin modellenmesinde de farklı yapıda modeller bulunmaktadır. Bu modeller tavukların bireysel veya sürü bazında üretim döngüsünü temsil etmek üzere türetilmişlerdir. Bu modellerden bazıları Narushin- Takma, Adams- Bell, Lokhorst, Minder- McMillian, Lojistic-Curvilinear, Compartmental, Wood, McNally şeklindedir (McMillian, 1981, Gavora ve diğ. 1982; Fialho ve Ledur, 1997; Grossman ve diğ. 2000; Narushin ve Takma, 2003). Yapay sinir ağı modelleri yumurta performansının modellenmesinde, laktasyon eğrilerine benzer şekilde, klasik yöntemlere alternatif olarak kullanılabilir (Ahmadi ve Golian, 2008; Ahmad, 2011; Savegnago ve diğ. 2011; Semsarian ve diğ. 2013).

Tez çalışmasında tek değişkenli klasik doğrusal olmayan regresyon analizi kapsamında kullanılan model yapıları; Logistic model (Nelder. 1961), Compartmental model (McMillan ve diğ. 1970a; McMillan ve diğ. 1970b), McNally modeli (McNally, 1971) ve Gamma modeli (Wood, 1967) olarak belirlenmiştir.

3.2.1. Logistic Model

Tez çalışmasında yumurtacı tavukların performans modellenmesini sağlamak üzere eğri uyumu, Nelder (1961) tarafından kullanılan doğrusal olmayan Logistic model ile elde edilmiş ve Eşitlik 3.24'de verilmiştir.

$$y_t = a\{1 + e^{(b-(ct))}\}^{-1} e^{-xt} \quad (3.24)$$

Eşitlik 3.24'de t : zaman; y : t zaman boyunca yumurta üretim oranını; a : Üretim sürecinde tepe noktasında yumurta üretiminin asimptotik değeri; b : Eğrinin büyümesiyle ilişkili bir değerdir; c : Sabit; x : Yumurta üretiminin persistensi ile ilişkili bir değerdir. Modelde yer alan e^{-xt} terimi tepe noktasından sonra daha iyi bir uyum sağlayabilmek adına eklenmiştir (Brody ve diğ. 1923a; Cason ve Ware, 1990; Savegnago ve diğ. 2011). Logistic model tez çalışması kapsamında sadece tek değişkenli doğrusal olmayan regresyon analizini gerçekleştirmek üzere analizlerde yer almıştır.

3.2.2. Compartmental Model

Compartmental fonksiyon, McMillan (1981) tarafından yumurta üretim modeline dönüştürülmüştür. Eşitlik 3.25'de tavukların en yüksek yumurtlama oranı ile üretime başladıkları ve başlangıç zamanının eksponansiyel olarak dağıldığı varsayılmıştır. b

parametresi yumurta üretiminde anlık artış oranını, c parametresi anlık düşüş oranını, a yumurta üretiminin en yüksek potansiyelini temsil eder (McMillan, 1981; Narinc, 2014). Compartmental model tez çalışmasında sadece tek değişkenli doğrusal olmayan regresyon analizini gerçekleştirmek üzere kullanılmıştır. Matematiksel gösterimi Eşitlik 3.25’de verilmiştir.

$$y_t = a(e^{-ct} - e^{-bt}) \quad (3.25)$$

3.2.3. McNally Model

Tez çalışması kapsamında hem tek değişkenli, hem de çok değişkenli doğrusal olmayan klasik regresyon analizini gerçekleştirmek üzere McNally (1971) tarafından kanatlı hayvanlarda yumurta veriminin modellenmesi amacıyla geliştirilen fonksiyon kullanılmıştır. Gamma Fonksiyonunun düzenlenmiş hali olarak literatürde yer alan model, doğrusallaştırılabilen doğrusal olmayan regresyon analizi modellerinden birisidir (McNally, 1971; Lopez, 2008). Fonksiyonun matematiksel gösterimi Eşitlik 3.26’da yer almaktadır.

$$y_t = at^b e^{(-ct+dt^{0.5})} \quad (3.26)$$

Çok değişkenli doğrusal olmayan regresyon analizinin Matlab programı kullanılarak analiz edilebilmesi amacıyla eşitliğin her iki tarafının logaritması alınmıştır. Böylece model doğrusal forma dönüştürülmüştür. Eşitlik 3.27’de doğrusal forma dönüştürülmüş fonksiyonun matematiksel gösterimi yer almaktadır.

$$\ln(y_t) = \ln(a) + b \cdot \ln(t) - c \cdot t + d \cdot \sqrt{t} \quad (3.27)$$

Eşitliklerde y_t : t zaman diliminde yumurta verimini; a : başlangıç üretimini; b , c ve d ise eğrinin azalış ve artış eğimi ile ilgili model parametrelerini temsil etmektedir.

3.2.4. Gamma model

Wood (1967) tarafından geliştirilen Gamma fonksiyonu literatürde oldukça kabul görmüş ve güvenilirliği yüksek model yapılarından birisidir. Tez çalışması kapsamında doğrusal olmayan tek değişkenli bulanık regresyon analizi sonuçları ile karşılaştırma yapmak amacıyla çalışmaya dahil edilmiştir. Gamma fonksiyonu tez çalışmasında sadece tek değişkenli doğrusal olmayan regresyon analizini gerçekleştirmek üzere kullanılmıştır.

Gamma fonksiyonuna ilişkin matematiksel gösterim Eşitlik 3.28'de yer almaktadır.

$$Y_t = a \cdot t^b \cdot e^{(-c \cdot t)} \quad (3.28)$$

Modelde verimin en yüksek olduğu değer Eşitlik 3.29'da, en yüksek verim değerine ulaşma zamanı ise Eşitlik 3.30'da gösterilmektedir (Papajcsik ve Bodero, 1988; Grzesiak ve diğ. 2006).

$$PY = a \cdot (b/c)^b \cdot e^{-b} \quad (3.29)$$

$$PT = b/c \quad (3.30)$$

Eşitlik 3.28'de y_t : Verilen t zaman boyunca yumurta performans değerini; t : Zamanı; a parametresi: Başlangıç üretim değerini; b ve c parametreleri: Eğrinin sırası ile artış ve azalış eğimi ile ilişkili faktörleri belirtmektedir ve e doğal logaritma tabanını ifade etmektedir. Gamma modeli logaritmik transformasyon ile doğrusallaştırılabilen doğrusal olmayan regresyon modellerinden birisidir (Wood, 1967; Papajcsik ve Bodero, 1998; Grzesiak ve diğ. 2006; Tekerli ve diğ. 2000).

Tek değişkenli klasik doğrusal olmayan regresyon analizi kapsamında kullanılan model yapıları; Logistic model (Nelder. 1961), Compartmental modeli (McMillan ve diğ. 1970a; McMillan ve diğ. 1970b), McNally modeli (McNally, 1971) ve Gamma modeli (Wood, 1967) olarak belirlenmiştir. Çok değişkenli klasik doğrusal olmayan regresyon analizi kapsamında ise sadece McNally modeli ele alınmıştır. Parametrelerin tahmini, iteratif yöntemlerden birisi olan Levenberg-Marquardt tekniği ile gerçekleştirilmiştir. Parametrelerin başlangıç değerleri literatürde yer alan çalışmaların sonuçları incelenerek belirlenmiştir. Yakınsama kriteri 1.0E-08 olarak belirlenmiştir. Bu çalışmada klasik doğrusal olmayan regresyon analizi modellerinin, araştırmaya konu olan veri setine sağladığı uyum ortalama mutlak yüzde hata (OMYH) ve hata kareler ortalaması (HKO) kriterleri kullanılarak değerlendirilmiştir.

3.3. Bulanık Kümeler

Bulanık küme teorisi, klasik mantıkta yer alan kesinlik içeren düşünce yapısının yerine belirsizlik içeren dilsel ifadelerin kullanıldığı yaklaşık düşünmeyi temsil etmektedir (Zadeh, 1965). Bulanık mantık sayesinde insanların sahip olduğu tecrübelerin matematiksel modellemesi bilgisayar ortamına aktarılmakta böylece insanlara karar verme sürecinde büyük kolaylıklar sağlanmaktadır.

Aristo mantığında olaylar yapısında kesin doğru ve kesin yanlış ile ifade edilen sadece “0” ve sadece “1” ifadeleri kullanılarak açıklanmaktadır. Bulanık mantıkta ise olaylar sadece “0” ve sadece “1” ifadelerinin yanı sıra $[0, 1]$ kapalı aralığında belirli bir derece ile gösterilmektedir. Klasik mantıkta örneğin sıcak-soğuk, düşük-yüksek şeklinde ikili tanımlanan kavramlar, bulanık mantıkta “biraz, çok, çok fazla” gibi bulanık değişkenler kullanılarak nitelendirilmektedir. Çok değerli üyelik esas alındığı bulanık mantıkta önermeler, “hava çok sıcak” veya “hız çok düşük” gibi ifadelerle incelenmektedir.

Klasik kümelerde küme elemanları için iki değerli üyelik söz konusudur ve bir nesne bir kümenin ya elemanıdır (1) veya değildir (0) şeklinde tanımlanmaktadır. Bulanık kümelerde ise çok değerli üyelik kavramı mevcuttur. Bu özellik bulanık kümelerin klasik mantık sisteminden ayrılmasını sağlayan en önemli kavramlardan birisidir. Örneğin bir ineğin süt verimi klasik küme yapısına göre sadece düşük (0) ve sadece yüksek (1) olmak üzere ikili üyelik kavramı ile tanımlanmaktadır. Bulanık küme yapısında ise süt verimi “biraz düşük, düşük, orta, yüksek” gibi esnek niteleyiciler sayesinde $[0, 1]$ aralığında aynı anda farklı üyelik dereceleri ile farklı kümelerin elemanı olabilmektedir. Böylece gerçek hayata uygun ve gerçekçi değerlendirmeler yapılabilmektedir. Bulanık kümelerde, klasik kümelerde olduğu gibi sınırlar kesin çizgilerle ayrılmamaktadır (Görgülü 2007; Akkaptan, 2012).

Bulanık kümelerde üyelik derecesi, söz konusu nesnenin bulanık kümeye aidiyet miktarını ifade etmektedir ve $[0, 1]$ aralığında değişen değerler alabilmektedir. Üyelik derecesini hesaplamak için çeşitli üyelik fonksiyonları kullanılmaktadır. Literatürde en fazla karşılaşılan üyelik fonksiyonları üçgen, yamuk, çan eğrisi, Gauss, Sigmoidal, S ve pi şeklindedir. Bulanık kümeler, üyelik dereceleri sürekli olan nesnelere veya öğelere topluluğudur ve üyelik fonksiyonları ile tanımlanırlar. Üyelik fonksiyonları incelenen problemin yapısına göre değişiklik gösterebilir. (Zimmerman, 1991; Başaran, 2007).

Üçgen üyelik fonksiyonu a, b ve c gibi üç parametre ile Eşitlik 3.31’de yer alan matematiksel ifadeler yardımıyla tanımlanmaktadır.

$$\mu_A = (x; a, b, c) = \begin{cases} a \leq x \leq b & \text{ise } (x - a)/(b - a) \\ b \leq x \leq c & \text{ise } (c - x)/(c - b) \\ x > c \text{ veya } x < a & \text{ise } 0 \end{cases} \quad (3.31)$$

X evrensel kümesinde tanımlı A bulanık kümesi için üyelik fonksiyonuna ilişkin matematiksel gösterim aşağıdaki ifadede yer almaktadır.

$$\mu_A: X \rightarrow [0, 1]$$

A bulanık kümesi, küme elemanları ve üyelik dereceleri ile aşağıda yer alan ifade yardımıyla gösterilebilmektedir (Wang 1997; Görgülü 2007).

$$A = \{x, \mu_A(x) | x \in X\}$$

X evrensel kümesinin elemanları sürekli olduğunda,


$$A = \int \mu_A(x)/x$$

kesikli olduğunda ise,

$$A = \sum \mu_A(x)/x$$

olarak ifade edilmektedir.

Bulanık kümeler dışbükey ve normal olma özelliklerine sahip olmalıdırlar. Normal olarak nitelendirilen bulanık kümenin yüksekliğinin bire eşit olması gerekmektedir. Böylece en büyük üyelik derecesi de bire eşit olmuş olur. Matematiksel gösterimi $\max_{x \in X} \mu_A(x) = 1$ şeklinde ifade edilmektedir (Yapıcı Pehlivan, 2005). Dışbükeylik ise fonksiyonun üyelik derecesi bire eşit oluncaya kadar sürekli artan ve daha sonra azalan olmasını temsil etmektedir. Üyelik fonksiyonları kullanılarak bulanık kümelerde kesişim, birleşim, tümleme gibi cebirsel işlemler gerçekleştirilebilmektedir. Bulanık sayılar kendi üyelik fonksiyonları ile tanımlanırlar. Başta üçgen ve yamuk olmak üzere farklı türde bulanık sayılar mevcuttur. Şekil 3.1’de normal ve normal olmayan bulanık kümeler ile dışbükey ve dışbükey olmayan bulanık kümelerin şekilsel gösterimi yer almaktadır.



Şekil 3.1: Normal (a) ve Normal Olmayan (b), Dışbükey (c) ve Dışbükey Olmayan (d) Bulanık Kümeler.

Üyelik fonksiyonlarına ilişkin farklı değer atama yöntemleri mevcuttur. Bunlardan en fazla karşılaşılan yöntem karar vericinin sezgisel şekilde hareket etmesidir. Karşılaşılan problemin niteliği ve veri yapısına bağlı olarak araştırmacı farklı üyelik fonksiyonları arasından seçim yapmaktadır. Ayrıca genetik algoritmalar gibi evrimsel hesaplama dayalı bazı arama algoritmaları ile yapay sinir ağları gibi yapay zeka temelli yöntemler de araştırmacılar tarafından kullanılmaktadır. Ancak hesaplama zorluğu ve yöntemlerin karmaşık olmasından dolayı daha az tercih edilmektedirler (Arslan ve Kaya 2001; Bağış, 2003; Jiang ve diğ.. 2008; Acilar ve Arslan 2011; Ross, 2004).

Bulanık küme teorisinde oldukça önemli kavramlardan birisi olan genişletme ilkesi Zadeh (1975) tarafından tanımlanmış sonrasında ise Yager (1986) tarafından ayrıntılı şekilde ele alınmıştır. Genişletme ilkesi bulanık olmayan ilişkileri bulanık karşılıklarının geliştirilmesinde kullanılan oldukça güçlü bir araçtır. Aynı zamanda da bulanık sayıların kullanıldığı bulanık aritmetiğin işlenmesinde araç olarak kullanılabilir (Fedrizi ve Kacprzyk, 1995). Bu kavram bulanık olmayan matematiksel ifadelerin (kavram ve teorilerin) belirsizlik ortamında bulanık miktarlarla açıklanmasını ve tanımlı bulanık kümeler genişletilmesini sağlamaktadır. Bulanık aritmetiğin gelişiminde oldukça önemli rol oynayan genişletme ilkesi; toplama, çıkarma, çarpma ve bölme gibi ikili aritmetik işlemlerin bulanık sayılar üzerinde uygulanmasında bir başka ifade ile bulanık kümeler genişletilmesinde bir araç olmuştur.

X evrensel kümelerin kartezyen çarpımını temsil etmek üzere,

$$X = X_1 \times X_2 \times \dots \times X_n$$

şeklinde ifade edilir. Burada n evrensel küme sayısıdır. X_1, X_2, \dots, X_n evrensel kümelerinin tanımlı bulanık alt kümeleri A_1, \dots, A_n şeklinde ifade edilir. Burada da n bulanık küme sayısını temsil etmektedir. n sayıda A bulanık kümesine ilişkin kartezyen çarpımının matematiksel gösterimi $A_1 \times \dots \times A_n = \int_{X_1 \times \dots \times X_n} \min(\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n)) / (x_1, \dots, x_n)$ şeklindedir.

B bulanık kümesi Y evrensel kümesinde tanımlıdır. Burada $f: X \rightarrow Y$ ve $y = f(x_1, \dots, x_n)$ olmak üzere, bu noktada genişletme ilkesi X evrensel kümesinde tanımlı A bulanık kümesinden Y evrensel kümesinde tanımlı B bulanık kümesi arasındaki geçişi sağlamaktadır. Bir başka ifade ile B bulanık kümesi f fonksiyonu ile ifade

edilebilmektedir. B bulanık kümesinin üyelik fonksiyonu Eşitlik 3.32'deki gibi tanımlanmaktadır.

$$\mu_B(y) = \sup_{y=f(x_1, \dots, x_n)} \min(\mu_{A_1}(x_1), \dots, \mu_{A_r}(x_n)) \quad (3.32)$$


$$\mu_B(y) = 0 \quad \text{eğer } f^{-1}(y) = \emptyset$$

$f^{-1}(y)$ ifadesi y 'nin ters görüntüsüdür. $f^{-1}(y) = \emptyset$ olduğu durumda B bulanık kümesinin üyelik fonksiyonu sıfır değerini almaktadır, $\mu_B(y) = 0$ (Zadeh, 1975; Dubois ve Prade, 1980; Yager 1986; Ross 2004). Eşitlik 3.32'de yer alan ifade genel bir tanımlama ile Eşitlik 3.33'deki gibi yazılabilir.

$$B = f(A_1, \dots, A_n) = \int_{x_1 \times \dots \times x_n} \min(\mu_{A_1}(x_1), \dots, \mu_{A_n}(x_n)) / f(x_1, \dots, x_n) \quad (3.33)$$

3.4. Bulanık Sayı Kavramı

Bulanık küme teorisinde yer alan temel kavramlardan bir diğeri bulanık sayılardır. Bulanık sayılar gerçel sayılar kümesinde tanımlanan ve bulanık aralıklarla ifade edilen bir bulanık küme olarak literatürde ifade edilmektedir (Baykal ve Beyan, 2004a; Baykal ve Beyan 2004b; Lee, 2005). Bulanık aralık $[a_1, a_2, a_3]$ olarak üçgensel bulanık sayı için verildiğinde a_1 ve a_3 sınır noktaları; a_2 ise bulanık sayının tepe noktası olmaktadır. Bulanık sayılar ile toplama, çıkarma, çarpma ve bölme gibi cebirsel işlemler yapılabilmektedir (Ross, 2004; Görgülü, 2007). Şekil 3.2'de üçgen ve yamuk sayıların genel görünümü yer almaktadır.



Şekil 3.2: Üçgen ve Yamuk Bulanık Sayılar.

Bulanık sayılarda aritmetik işlemler, bulanık küme kavramları içinde yer alan genişletme ilkesi ve α kesimi (A_α) yardımıyla gerçekleştirilmektedir. α kesim kümesi, $\forall \alpha \in [0, 1]$ olmak üzere, α 'nın belirli bir değerinden eşit veya büyük olan, X evrensel kümesinde tanımlı tüm öğeleri içeren A bulanık kümesindeki üyelik dereceleri X evrensel

kümesinde tanımlı A bulanık kümesinde α kesim kümesi Eşitlik 3.34'de yer alan ifade ile belirtilmektedir (Klir ve Yuan 1995; Zimmermann 2001).

$$A_\alpha = \{x \in X | \mu_A(x) \geq \alpha\} \quad (3.34)$$

Bulanık kümelerde birleşim, kesişim ve tümlenme olarak bilinen temel bulanık işlemler sırasıyla Eşitlik 3.35-3.37'de verilmektedir. $x \in X$ olmak üzere A, B ve C bulanık kümelerdir.

$$(A \cup B)(x) = \forall x \in X | \max [A(x), B(x)] \quad (3.35)$$

$$(A \cap B)(x) = \forall x \in X | \min [A(x), B(x)] \quad (3.36)$$

$$\bar{A} = \{\forall x \in X | \mu_{\bar{A}}(x) = 1 - \mu_A(x)\} \quad (3.37)$$

Bulanık sayılara ilişkin toplama, çıkarma, çarpma ve bölme cebirsel işlemleri α kesimi kullanılarak gerçekleştirilebilir. α kesim seviyesi, bulanık aritmetik içinde bulanık sayılar ile ilgili önemli bir kavramdır. Bulanık sayıların α kesim seviyesi $\forall \alpha \in [0, 1]$ olarak belirtilen kapalı aralıkta gerçek sayı değerleri almaktadır. Burada her bulanık sayı bir konveks bulanık kümedir. Bu konu kapsamında tanımlamalar üçgensel bulanık sayılar üzerinden verilecektir (Klir ve Yuan, 1995). Toplama, çıkarma, çarpma ve bölme olmak üzere dört aritmetik işlemciye ilişkin matematiksel gösterimler Eşitlik 3.38-3.41'de verilmektedir.

$$[a, b] + [d, e] = [a + d, b + e] \quad (3.38)$$

$$[a, b] - [d, e] = [a - e, b - d] \quad (3.39)$$

$$[a, b] \cdot [d, e] = [\min(ad, ae, bd, be), \max(ad, ae, bd, be)] \quad 0 \notin [d, e] \quad (3.40)$$

$$[a, b] / [d, e] = [\min(a/d, a/e, b/d, b/e), \max(a/d, a/e, b/d, b/e)] \quad (3.41)$$

A ve B iki farklı üçgensel bulanık sayı olmak üzere üyelik fonksiyonlarına ilişkin bilgiler Eşitlik 3.42 ve 3.43'de belirtilmiştir.

$$\mu_A(x) = \begin{cases} (x + 1)/2 & \text{ise } -1 < x \leq 1 \\ (3 - x)/2 & \text{ise } 1 < x \leq 3 \\ 0 & \text{ise } x \leq -1 \text{ ve } x > 3 \end{cases} \quad (3.42)$$

$$\mu_B(x) = \begin{cases} (x-1)/2 & \text{ise } 1 < x \leq 3 \\ (5-x)/2 & \text{ise } 3 < x \leq 5 \\ 0 & \text{ise } x \leq 1 \text{ ve } x > 5 \end{cases} \quad (3.43)$$

A ve B bulanık sayılarının α kesim seviyeleri ile belirtilen matematiksel ifadeleri sırasıyla Eşitlik 3.44 ve Eşitlik 3.45'de yer almaktadır.

$$A_\alpha = [2\alpha - 1, 3 - 2\alpha] \quad (3.44)$$

$$B_\alpha = [2\alpha + 1, 5 - 2\alpha] \quad (3.45)$$

A ve B bulanık sayıları için α kesim seviyeleri kullanılarak gerçekleştirilen toplama, çıkarma, çarpma ve bölme cebirsel işlemleri Eşitlik 3.38-3.43'de verilen formüller yardımıyla Eşitlik 3.46-3.49'deki gibi hesaplanmaktadır.

$$(A + B)_\alpha = [4\alpha, 8 - 4\alpha] \quad (3.46)$$

$$(A - B)_\alpha = [4\alpha - 6, 2 - 4\alpha] \quad (3.47)$$

$$(A \cdot B)_\alpha = \begin{cases} [-4\alpha^2 + 12\alpha - 5, 4\alpha^2 - 16\alpha + 15] & \alpha \in (0, 0.5] \\ [4\alpha^2 - 1, 4\alpha^2 - 16\alpha + 15] & \alpha \in (0.5, 1) \end{cases} \quad (3.48)$$

$$(A/B)_\alpha = \begin{cases} \left[\frac{2\alpha-1}{2\alpha+1}, \frac{3-2\alpha}{2\alpha+1} \right] & \alpha \in (0, 0.5] \\ \left[\frac{2\alpha-1}{5-2\alpha}, \frac{3-2\alpha}{2\alpha+1} \right] & \alpha \in (0.5, 1] \end{cases} \quad (3.49)$$


Gerçekleştirilen hesaplamalar sonucunda elde edilen sonuçlar Eşitlik 3.50-3.53'de özetlenmiştir. A ve B bulanık sayılarının cebirsel işlemlerinin sonuçları Şekil 3.3'de toplama işlemi, Şekil 3.4'de çıkarma işlemi, Şekil 3.5'de çarpma ve Şekil 3.6'da bölme işlemi olmak üzere görülmektedir.

$$(A + B)(x) = \begin{cases} (x/4) & \text{ise } 0 < x \leq 4 \\ (8-x)/4 & \text{ise } 4 < x \leq 8 \\ 0 & \text{ise } x \leq 0 \text{ ve } x > 8 \end{cases} \quad (3.50)$$


$$(A - B)(x) = \begin{cases} (x+6)/4 & \text{ise } -6 < x \leq -2 \\ (2-x)/4 & \text{ise } -2 < x \leq 2 \\ 0 & \text{ise } x \leq -6 \text{ ve } x > 2 \end{cases} \quad (3.51)$$

$$(A \cdot B)(x) = \begin{cases} \frac{[3-(4-x)^{\frac{1}{2}}]}{2} & \text{ise } -5 \leq x < 0 \\ \frac{(1+x)^{\frac{1}{2}}}{2} & \text{ise } 0 \leq x < 3 \\ \frac{[4-(1+x)^{\frac{1}{2}}]}{2} & \text{ise } 3 \leq x < 15 \\ 0 & \text{ise } x < -5 \text{ ve } x \geq 15 \end{cases} \quad (3.52)$$


$$(A/B)(x) = \begin{cases} \frac{[x+1]}{2-2x} & \text{ise } -1 \leq x < 0 \\ \frac{5x+1}{2x+2} & \text{ise } 0 \leq x < 1/3 \\ \frac{[3-x]}{2x+2} & \text{ise } 1/3 \leq x < 3 \\ 0 & \text{ise } x < -1 \text{ ve } x \geq 3 \end{cases} \quad (3.53)$$




Şekil 3.3: Bulanık Sayılarda Toplama İşlemi Gösterimi (Klir ve Yuan, 1995).



Şekil 3.4: Bulanık Sayılarda Çıkarma İşlemi Gösterimi (Klir ve Yuan, 1995).



Şekil 3.5: Bulanık Sayılarda Çarpma İşlemi Gösterimi (Klir ve Yuan, 1995).



Şekil 3.6: Bulanık Sayılarda Bölme İşlemi Gösterimi (Klir ve Yuan, 1995).


Bulanık aritmetik hesaplamalarında genişletme ilkesinin kullanımı her zaman kolay olmayabilir. Bu nedenle bulanık sayılar biçimsel olarak bir düzenlemeye tabi tutulmuş ve geliştirilmiştir (Panik 2009). Dubois ve Prade (1980) simetrik ve simetrik olmayan üçgensel bulanık sayılar ile yamuk bulanık sayıları uygulama kolaylığı sağlamak üzere önermişlerdir. Dubois ve Prade (1978), Dubois ve Prade (1979) ve Dubois ve Prade (1980) tarafından yapılan çalışmalarda, $L - R$ formunda tanımlanan özel türde bulanık sayıların gösterimi ve cebirsel işlemlerine ilişkin tanımlamalar ayrıntılı bir biçimde sunulmuştur. $L - R$ formunda bulanık sayıların oluşturulmasındaki ana fikir, bulanık sayının merkez değerini sağ ve sol olmak üzere iki eğriye bölmektir (Hanss, 2005).

Bulanık sayıların referans fonksiyonu genellikle L veya R ile ifade edilmektedir. M bulanık sayısının $L - R$ formunda üyelik fonksiyonuna ilişkin gösterimi Eşitlik 3.54'deki gibi ifade edilmektedir.

$$\mu_M(x) = \begin{cases} L\left(\frac{m-x}{\alpha}\right), \alpha > 0, x \leq m; \\ R\left(\frac{x-m}{\beta}\right), \beta > 0, x \geq m. \end{cases} \quad (3.54)$$

Burada L fonksiyonu sol referansı temsil etmektedir. Bunu sağlayan durumlar; $L(x) = L(-x)$; $L(0) = 1$ ve L fonksiyonu $[0, +\infty)$ arasında monoton artan olarak özetlenmektedir. “ m ”, M bulanık sayısının ortalaması; α ve β ise sırasıyla sol ve sağ yayılımı temsil etmektedir. Yayılımlar sıfır olduğunda M geleneksel bulanık olmayan gerçel veya kesin bir sayı haline gelecektir. Yayılımlarda bir artış gözlemlendiğinde M 'nin daha da bulanık hale geldiği görülecektir. M bulanık sayısının matematiksel gösterimi Eşitlik 3.55’de verilmiştir. M bulanık sayısına ilişkin görünüm Şekil 3.7’de yer almaktadır.

$$M = (m, \alpha, \beta)_{LR} \quad (3.55)$$



Şekil 3.7: M Bulanık Sayısına İlişkin Gösterim (Panik, 2009).

R fonksiyonu sağ referansı temsil etmektedir. Bunu sağlayan durumlar; $R(x) = R(-x)$, $R(0) = 1$, $[0, +\infty)$ arasında monoton azalandır. $L - R$ bulanık sayılarına ilişkin gerçekleştirilecek aritmetik işlemler, sayıların ortalaması, sağ ve sol yayılımları üzerinden ifade edilmektedir. Dubois ve Prade (1980) tarafından yapılan çalışmada görüleceği üzere, $M = (m, \alpha, \beta)_{LR}$ ve $N = (n, \gamma, \delta)_{LR}$ olmak üzere iki bulanık sayı $L - R$ formunda tanımlanmış olsun. x ve y gerçel sayılar olmak üzere Eşitlik 3.56’de yer alan ifadeyi sağlamaktadır.

$$L\left(\frac{m-x}{\alpha}\right) = \omega = L\left(\frac{n-y}{\gamma}\right) \quad (3.56)$$

ω ise $[0, 1]$ aralığında sabit bir sayı olmak üzere x ve y değerleri Eşitlik 3.57’de; x ve y değerlerinin toplamı (z) Eşitlik 3.58’deki gibi ifade edilmektedir.

$$x = m - \alpha L^{-1}(\omega) \quad (3.57)$$

$$y = n - \gamma L^{-1}(\omega)$$

x ve y değerleri toplamı;

$$z = x + y = m + n - (\alpha + \gamma)L^{-1}(\omega) \quad (3.58)$$

Bahsi geçen bulanık sayıların üyelik değeri Eşitlik 3.59'deki gibi ifade edilmektedir.

$$\begin{aligned} L\left(\frac{m+n-z}{\alpha+\gamma}\right) &= \omega \\ R\left(\frac{z-(m+n)}{\beta+\delta}\right) &= \omega \end{aligned} \quad (3.59)$$

Böylece M ve N bulanık sayılarının toplamı Eşitlik 3.60'daki gibi ifade edilir.

$$M + N = (m, \alpha, \beta)_{LR} + (n, \gamma, \delta)_{LR} = (m + n, \alpha + \gamma, \beta + \delta)_{LR} \quad (3.60)$$

M ve N bulanık sayılarına ilişkin çıkarma işlemi Eşitlik 3.61'da verilmiştir.

$$M - N = ((m, \alpha, \beta)_{LR} - (n, \gamma, \delta)_{RL}) = (m - n, \alpha + \delta, \beta + \gamma)_{LR} \quad (3.61)$$

Burada bir bulanık sayının tersi Eşitlik 3.62'deki gibi ifade edilmektedir.

$$-(m, \alpha, \beta)_{LR} = (-m, \beta, \alpha)_{RL} \quad (3.62)$$

Çarpma işlemi Eşitlik 3.63'de yer alan ifade ile elde edilmektedir.

$$z = x * y = m * n - (m\gamma + n\alpha)L^{-1}(\omega) + \alpha\gamma(L^{-1}(\omega))^2 \quad (3.63)$$

Eşitlik 3.63'de yer alan ifade kullanılarak yapılan işlem sonucunda M ve N bulanık sayılarının çarpımlarının, $L - R$ formlu bir bulanık sayı olmadığı görülmektedir. M ve N bulanık sayılarına ilişkin çarpma ve bölme işlemleri, toplama ve çıkarma işleminde olduğu gibi kapalı biçimde ifade edilmemektedir (Başaran 2007). Ayrıca α ve γ ile m ve n arasındaki düşük seviyede ilişki olduğunda M ve N bulanık sayılarının çarpımı Eşitlik 3.64'deki gibi ifade edilmektedir.

$$(M, N > 0), (m, \alpha, \beta)_{LR} \times (n, \gamma, \delta)_{LR} \simeq (mn, m\gamma + n\alpha, m\delta + n\beta)_{LR} \quad (3.64)$$

$$(M < 0, N > 0), (m, \alpha, \beta)_{RL} \times (n, \gamma, \delta)_{LR} \simeq (mn, n\alpha - m\delta, n\beta + m\gamma)_{RL}$$

$$(M < 0, N < 0), (m, \alpha, \beta)_{LR} \times (n, \gamma, \delta)_{LR} \simeq (mn, -n\beta - m\delta, -n\alpha - m\gamma)_{RL}$$

M ve N bulanık sayılarının bölme işlemine ilişkin gösterim, M ve N bulanık sayılarının pozitif olduğu durumlar için Eşitlik 3.65'de verilmiştir. M ve N bulanık sayılarının birinin veya her ikisinin de negatif sayı olduğu durumlarda da benzer formülasyon kullanılabilir (Dubois ve Prade, 1980).

$$(M > 0, N > 0) (m, \alpha, \beta)_{LR} \div (n, \gamma, \delta)_{RL} \simeq \left(\frac{m}{n}, \frac{\delta m + \alpha n}{n^2}, \frac{m\gamma + \beta n}{n^2}\right)_{LR} \quad (3.65)$$

λ , skaler sayı ve $M, L - R$ formunda bir bulanık sayı olmak üzere skaler çarpıma ilişkin ifade Eşitlik 3.66'de yer almaktadır.

$$\forall \lambda > 0, \lambda \in \mathbb{R}, \lambda * (m, \alpha, \beta)_{LR} = (\lambda m, \lambda \alpha, \lambda \beta)_{LR} \quad (3.66)$$

$$\forall \lambda < 0, \lambda \in \mathbb{R}, \lambda * (m, \alpha, \beta)_{LR} = (\lambda m, -\lambda \beta, -\lambda \alpha)_{RL}$$


M pozitif $L - R$ formulu bir bulanık sayı ($M = (m, \alpha, \beta)$) ve

$$\mu_{M^{-1}}(x) = \mu_M\left(\frac{1}{x}\right) \forall x \neq 0, \forall M \in \tilde{\mathcal{P}}(\mathbb{R} - \{0\})$$

olmak üzere bulanık sayının tersi Eşitlik 3.67'deki gibi ifade edilir.

$$\mu_{M^{-1}}(x) = L\left(\frac{1-mx}{\alpha x}\right), x \geq 1/m \quad (3.67)$$

Simetrik ve simetrik olmayan üçgensel bulanık sayıların şekilsel gösterimi Şekil 3.8'de yer almaktadır (Panik, 2009). Şekil 3.8(a)'da simetrik olmayan M bulanık üçgensel sayısı $M = (m, \alpha, \beta)$ olarak ifade edilmektedir. m , bulanık sayının merkezini; α , sol yayılım ve β sağ yayılım değerini temsil etmektedir. Şekil 3.8(b)'de simetrik üçgensel M bulanık sayısı görülmektedir. Burada m bulanık sayının merkezini ($m + c$) sol yayılım değeri ve ($m - c$) ise sağ yayılım değerini temsil etmektedir. Simetrik üçgensel bulanık sayı $M = (m, c)$ olarak ifade edilmektedir.



Şekil 3.8: Simetrik olmayan (a) ve simetrik (b) üçgensel bulanık sayı.

M üçgensel bulanık sayısının üyelik fonksiyonu Eşitlik 3.68'de yer almaktadır. Burada L ve R , x 'in doğrusal fonksiyonu olarak varsayılmaktadır.

$$\mu_M(x) = \begin{cases} \frac{x-\alpha}{m-\alpha}, & \alpha \leq x \leq m; \\ \frac{x-\beta}{m-\beta}, & m < x \leq \beta; \\ 0, & x < \alpha \text{ veya } x > \beta \end{cases} \quad (3.68)$$

Simetrik üçgensel bulanık sayının üyelik fonksiyonu Eşitlik 3.69'deki gibi ifade edilmektedir (Panik, 2009).

$$\mu_M(x) = \begin{cases} \frac{x-(m-c)}{m-(m-c)}, & m-c \leq x \leq m \\ \frac{x-(m+c)}{m-(m+c)}, & m < x \leq m+c \\ 0, & \text{diğer} \end{cases}$$

$$\mu_M(x) = \begin{cases} 1 - \frac{(m-x)}{c}, & m-x > 0 \\ 1 - \frac{(x-m)}{c}, & m-x < 0 \\ 0, & \text{diğer} \end{cases} \quad (3.69)$$

$$\mu_M(x) = \begin{cases} 1 - \frac{|x-m|}{c}, & m-c \leq x \leq m+c \\ 0, & \text{diğer} \end{cases}$$

Simetrik üçgensel bulanık sayının üyelik fonksiyonuna ilişkin bir başka ifade Eşitlik 3.70'da yer almaktadır.

$$\mu_M(x) = L\left(\frac{(x-m)}{c}\right), c > 0 \quad (3.70)$$

3.5. Bulanık Regresyon Analizi

3.5.1. Bulanık Doğrusal Regresyon Analizi

Gerçek yaşamda karşılaşılan problem yapıları insanların düşünce yapısına benzer şekilde bulanık karakterlidir ve belirsizlik içermektedir. Bulanık regresyon analizi, bağımlı ve bağımsız değişkenler arası ilişkilerin belirsizlik niteliği taşıdığı durumlarda birçok araştırmacı tarafından kullanılmaktadır. Böylece bağımsız değişkenlerin etkileri gerçeğe daha uygun şekilde ortaya koyulabilmekte ve yorumlanabilmektedir. Bulanık regresyon analizi bazı durumlarda klasik regresyon analizinden daha iyi performans gösterebilmektedir. Bu durumlar şu şekilde özetlenebilmektedir: Veri setinin istatistiksel regresyon analizini desteklemek için yeterli olmadığı bir başka ifade ile değişkenler arasında geçerli bir istatistiksel ilişki kurmak için yeterli sayıda verinin mevcut olmadığı


durumlarda (Bardossy ve diğ. 1990; Bardossy ve diğ. 1993; Kim ve diğ. 1996), istatistiksel dağılım varsayımları sağlanamadığında (Tanaka ve diğ. 1982; Tanaka 1987), regresyon modeli verileri yeterli derecede temsil etmiyorsa (Kim ve diğ. 1996), insani yargılar söz konusu ise (girdi ve / veya çıktılar bulanık sayı olarak analize dahil edilmesi gerekiyorsa) ve hatalar model yapısının belirsizliği ile ilişkiliyse (istatistiksel durumun aksine hatalar gözlemlerle ilişkilendirilir) bulanık regresyon uygun ve alternatif bir yaklaşım sağlayabilmektedir (Özelkan ve Duckstein, 2000). Ayrıca kesin sayısal verilere ulaşamadığı bir başka ifade ile sözel ifadelerin insani yargıların bulanık sayı olarak ifade edildiği durumlarda da bulanık regresyon analizi tercih sebebi olarak görülmektedir (D'urso ve Gastaldi, 2000).

Klasik regresyon analizinde gözlemlenen ve tahminlenen değerler arasındaki farklılığın gözlemsel hatalardan veya modelin yanlış seçiminden kaynaklandığı varsayılır. Bulanık regresyonda ise gözlenen ve tahminlenen değerler arasındaki farklılığın sistem yapısında doğal olarak bulunan belirsizlikten kaynaklı olduğu kabul edilir. Sistem yapısında belirlenmiş girdiler için tanımlanan çıktı değişkeninin belirlenen aralıkta olası bir değeri vardır ve bu aralıkta herhangi bir değeri alabilmektedir. Bulanık regresyon analizinde model yapısında var olan bulanık katsayıları ifade etmek üzere bulanık fonksiyonlar kullanılmaktadır (Tanaka ve diğ. 1982; Ross, 2004). Bulanık doğrusal regresyon analizi Eşitlik 3.71'deki gibi ifade edilmektedir.

$$\tilde{Y}_i = \tilde{A}_0 + \tilde{A}_1 X_1 + \dots + \tilde{A}_p X_{ip} \quad (3.71)$$

Bulanık doğrusal regresyon modeline ait eşitlikte \tilde{A}_j parametresi bulanık sayı ile ifade edilmekte olup j 'inci bulanık katsayıyı temsil etmektedir. Üyelik fonksiyonları olası değer aralığına ilişkin tahminlerin oluşturulmasında önemli rol oynamaktadır. Üyelik fonksiyonu, nesnelere belirli üyelik veya aitlik değeri atanarak oluşturulmaktadır (Ross 2004). $c_j > 0$ olmak üzere \tilde{A}_j parametresi $\tilde{A}_j = (\alpha_j, c_j)$, $j = 1, \dots, p$, $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_p)$ ve $c = (c_0, c_1, \dots, c_p)$ olarak ifade edilmektedir. Böylece Eşitlik 3.71'de yer alan ifade daha ayrıntılı bir şekilde Eşitlik 3.72'deki gibi yazılabilmektedir.

$$\tilde{Y}_i = (a_0, c_0) + (a_1, c_1)X_1 + \dots + (a_p, c_p)X_{ip} \quad (3.72)$$



Şekil 3.9: \tilde{A}_j Bulanık Katsayısının Üyelik Fonksiyonu (Ross, 2004).


Şekil 3.9'da \tilde{A}_j bulanık katsayısının üçgensel üyelik fonksiyonu yer almaktadır. Şekil 3.9'da görüleceği üzere \tilde{A}_j parametresi merkezi α_j ve yayılımı c_j olan bir bulanık sayı olarak tanımlanmaktadır. Burada merkez değeri $\alpha = (\alpha_0, \alpha_1, \dots, \alpha_p)$ ve fonksiyonun bulanıklığını temsil eden yayılım $c = (c_0, c_1, \dots, c_p)$ olarak ifade edilmektedir. Bağımsız değişkenlerin katsayıları için tanımlanan μ_{A_j} üyelik fonksiyonu Eşitlik 3.73'deki gibi yer almaktadır (Tanaka 1982; Tanaka ve diğ. 1989; Şanlı 2005).

$$\mu_{A_j}(a_j) = \begin{cases} 1 - \frac{|\alpha_j - a_j|}{c_j}, & \alpha_j - c_j < a_j < \alpha_j + c_j \\ 0, & \text{diğer} \end{cases} \quad (3.73)$$

Zadeh (1975) tarafından tanımlanan genişletme ilkesi yardımıyla $c_j > 0$, $\tilde{A}_j = (\alpha_j, c_j)$, $j = 1, \dots, p$ olmak üzere \tilde{Y}_j bulanık sayısının üyelik fonksiyonu Eşitlik 3.74'deki gibi tanımlanmaktadır (Tanaka 1982; Wang ve Tsaur 2000b).

$$\mu_{Y_j}(y) = \begin{cases} 1 - \frac{|y_j - \sum_{j=1}^p \alpha_j x_j|}{\sum_{j=1}^p c_j |x_j|}, & x \neq 0 \\ 1, & x = 0, y = 0 \\ 0, & x = 0, y \neq 0 \end{cases} \quad (3.74)$$

Burada y_j , j 'inci gözlem için çıktı değerini; x ise girdi değişkenini temsil etmektedir.



Şekil 3.10: Bulanık Çıktı Gösterimi (Ross, 2004).

Şekil 3.10'da bulanık regresyon modelinde yer alan bulanık çıktının bileşenleri yer almaktadır. Gözlemlenen bulanık çıktı için üyelik fonksiyonu Tanaka (1982) tarafından

Eşitlik 3.75'deki gibi tanımlanmıştır. Burada $Y_j = (y_j, e_j)$ bulanık sayısı, y_j merkez değeri ve e_j çıktının bulanıklığını veya genişliğini ifade etmek üzere tanımlanmaktadır.

$$\mu_{Y_j}(y) = 1 - \frac{|y_j - y|}{e_j} \quad (3.75)$$

3.5.1.1. Bulanık doğrusal regresyon analizi ve “ h ” değeri

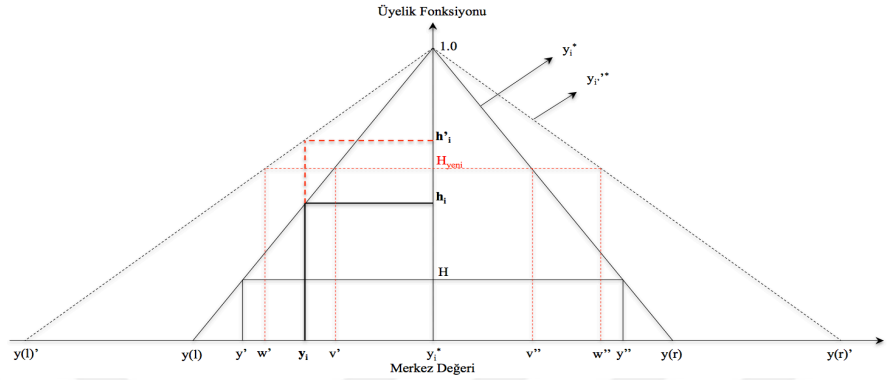
h değeri bulanık doğrusal regresyon analizinde tahmin edilen bulanık çıktıların, bağımlı değişkenin gözlemlenen değerlerine göre uyum derecesini bir başka ifade ile istenilen güvenilirlik seviyesini ifade etmektedir (Ross, 2004). Bu kavramın klasik regresyon analizinde bulunan uyum iyiliği gibi düşünülmemesi gerekir. h değeri, bulanık doğrusal regresyon analizinde bulanık parametrelerin bulanık dağılımlarının genişlik ya da darlığının elde edilmesinde oldukça önemli rol oynamaktadır. Bulanık doğrusal regresyon analizinde modelde yer alan parametrelerin her biri bir bulanıklık seviyesine sahiptir. Hatalar tek bir terim yerine tüm model katsayılarına dağıtılmıştır. h değeri bulanıklığı azaltmak ve örneklem üzerindeki şüpheleri en baştan belirlemek için kullanılır (Moskowitz ve Kim, 1993; İçen 2010). h değeri analize başlamadan önce araştırmacı tarafından belirlenmektedir. $[0, 1]$ aralığında belirlenen bu değer modele bir girdi parametresi olarak dahil edilir (Tanaka ve diğ. 1982; Moskowitz ve Kim, 1993).

Literatürde bir çok araştırmacı tarafından h değerinin ne olması gerektiğine ilişkin çeşitli çalışmalar yürütmüştür. Tanaka ve Watada (1988) veri setinin büyüklüğü doğrultusunda h değerinin farklı seçimlerine ilişkin öneride bulunmuşlardır. Veri seti yeterli büyüklükte olduğu takdirde h değerinin “0.0”; ideal seviyeden uzak olması halinde ise h değerine daha büyük değerlerin verilmesi gerektiğini belirtmişlerdir. Bardossy ve diğ. (1990) h değerinin “0.0- 0.7” aralığında belirlenmesi hususunda öneride bulunmuşlardır. Tanaka (1987), Hayashi ve Tanaka (1990), Suzuki ve diğ. (1990) çalışmalarında h değerini “0.0”; Tanaka ve Watada (1988) “0.2”; Tanaka ve diğ. (1982), Heshmaty ve Kandel (1985) “0.5”; Bardossy, ve diğ. (1987), Bardossy ve diğ. (1990) “0.7”; Bardossy (1990) “0.75”; Oh ve diğ. (1990) “0.9” değerli olarak kabul etmişlerdir.

Liu ve Chen (2013), çalışmalarında simetrik üçgensel bulanık sayılarla minimum bulanıklık kriterini kullanarak optimize edilmiş h değerleri için bulanık regresyon analizini gerçekleştirmek üzere bir yaklaşım önermişlerdir. Ayrıca literatürde farklı seviyelerde h değerlerinin tahmin başarısını yükseltmesi amacıyla kullanıldığı bulanık regresyon analizi

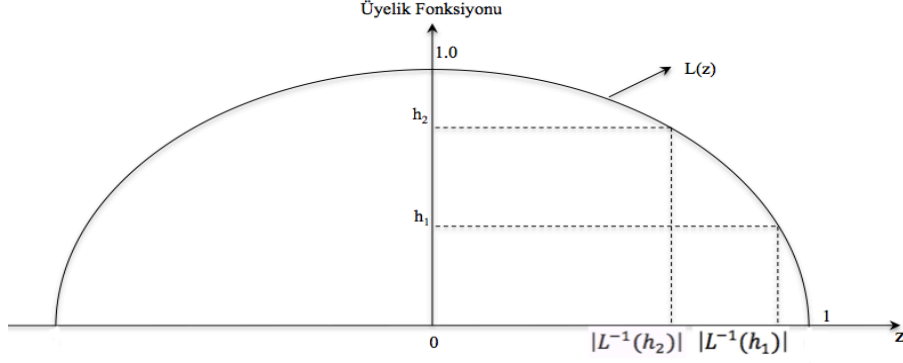
çalışmaları da mevcuttur (Liu ve Chen, 2013; Lin ve Pai, 2010; Chen ve diğ. 2015).

Moskowitz ve Kim (1993) yaptıkları çalışmada h değeri ile bulanık doğrusal regresyon analizinde yer alan bulanık parametrelerin yayılımı ve üyelik fonksiyonlarının şekli arasındaki ilişkiyi belirlemeyi amaçlamıştır.



Şekil 3.11: h Değeri İncelemesi (Moskowitz ve Kim, 1993).

Farklı h değerlerinin bulanık doğrusal regresyon modeli üzerine etkisi, Şekil 3.11'de yer alan iki adet simetrik üçgensel bulanık sayı yardımıyla anlatılacaktır. Şekilde yer alan y_i^* ve $y_i'^*$ bulanık sayıları tahminlenen parametreleri ifade etmektedir. İki sayının da merkez değeri y_i^* şeklindedir. y_i^* bulanık sayısının sol sınır noktası $y_{(l)}$ ve sağ sınır noktası $y_{(r)}$ şeklindedir. Şekil 3.11'de görüleceği üzere y_i gözlem değeri hem y_i^* hem de $y_i'^*$ bulanık sayısının destek bölgesinde konumlanmıştır. y_i^* bulanık sayısının h değeri $[y', y'']$ olarak belirlenmiştir. Burada h değerinde bir artış söz konusudur. y_i^* ve y_i sabit kalmak üzere böyle bir durumda y_i^* bulanık sayısının destek bölgesi $[y_{(l)}, y_{(r)}]$ yerine $[y'_{(l)}, y'_{(r)}]$ olarak belirlenecektir. Dolayısı ile yayılım değerinde de bir artış gözlenmektedir. Ayrıca y_i 'nin üyelik değeri ilk durumda h_i olmasına karşın, yayılım değeri arttığından dolayı yeni üyelik değeri h_i' olarak belirlenmiştir. h değerini olduğundan daha yüksek bir değere çıkarabilmek için merkez değerini sabit tutmak şartıyla yayılımların artırılması gerekmektedir (Moskowitz ve Kim, 1993; Başaran 2007). Yayılımların büyüklüğü ve h değeri arasındaki bu denge bulanık doğrusal regresyon analizi için çok önemlidir. Ayrıca h değerinin büyüklüğü, bulanık doğrusal regresyon analizinin bağımlı değişken için belirlediği tahmin aralığının genişliğini ve darlığını doğrudan etkilemektedir. Literatürde h değerinin ne olması gerektiğine ilişkin açık bir formülizasyon bulunmamaktadır. h değeri bulanık doğrusal regresyon modelinin güvenilirlik seviyesini ifade etmektedir.



Şekil 3.12: Farklı h Değerleri için $|L^{-1}(h)|$ Değişimleri (Moskowitz ve Kim, 1993).

$A^* = (a^*, c^*)$ tahmin edilen bulanık parametre ve L üyelik fonksiyonu altında bulanık tahmin modeli $y^* = A^*X_i$ olmak üzere, Moskowitz ve Kim, 1993 tarafından yapılan çalışmada h seviyesindeki artışın bulanık parametrelerin yayılım değerlerini daralttığı ortaya konulmuştur. Bir başka ifade ile $|L^{-1}(h)|$ değerinde oluşacak azalma doğrusal programlama probleminin sınırlarını daraltmaktadır. Tanaka ve Watada, 1988'de $|L^{-1}(h)| = 1 - h$ olarak verilmiştir. Şekil 3.12'de h değerinin h_1 ve h_2 seviyelerine karşılık üyelik fonksiyonu değerlerindeki değişim görülmektedir. Burada L , standartlaştırılmış z parametresinin üyelik fonksiyonunu temsil etmek üzere h_1 güvenilirlik seviyesinde optimum çözüm Eşitlik 3.76'de yer almaktadır.

$$A^*_{h_1,L} = (a^*, c^*) \quad (3.76)$$

L üyelik fonksiyonu, bulanık tahminin merkezi (y_i^*) ve gözlem değeri arasındaki uzaklığın bulanık tahminin yayılım değerine bölünmesi ile elde edilmektedir. $|L^{-1}(h)|$ h 'nin üyelik değeri olan z 'yi temsil etmektedir. $h_2 > h_1$ olduğundan dolayı $|L^{-1}(h_2)| < |L^{-1}(h_1)|$ olmaktadır. Küçük $|L^{-1}(h)|$ değeri Tanaka ve diğ. (1982) tarafından sunulan doğrusal programlama probleminde daha dar bir tahmin aralığı sağlar ve minimizasyon probleminin amaç fonksiyonu değerinde de artış elde edilir.

L üyelik fonksiyonu ve h_2 güvenilirlik seviyesinde optimum çözüm Eşitlik 3.77'de yer almaktadır.

$$A^*_{h_2,L} = (a^*, \frac{|L^{-1}(h_1)|}{|L^{-1}(h_2)|} c^*) \quad (3.77)$$

Tanaka ve Watada (1988) tarafından yapılan çalışmada Eşitlik 3.76 ve 3.77'de yer alan ifadeler bir teorem olarak sunulmuş ve ispatları ile birlikte ayrıntılarıyla incelenmiştir (Tanaka ve Watada, 1988; Moskowitz ve Kim, 1993).

3.5.1.2. Bulanık Doğrusal Regresyon Analizinde Parametre Tahmin Yöntemleri

Çalışmanın bu bölümünde bulanık doğrusal regresyon analizine ilişkin parametre tahmin yöntemleri incelenecektir. Bu kapsamda matematiksel programlamaya dayalı parametre tahmin yöntemleri ile en küçük kareler yöntemine dayalı parametre tahmin yöntemlerine ait bilgiler sunulacaktır.

Matematiksel Programlamaya Dayalı Parametre Tahmini

Bulanık doğrusal regresyon analizinde değişkenler bulanık veya gerçel sayı formunda olabilirler. Ancak parametreler her zaman bulanık olmaktadır. Literatürde bağımlı değişkenin bulanık, bağımsız değişkenlerin gerçel sayı olduğu bulanık doğrusal regresyon modeli ilk olarak Tanaka ve diğ. (1982) tarafından ortaya konmuştur. Tanaka ve diğ. (1982) tarafından geliştirilen bu modelde amaç belirli bir h değerinde, yayılımları minimize ederek bulanık parametrelerin tahmin değerlerini elde etmektir. Lotfi A. Zadeh'in genişletme ilkesinden yola çıkarak ürettikleri bu çalışmada sapmaların klasik regresyon analizinde olduğu gibi bağımlı değişkene ilişkin tahmin ve gözlem değerleri arasındaki farklılıktan değil sistem yapısında bulunan belirsizlikten kaynaklı olduğunu bildirmişlerdir (Tanaka ve diğ. 1982). Tanaka ve diğ. (1982) tarafından ortaya koyulan bu yöntem bulanık doğrusal regresyon çözümlemesinde “doğrusal programlamaya dayanan bulanık regresyon modeli” veya “Tanaka modeli” olarak adlandırılmaktadır.

X ve Y kümeleri için $f(x, \alpha)$ fonksiyonunun X kümesinden Y kümesine tanımlanmış olduğu varsayılınsın. Parametreler A bulanık kümesi tarafından ifade edilen fonksiyon $f(x, A)$ olarak ifade edilmek üzere bulanık fonksiyon haline gelecektir. Bulanık fonksiyonun matematiksel gösterimi Eşitlik 3.78'de yer almaktadır.

$$f: X \rightarrow \mathcal{F}(y); Y = f(x, A)$$

$$f: X \rightarrow Y \subset \mathcal{F}(y); f(x; A_0, A_1) \quad (3.78)$$

$\mathcal{F}(y)$, Y 'deki tüm bulanık alt kümeleri temsil etmektedir. x kesin bir sayı olmaktadır. Y bulanık kümesini tanımlayan üyelik fonksiyonu Eşitlik 3.79'de yer almaktadır.

$$\mu_Y(y) = \begin{cases} \max_{\{\alpha \mid y = f(x, \alpha)\}} \mu_A(\alpha), & \{\alpha \mid y = f(x, \alpha)\} \neq \emptyset \\ 0 & \text{diğer} \end{cases} \quad (3.79)$$

A , parametrelerin çarpım uzayında bir bulanık küme olarak tanımlanmaktadır. A 'nın üyelik fonksiyonu Eşitlik 3.80 ve Eşitlik 3.81'de görüleceği üzere $\mu_A(\alpha)$ olarak ifade edilmektedir. A parametresi simetrik bulanık üçgensel sayılarla ($A_j = (\alpha_j, c_j)$) ifade edilmektedir.

$$\mu_A(\alpha) = \min_j [\mu_{A_j}(\alpha_j)] \quad (3.80)$$

$$\mu_{A_j}(\alpha_j) = \begin{cases} 1 - \frac{|\alpha_j - a_j|}{c_j}, & \alpha_j - c_j < \alpha_j < \alpha_j + c_j \\ 0, & \text{diğer} \end{cases} \quad (3.81)$$

$c_j > 0$ olmak üzere α bulanık parametresinin merkezini, c ise yayılımını temsil etmektedir. $\tilde{A}_j = (\alpha_j, c_j)$, $j = 1, \dots, p$ olmak üzere \tilde{Y}_j bulanık sayısının üyelik fonksiyonu Eşitlik 3.82'deki gibi tanımlanmaktadır (Tanaka 1982; Wang ve Tsaur 2000a).

$$\mu_{Y_j}(y) = \begin{cases} 1 - \frac{|y_j - \sum_{j=1}^p \alpha_j x_j|}{\sum_{j=1}^p c_j |x_j|}, & x \neq 0 \\ 1, & x = 0, y = 0 \\ 0, & x = 0, y \neq 0 \end{cases} \quad (3.82)$$

Bulanık doğrusal regresyonda, modelin bulanık çıktısı (Y_j) bağımlı değişkenin tüm gözlem değerlerini (y_j) $[0, 1]$ aralığında yer alan kesin bir h değerinde kapsamalıdır. Bu durum bir kısıt olarak nitelendirilir. Kısıtın matematiksel ifadesi Eşitlik 3.83'deki gibidir.

$$(Y_j)_{h_i} = \{y_j | \mu_{Y_j}(y_j) \geq h_j\} \quad j = 1, \dots, p \quad (3.83)$$

$$\mu_{Y_j}(y_j) = 1 - \frac{|y_j - \sum_{j=1}^p \alpha_j x_j|}{\sum_{j=1}^p c_j |x_j|} \geq h_j$$

Bulanık doğrusal regresyon modeline ait bulanıklık derecesi $J = c_1 + \dots + c_p$ amaç fonksiyonu ile ifade edilir. Burada bulanıklık derecesi bulanık parametrelerin yayılımları toplamına eşit olmaktadır.

Eşitlik 3.83'de yer alan kısıtlar koşullu eşitsizlik olarak belirtilir. Bu kısıttan yola çıkarak Eşitlik 3.84'de yer alan eşitsizlik çifti her veri noktası için (x_i, y_i) üretilmiştir. Burada bağımlı değişken kesin sayı olarak modelde bulunmaktadır.

$$(1 - h)(\sum_{j=1}^p c_j |x_j|) + \sum_{j=1}^p \alpha_j x_j \geq y_i \quad (3.84)$$

$$(h - 1)(\sum_{j=1}^p c_j |x_j|) + \sum_{j=1}^p \alpha_j x_j \leq y_i$$

$$c_j \geq 0, \alpha \in \mathfrak{R}, x_{i_0} = 1, (0 \leq h \leq 1; j = 1, 2, \dots, p)$$

Eşitlik 3.84’de yer alan kısıtlar yardımıyla, Eşitlik 3.71’de verilen modelin parametrelerini tahmin etmek üzere doğrusal programlama çözümünden yararlanılmıştır. Eşitlik 3.85’de yer alan kısıtı sağlamak üzere, Eşitlik 3.86’de bağımlı değişkenin bulanık olduğu durumda çözümlenecek doğrusal programlama modeli yer almaktadır.

$$\text{Min } c^t |X| = \text{Min } \sum_{j=1}^p c_j \sum_{i=1}^m |x_{ij}| \text{ veya } \min_{\alpha_j, c_j} J = c_1 + \dots + c_p \quad (3.85)$$

$$c_j \geq 0$$

$$\sum_{j=1}^p \alpha_j x_{ij} + (1 - h) \sum_{j=1}^p c_j |x_{ij}| \geq y_i + (1 - h)e_i \quad (3.86)$$

$$\sum_{j=1}^p \alpha_j x_{ij} - (1 - h) \sum_{j=1}^p c_j |x_{ij}| \leq y_i - (1 - h)e_i$$

$$c_j \geq 0, \alpha \in \mathfrak{R}, x_{i_0} = 1 (0 \leq h \leq 1; j = 1, 2, \dots, p)$$

Eşitlik 3.87’de bağımlı değişkenin kesin sayı olduğu durumda çözümlenecek doğrusal programlama modeli yer almaktadır.

$$\text{Min } c^t |X| = \text{Min } \sum_{j=0}^p c_j \sum_{i=1}^m |x_{ij}| \text{ kısıtı altında} \quad (3.87)$$

$$\sum_{j=1}^p \alpha_j x_{ij} + (1 - h) \sum_{j=1}^p c_j |x_{ij}| \geq y_i$$

$$\sum_{j=1}^p \alpha_j x_{ij} - (1 - h) \sum_{j=1}^p c_j |x_{ij}| \leq y_i$$

$$c_j \geq 0, \alpha \in \mathfrak{R}, x_{i_0} = 1 (0 \leq h \leq 1; j = 1, 2, \dots, p)$$

Eşitlik 3.86 ve 3.87’de yer alan doğrusal programlama modelleri çözümlenerek bulanık parametrelere ilişkin tahminler elde edilmektedir. Burada amaç fonksiyonu minimize edilmektedir. Tanaka ve diğ. (1982) tarafından geliştirilen bu yöntem uç değerlere karşı çok hassas olduğundan literatürde bu yaklaşıma alternatif çalışmalar ortaya çıkmıştır (Diamond 1988; Savic ve Pedrycz, 1991; Sakawa ve Yano 1992; Peters 1994; Diamond ve Tanaka 1998; Wang ve Tsaur 2000a).

Savic ve Pedrycz (1991) tarafından yapılan çalışmada minimum bulanıklık kriterini geliştirerek doğrusal regresyon analizini iki aşamada inceleyen model önerilmiştir. Araştırmacılar minimum bulanıklık kriterini temel alan bulanık regresyon analizini geliştirmeyi amaçlamışlardır. Buna göre ilk aşamada gerçel sayı olan gözlem değerleri kullanılarak klasik doğrusal regresyon analizi prosedürü uygulanmıştır. En küçük kareler yöntemi kullanılarak katsayıların merkez değerleri hesaplanmıştır. İkinci aşamada ise amaç fonksiyonunu minimize etmek üzere birinci aşamada elde edilen merkez değerleri doğrusal programlama probleminde girdi verisi olarak tanımlanır. Doğrusal programlama problemi çözümlendiğinde yayılım değerleri hesaplanmış olur. Toplam yayılımları minimize etmek üzere Savic ve Pedrycz (1991) tarafından önerilen doğrusal programlama problemi Eşitlik 3.88'de yer almaktadır. Burada c bilinmeyen değişken vektörleridir. Tanaka modelinden farklılığı merkez değerlerinin yöntemin birinci aşamasında belirleniyor olması ve doğrusal programlama problemi çözümünde bilinen bir vektör olarak kullanılmasıdır (Savic ve Pedrycz, 1991; Panik 2009).

$$(1 - h) \sum_{j=0}^m c_j |x_{ij}| + x_i^t \hat{\alpha} \geq y_i \quad (3.88)$$

$$(h - 1) \sum_{j=0}^m c_j |x_{ij}| + x_i^t \hat{\alpha} \geq y_i$$

$$c \geq 0, \min J = \sum_{j=0}^m c_j$$

Bulanık doğrusal regresyon analizinde matematiksel programlamaya dayanan bir diğer önemli araştırma Sakawa ve Yano (1992) tarafından yapılmıştır. Sakawa ve Yano (1992), girdi ve çıktıların bulanık sayı olduğu çok amaçlı bulanık regresyon analizinin çözümlenmesini gerçekleştirmek üzere üç farklı algoritma tanımlamışlardır. Bunlar yinelemeli, karar vericiyle etkileşime dayanan ve etkileşimli algoritma şeklindedir (Sakawa ve diğ. 2013). Sakawa ve Yano (1992) çalışmalarında bulanık doğrusal regresyon modelini Eşitlik 3.89'deki gibi sunmuşlardır.

$$\tilde{y}_i = \tilde{\alpha} \otimes \tilde{x}_i, \quad i = 1, \dots, k \quad (3.89)$$

Burada $\tilde{\alpha} = (\tilde{\alpha}_0, \tilde{\alpha}_1, \dots, \tilde{\alpha}_n)$ ve $\tilde{x}_i = (1, \tilde{x}_{i1}, \dots, \tilde{x}_{in})^t$ olmak üzere \tilde{y}_i , $\tilde{\alpha}$ ve \tilde{x}_i $L - L$ bulanık sayılarıdır. " \otimes " ise genişletme ilkesini temel alan çarpım işlemcisidir. \tilde{x}_i girdi verilerini, \tilde{y}_i çıktı verilerini, $\tilde{\alpha}$ bulanık parametreleri temsil etmektedir. Modelde yer alan bulanık sayıların üyelik fonksiyonları Eşitlik 3.90'da ifade edilmektedir.

$$\mu_{\tilde{x}_{ij}}(x_{ij}) = L\left(\frac{|\bar{x}_{ij}-x_{ij}|}{d_{ij}}\right), d_{ij} > 0$$

$$\mu_{\tilde{y}_i}(y_i) = L\left(\frac{|\bar{y}_i-y_i|}{e_i}\right), e_i > 0 \quad (3.90)$$

$$\mu_{\tilde{a}_j}(a_j) = L\left(\frac{|\bar{a}_j-a_j|}{c_j}\right), c_j > 0$$

Üyelik fonksiyonlarında tanımlanan $L(\cdot)$ referans fonksiyonunu; \bar{x}_{ij} , \bar{y}_i ve \bar{a}_j ortalama değeri; d_{ij} , e_i ve c_j ise yayılım değerlerini temsil etmektedir. \bar{x}_{ij} , \bar{y}_i ve \bar{a}_j $L-L$ bulanık sayılarının matematiksel gösterimi Eşitlik 3.91’de ifade edilmektedir.

$$\tilde{x}_i = (\bar{x}_{ij}, d_{ij})_L$$

$$\tilde{y}_i = (\bar{y}_i, e_i)_L \quad (3.91)$$

$$\tilde{a}_j = (\bar{a}_j, c_j)_L$$

Önerilen bulanık doğrusal regresyon modelinde h değerine ait küme $(0, 1]$ aralığında pozitif değerlerden oluşmaktadır. $\tilde{a} \otimes \tilde{x}_i$ ’nin üyelik fonksiyonu doğrudan elde edilemediğinden, $\tilde{a} \otimes \tilde{x}_i$ ’nin h değer kümesi Nguyen (1978) tarafından tanımlanan teorem aracılığı ile hesaplanmaktadır. Teoremde h değer kümesi Eşitlik 3.92’de yer alan matematiksel ifade ile tanımlanmaktadır.

$$(\tilde{a} \otimes \tilde{x}_i)_h = [Y_{ih}^L, Y_{ih}^R] \quad (3.92)$$

$$Y_{ih}^L = \sum_{j=0}^n \left\{ \min \left\{ (\bar{a}_j - L^{-1}(h)c_j)(\bar{x}_{ij} - L^{-1}(h)d_{ij}), (\bar{a}_{ij} - L^{-1}(h)c_j)(\bar{x}_{ij} + L^{-1}(h)d_{ij}) \right\} \right\} \quad (3.93)$$

$$Y_{ih}^R = \sum_{j=0}^n \left\{ \max \left\{ (\bar{a}_j + L^{-1}(h)c_j)(\bar{x}_{ij} + L^{-1}(h)d_{ij}), (\bar{a}_{ij} + L^{-1}(h)c_j)(\bar{x}_{ij} - L^{-1}(h)d_{ij}) \right\} \right\} \quad (3.94)$$

Eşitlik 3.93-3.94’de yer alan Y_{ih}^L ve Y_{ih}^R ‘da tanımlı minimum ve maksimum işlemcileri ile hesaplama yapmak amacıyla Eşitlik 3.95’deki ilişkilerin varsayımı kabul edilmiştir. Burada h sabit bir değerdir. Tanımlanan ilişkide $J = \{0, \dots, n\} = J_1 \cup J_2 \cup J_3, J_i \cap J_j = \emptyset, i(\neq j) = 1,2,3$ olarak ifade edilmektedir.

$$\bar{a}_j - L^{-1}(h)c_j \geq 0, j \in J_1$$

$$\bar{a}_j - L^{-1}(h)c_j \leq 0, \bar{a}_j + L^{-1}(h)c_j \geq 0, \quad j \in J_2 \quad (3.95)$$

$$\bar{a}_j + L^{-1}(h)c_j \geq 0, \quad j \in J_3$$

Eşitlik 3.95’de yer alan koşullar gerçek hayatta karşılaşılan durumlara karşı oldukça sınırlayıcı olduğunu belirten araştırmacılar Y_{ih}^L ve Y_{ih}^R ’nin Eşitlik 3.96 ve 3.97’deki gibi ifade edilebileceğini belirtmişlerdir.

$$Y_{ih}^L = \sum_{j \in J_1} (\bar{a}_j - L^{-1}(h)c_j) (\bar{x}_{ij} - L^{-1}(h)d_{ij}) + \sum_{j \in J_2 \cup J_3} (\bar{a}_j - L^{-1}(h)c_j) (\bar{x}_{ij} + L^{-1}(h)d_{ij}) \quad (3.96)$$

$$Y_{ih}^R = \sum_{j \in J_1 \cup J_2} (\bar{a}_j + L^{-1}(h)c_j) (\bar{x}_{ij} + L^{-1}(h)d_{ij}) + \sum_{j \in J_2 \cup J_3} (\bar{a}_j + L^{-1}(h)c_j) (\bar{x}_{ij} - L^{-1}(h)d_{ij}) \quad (3.97)$$

İncelenen bulanık eşitlikler ile işlem yapabilmek adına Dubois ve Prade (1983) ve Dubois ve Prade (1987) tarafından geliştirilen üç farklı indis Eşitlik 3.98’de yer almaktadır. \tilde{m} ve \tilde{n} bulanık sayılar, $\mu_{\tilde{m}}(u)$ ve $\mu_{\tilde{n}}(u)$ bulanık sayıların üyelik fonksiyonları olarak tanımlıdır. Pos ifadesi “possibility”; Nes ifadesi “necessity” kelimelerinin İngilizce kısaltmalarıdır.

$$Pos(\tilde{m} = \tilde{n}) = \sup_{u \in R} \min \{ \mu_{\tilde{m}}(u), \mu_{\tilde{n}}(u) \} \quad (3.98)$$

$$Nes(\tilde{m} \subset \tilde{n}) = \inf_{u \in R} \max \{ 1 - \mu_{\tilde{m}}(u), \mu_{\tilde{n}}(u) \}$$

$$Nes(\tilde{m} \supset \tilde{n}) = \inf_{u \in R} \max \{ \mu_{\tilde{m}}(u), 1 - \mu_{\tilde{n}}(u) \}$$

Girdi ve çıktının her ikisinin de bulanık sayı olduğu bulanık doğrusal regresyon çözümlemesinde, Eşitlik 3.98’de yer alan indisler eşitlik ilişkisinde kullanıldığında üç farklı problem ile karşılaşılmaktadır. Bunlar Eşitlik 3.99-3.101’de tanımlanmıştır.

$$P_1(h): \min Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \quad (3.99)$$

$$Pos(\hat{y}_i = \tilde{a} \otimes \tilde{x}_i) \geq h, \quad i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

$$P_2(h): \min Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \quad (3.100)$$

$$Nes(\tilde{y}_i \subset \tilde{a} \otimes \tilde{x}_i) \geq h, i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

$$P_3(h): \max Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \quad (3.101)$$

$$Nes(\tilde{y}_i \supset \tilde{a} \otimes \tilde{x}_i) \geq h, i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

$\tilde{y}_i = \tilde{a} \otimes \tilde{x}_i$ olarak tanımlanmış bulanık doğrusal regresyon modelinde, $0 < h \leq 1$ aralığında tanımlı h değeri bulanık çıktı verisi ile model arasındaki uyumu ifade eder. Z amaç fonksiyonu Tanaka modeline benzer şekilde bulanıklık derecesini gösterir. Metin içinde tanımlanan indisler ve bulanık sayılar yardımıyla Eşitlik 3.99-3.101'de yer alan ifadeler Sakawa ve Yano (1992) tarafından tanımlanan teorem yardımıyla Eşitlik 3.102'de yer alan olağan eşitsizlik formuna dönüştürülebilir. İlgili ifadeler Eşitlik 3.102'de yer almaktadır.

$$Pos((\tilde{y}_i = \tilde{a} \otimes \tilde{x}_i) \geq h, i = 1, \dots, k, \text{ ancak ve ancak } \bar{y}_i + L^{-1}(h)e_i \geq Y_{ih}^L, \bar{y}_i - L^{-1}(h)e_i \leq Y_{ih}^R, \quad (3.102)$$

$$Nes(\tilde{y}_i \subset \tilde{a} \otimes \tilde{x}_i) \geq h, i = 1, \dots, k, \text{ ancak ve ancak } \bar{y}_i + L^{-1}(1-h)e_i \leq Y_{ih}^R, \bar{y}_i - L^{-1}(1-h)e_i \geq Y_{ih}^L,$$

$$Nes(\tilde{y}_i \supset \tilde{a} \otimes \tilde{x}_i) \geq h, i = 1, \dots, k, \text{ ancak ve ancak } \bar{y}_i + L^{-1}(h)e_i \geq Y_{i(1-h)}^R, \bar{y}_i - L^{-1}(h)e_i \leq Y_{i,1-h}^L,$$

Eşitlik 3.99-3.101'de $P_1(h)$, $P_2(h)$ ve $P_3(h)$ olarak tanımlı problemler (\tilde{a}, c) 'ye göre doğrusal programlama problemine indirgenebilir. Böylece çok daha kolay bir çözümleme tekniğine kavuşulmuş olunur. Araştırmacı analize başlamadan önce $(0,1]$ aralığında olabildiğince yüksek bir h değeri belirlemelidir. Bunun nedeni h değerinin bulanık çıktılar ve tahmin değerleri arasındaki uyum derecesini temsil ediyor oluşudur. Ancak diğer taraftan modelin bulanıklık seviyesinin de minimum seviyede tutulması gerekmektedir. İki farklı durum arasındaki uyumsuzluk nedeniyle Eşitlik 3.102'de tanımlanan ifadeler Eşitlik 3.103'de çok amaçlı programlama problemi olarak tekrar düzenlenmiştir. Tanımlanan problemlerde $0 < h \leq 1$ koşulu geçerlidir (Sakawa ve Yano, 1990; Sakawa ve Yano, 1992; Başaran 2007).

$$MP_1: \min Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L),$$

$$\max h$$

$$Pos(\tilde{y}_i = \tilde{a} \otimes \tilde{x}_i) \geq h, \quad i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

$$MP_2: \min Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L),$$

$$\max h$$

$$Nes(\tilde{y}_i \subset \tilde{a} \otimes \tilde{x}_i) \geq h, \quad i = 1, \dots, k. \quad (3.103)$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

$$MP_3: \max Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L),$$

$$\max h$$

$$Nes(\tilde{y}_i \supset \tilde{a} \otimes \tilde{x}_i) \geq h, \quad i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3)$$

Sakawa ve Yano (1992) çok amaçlı programlama probleminin çözümü için sayısal optimizasyon problemlerinin çözümünde, olağan optimal çözüm kavramı yerine Pareto optimal çözüm kavramını önermişlerdir. MP_1, MP_2 ve MP_3 problemleri için Pareto optimal çözümü $(\bar{a}^*, c^*), h^*$ olarak tanımlanmıştır. Bu tanımın geçerli olması için $Z \leq Z^*(MP_1(h), MP_2(h))$ ve $Z \geq Z^*(MP_3(h))$ ile $h \geq h^*$ şartlarını sağlayan $(\bar{a}, c), h$ değerlerinin olması gerekmektedir. Burada araştırmacı sonsuz sayıda nokta içeren Pareto çözümleri içinden kendine uygun çözüm kümelerinden birini belirlemektedir. Geliştirilen yöntemin bundan sonraki aşamasında MP_1, MP_2 ve MP_3 çok amaçlı programlama problemleri için pareto optimal çözümleri üretilmiştir. Eşik değeri (ε) araştırmacı tarafından $0 < \varepsilon \leq 1$ aralığında belirlenmek üzere MP_1 olarak tanımlanmış kısıt problemi Eşitlik 3.104'de ifade edilmektedir.

$$CP_1(\varepsilon): \min Z = \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \quad (3.104)$$

$$Pos(\tilde{y}_i = \tilde{a} \otimes \tilde{x}_i) \geq h, \quad i = 1, \dots, k.$$

$$(\tilde{a}, c) \in L(J_1, J_2, J_3), \quad h \geq \varepsilon$$

Eşitlik 3.104'de yer alan kısıt problemi Eşitlik 3.102'de yer alan teorem yardımıyla

doğrusal programlama problemine dönüştürülmektedir. Bu ifadenin $CP_1(\varepsilon)$ için matematiksel gösterimi Eşitlik 3.105’de yer almaktadır.

$$\begin{aligned}
CP_1(\varepsilon): \min Z &= \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \\
\bar{y} + L^{-1}(\varepsilon)e_i &\geq Y_{ie}^L, \quad i = 1, \dots, k, \\
\bar{y} - L^{-1}(\varepsilon)e_i &\leq Y_{ie}^R, \quad i = 1, \dots, k, \\
\bar{a}_j - L^{-1}(\varepsilon)c_j &\geq 0, \quad j \in J_1, \\
\bar{a}_j - L^{-1}(\varepsilon)c_j &\leq 0, \quad \bar{a}_j + L^{-1}(\varepsilon)c_j \geq 0, \quad j \in J_2, \\
\bar{a}_j + L^{-1}(\varepsilon)c_j &\leq 0, \quad j \in J_3, \\
c_j &\geq 0, \quad j = 0, \dots, n.
\end{aligned} \tag{3.105}$$

Eşitlik 3.105’de yer alan çok amaçlı programlama probleminin, doğrusal programlama problemi olarak çözümünü için üç adımda gerçekleşen etkileşimli bir algoritma geliştirilmiştir (Sakawa ve Yano, 1992). Buna göre;

Adım 1: Araştırmacı $0 < \varepsilon \leq 1$ aralığında bir başlangıç ε eşik değeri belirlemektedir. Burada $J_1^{(1)} = \{0, 1, \dots, n\}, J_2^{(1)} = \emptyset, J_3^{(1)} = \emptyset$ ve iterasyon indeksi $l = 1$ olmaktadır.

Adım 2: Belirlenen ε eşik değeri ile $CP_1(\varepsilon)$ kısıt problemi çözümlenir.

Adım 3: $(\bar{a}_j^{(l)}, c_j^{(l)})$, $j = 0, \dots, n$ optimal çözümü elde etmek amacıyla Eşitlik 3.106’da yer alan problem çözülür.

$$\begin{aligned}
CP_1(\varepsilon; J_1^{(1)}, J_2^{(1)}, J_3^{(1)}): \min Z &= \sum_{i=1}^k (Y_{i0}^R - Y_{i0}^L) \\
\bar{y} + L^{-1}(\varepsilon)e_i &\geq Y_{ie}^L, \quad i = 1, \dots, k, \\
\bar{y} - L^{-1}(\varepsilon)e_i &\leq Y_{ie}^R, \quad i = 1, \dots, k, \\
\bar{a}_j - L^{-1}(\varepsilon)c_j &\geq 0, \quad j \in J_1, \\
\bar{a}_j - L^{-1}(\varepsilon)c_j &\leq 0, \quad \bar{a}_j + L^{-1}(\varepsilon)c_j \geq 0, \quad j \in J_2,
\end{aligned} \tag{3.106}$$

$$\bar{a}_j + L^{-1}(\varepsilon)c_j \leq 0, \quad j \in J_3,$$

$$c_j \geq 0, \quad j = 0, \dots, n.$$

Problem çözümü gerçekleştirildikten sonra kısıt probleminin optimal çözümü

$$\bar{a}_j^* - L^{-1}(h)c_j^* > 0, \quad j \in J_1^{(l)},$$

$$\bar{a}_j^* - L^{-1}(h)c_j^* < 0, \quad \bar{a}_j^* + L^{-1}(h)c_j^* > 0, \quad j \in J_2^{(l)},$$

$$\bar{a}_j^* + L^{-1}(h)c_j^* < 0, \quad j \in J_3^{(l)},$$

şartlarını sağlıyor ise algoritma durdurulur. Eğer şartlar sağlanmıyor ise $J^{(l+1)}$ indeks kümesi güncellenerek algoritmanın uygulanmasına devam edilir.

$$J_1^{(l+1)} = \{j \in J_1^{(l)} \mid \bar{a}_j^{(l)} - L^{-1}(\varepsilon)c_j^{(l)} > 0\} + \{j \in J_2^{(l)} \mid \bar{a}_j^{(l)} - L^{-1}(\varepsilon)c_j^{(l)} = 0\},$$

$$J_2^{(l+1)} = \{j \in J_2^{(l)} \mid \bar{a}_j^{(l)} - L^{-1}(\varepsilon)c_j^{(l)} < 0\} \vee \bar{a}_j^{(l)} + L^{-1}(\varepsilon)c_j^{(l)} > 0 + \{j \in J_1^{(l)} \mid \bar{a}_j^{(l)} - L^{-1}(\varepsilon)c_j^{(l)} = 0\} + \{j \in J_3^{(l)} \mid \bar{a}_j^{(l)} + L^{-1}(\varepsilon)c_j^{(l)} = 0\}$$

$$J_3^{(l+1)} = \{j \in J_3^{(l)} \mid \bar{a}_j^{(l)} + L^{-1}(\varepsilon)c_j^{(l)} < 0\} + \{j \in J_2^{(l)} \mid \bar{a}_j^{(l)} + L^{-1}(\varepsilon)c_j^{(l)} = 0\}$$

İterasyon indeksi $l = l + 1$ olacak şekilde çözümün başladığı yere geri dönlür. Modelin bulanıklık seviyesi ve bulanık eşik değeri araştırmacı için uygun ise algoritmanın işlemlerine son verir ve çözüm tamamlanmış olur. Aksi durumda bulanıklık seviyesi ve bulanık eşik değeri için farklı değerler kullanılarak araştırma için en uygun çözüm araştırılabilir (Sakawa ve Yano, 1990; Sakawa ve Yano, 1992; Başaran 2007).

Tanaka ve diğ. (1982) tarafından önerilen yöntem alternatif bir başka çalışma Peter (1994) tarafından yapılmıştır. Çalışmasında önerdiği bulanık regresyon modelinin aralık sınırlarının bulanık olduğu belirtilmiştir. Geliştirilen modelde Tanaka modelinden farklı olarak λ tolerans katsayısı bulunmaktadır. λ 'yı maksimize etmek üzere modelin matematiksel gösterimi Eşitlik 3.107-3.109'da yer almaktadır.

$$\text{Max } \lambda \tag{3.107}$$

$$(1 - \lambda)p_0 - \sum_{i=1}^n c^t |x_i| \geq -d_0 \quad (\text{amaç fonksiyonu})$$

$$(1 - \lambda)p_0 - \sum_{i=1}^n (c_0|x_0| + c_1|x_1| + \dots + c_n|x_n|) \geq -d_0$$

$$(1 - \lambda)p_i + a^t x_i + (1 - h)c^t |x_i| \geq y_i \quad (\text{üst sınır}) \quad (3.108)$$

$$(1 - \lambda)p_i - a^t x_i + (1 - h)c^t |x_i| \geq -y_i \quad (\text{alt sınır}) \quad (3.109)$$

$$-\lambda \geq -1, \lambda, c_i \geq 0, i = 1, 2, \dots, n. 0 \leq h \leq 1.$$

Eşitlik 3.107-3.109'da n bağımsız değişken sayısı olmak üzere p_i, y_i 'nin tolerans aralığına ilişkin genişlik; p_0 ise arzu edilen alt sınır toleransıdır (Chen 2001; Başaran 2007). p_i ve p_0 araştırmanın içeriğine göre belirlenmektedir. d_0 amaç fonksiyonunun istenilen değeridir. d_0 'ın sifıra eşit olması tavsiye edilmektedir. Böylece modelin toplam bulanıklık değeri de sıfır olacaktır (Peters, 1994). Peters (1994)'ün çalışmasında girdi ve çıktılardan her ikisi de kesin sayı olarak modele dahil edilmiştir ve aykırı değerler söz konusu olduğunda bulanık doğrusal regresyon modelinin gelişimine önemli katkılar sağlamıştır. Peter (1994)'ün çalışmasını izleyen dönemde Chen (2001) aykırı değer probleminin çözümü için bulanık sayı olmayan girdi ve bulanık sayı olan çıktıları kullanarak bir bulanık regresyon modeli önermiştir. Çalışmada problemin niteliğine göre belirlenen önceden atanmış (pre-assigned) k-limit değerleri yorumlanmıştır.

Bulanık En Küçük Kareler Yöntemine Dayalı Parametre Tahmini

Bulanık en küçük kareler yöntemi Diamond (1988a) tarafından bulanık doğrusal regresyon analizinde parametre tahmini amacıyla geliştirilmiştir. Bulanık en küçük kareler regresyonu, klasik doğrusal regresyon analizinin bulanık genişlemesi şeklinde yorumlanabilmektedir. Parametrelerin elde edilme sürecinde klasik regresyon analizi ile benzerlik göstermektedir. Diamond (1988a) tarafından önerilen modelin amacı tahmin ve gerçek değerler arası uzaklığı minimize etmektir. Girdi ve çıktının bulanık sayı olduğu durumda, bulanık en küçük kareler çözümlemesi için Diamond (1988a) tarafından iki farklı model önerilmiştir. Önerilen modellerin matematiksel gösterimleri Eşitlik 3.110-3.111'de yer almaktadır.

$$Y = a + bX, \quad a, b \in R, \quad (3.110)$$

$$Y = \tilde{E} + bX, \quad b \in R, \quad \tilde{E} \in F(R). \quad (3.111)$$

Gözlemlerin X_i, Y_i veri çiftlerinden oluştuğu varsayılmaktadır ($i=1, 2, \dots, N$). Modelde

$X_i = (x_i, \underline{\xi}_i, \bar{\xi}_i)_T$, $Y_i = y_i, \underline{\eta}_i, \bar{\eta}_i$ ve $x_i - \underline{\xi}_i \geq 0$ olarak tanımlanmaktadır. Eşitlik 3.111'de yer alan model Eşitlik 3.110'daki modelin genelleştirilmiş şeklidir. Bundan sonraki matematiksel gösterimler Eşitlik 3.110 üzerinden devam edecektir. Eşitlik 3.110'da yer alan modele ilişkin en küçük kareler optimizasyon problemi,

$$\text{minimum } r(a, b) = \sum d(a + bX_i, Y_i)^2$$

şeklinde tanımlanmaktadır. Burada $b \geq 0$ veya $b < 0$ olmak üzere iki durum ortaya çıkmaktadır. $b \geq 0$ olduğunda bulanık çıktı ile bağımlı değişkenin gözlemlenen değerleri arasındaki farkı bildiren uzaklık Eşitlik 3.112'deki gibi ifade edilmektedir.

$$d(a + bX_i, Y_i) = \left[a + bx_i - y_i - (b\underline{\xi}_i - \underline{\eta}_i) \right]^2 + \left[a + bx_i - y_i + (b\bar{\xi}_i - \bar{\eta}_i) \right]^2 + (a + bx_i - y_i)^2 \quad (3.112)$$

$b < 0$ olduğu durumda ise uzaklık Eşitlik 3.113'deki gibidir.

$$d(a + bX_i, Y_i) = \left[a + bx_i - y_i + b\bar{\xi}_i - \bar{\eta}_i \right]^2 + \left[a + bx_i - y_i - (b\underline{\xi}_i - \underline{\eta}_i) \right]^2 + (a + bx_i - y_i)^2 \quad (3.113)$$

Bulanık en küçük kareler regresyon çözümlemesinin bundan sonraki aşamasında Eşitlik 3.112'de yer alan fonksiyonun a ve b'ye göre türevleri alınmaktadır. Eşitlik 3.114'de yer alan denklem sisteminin çözümlenmesiyle a ve b parametreleri hesaplanmış olur (Diamond 1988a; Diamond ve Tanaka 1996; Şanlı 2005).

$$\frac{\partial d}{\partial a} = 3Na + b \sum [3x_i + \delta(X_i)] = \sum [3y_i + \delta(Y_i)] = 0, \quad (3.114)$$

$$\frac{\partial d}{\partial b} = a \sum [3x_i + \delta(X_i)] + b \left[x_i^2 + (x_i - \underline{\xi}_i)^2 + (x_i + \bar{\xi}_i)^2 \right] = \sum \left[(x_i - \underline{\xi}_i)(y_i - \underline{\eta}_i) + (x_i + \bar{\xi}_i)(y_i + \bar{\eta}_i) + x_i y_i \right] = 0$$

Burada x_i ($i = 1, 2, \dots, n$) olmak üzere,

$$\delta(X) = \bar{\xi} - \underline{\xi}$$

$$\delta(Y) = \bar{\eta} - \underline{\eta}$$

şeklinde ifade edilmektedir (Diamond, 1988a; Diamond ve Tanaka 1998; Xu ve Li, 2001;

Şanlı 2005).

Eşitlik 3.111’de yer alan model için en küçük kareler optimizasyonu *minimum* $\rho(E, b) = \sum d(E + bX_i, Y_i)^2$ şeklinde ifade edilmektedir. Burada $E = (c, \underline{\gamma}, \bar{\gamma})_T$ olarak tanımlanmaktadır. Eşitlik 3.110’da tanımlı modelde olduğu gibi bu modelde de $b \geq 0$ veya $b < 0$ olmak üzere iki durum mevcuttur. Uzaklık, $b \geq 0$ olduğu takdirde Eşitlik 3.115; $b < 0$ olduğunda Eşitlik 3.116’daki gibi tanımlanmaktadır (Diamond 1988a).

$$d(E + bX_i, Y_i) = \left[c + bx_i - y_i - \underline{\gamma} - (b\underline{\xi}_i - \underline{\eta}_i) \right]^2 + \left[c + bx_i - y_i + \bar{\gamma} + (b\bar{\xi}_i - \bar{\eta}_i) \right]^2 + (c + bx_i - y_i)^2 \quad (3.115)$$

$$d(E + bX_i, Y_i) = \left[c + bx_i - y_i - \underline{\gamma} - (b\underline{\xi}_i + \underline{\eta}_i) \right]^2 + \left[c + bx_i - y_i + \bar{\gamma} + (b\bar{\xi}_i + \bar{\eta}_i) \right]^2 + (c + bx_i - y_i)^2 \quad (3.116)$$

Diamond (1988a) tarafından geliştirilen yöntemde, veri çiftleri x_i , ($i=1,2,\dots,N$.) $Y_i = (y_i, \underline{\eta}, \bar{\eta})$ olmak üzere girdiler kesin sayı, çıktının bulanık sayı olduğu model tanımı Eşitlik 3.117’de yer almaktadır.

$$Y = A + xB, \quad x \in R, \quad A \in T(R), \quad B \in \wp(R), \quad Y_i \in F(R) \quad (3.117)$$

Modelde $A = (a, \underline{\alpha}, \bar{\alpha})$ ve $B = (b, \underline{\beta}, \bar{\beta})$ parametreleri simetrik üçgensel bulanık sayı olarak belirtilmiştir. Eşitlik 3.117’de yer alan modele ilişkin en küçük kareler optimizasyon problemi,

$$\text{minimum } r(A, B) = \sum d(A + x_i B, Y_i)^2$$

şeklinde tanımlanmaktadır. Modele ilişkin uzaklık ifadesi Eşitlik 3.118’de yer almaktadır.

$$d(A + x_i B, Y_i) = (a + bx_i - y_i)^2 + (a + bx_i - \underline{\alpha} - \underline{\beta}x_i - y_i + \underline{\eta}_i)^2 + (a + bx_i + \bar{\alpha} + x_i\bar{\beta} - y_i - \bar{\eta}_i)^2 \quad (3.118)$$

Eşitlik 3.117’de yer alan fonksiyonun a ’ya $\left(\frac{\partial d}{\partial a} = 0\right)$ ve b ’ye $\left(\frac{\partial d}{\partial b} = 0\right)$ göre türevleri alınıp sıfıra eşitlendiği takdirde a ve b parametreleri hesaplanmış olur. Buna göre elde edilen eşitlikler,

$$a = \hat{y} - b\hat{x}$$

$$\alpha = \hat{\eta} - \beta\hat{x}$$

$$b = \frac{K}{T^2}$$

$$\beta = \frac{k}{T^2}$$

şeklinde ifade edilmektedir. Elde edilen eşitliklerde yer alan K , T^2 , \hat{x} , \hat{y} ve k ifadeleri

$$K = \sum(x_i - \hat{x})(y_i - \hat{y})$$

$$k = \sum(x_i - \hat{x})(\eta_i - \hat{\eta})$$

$$\hat{x} = \frac{\sum x_i}{N}$$

$$\hat{y} = \frac{\sum y_i}{N}$$

$$T^2 = \sum(x_i - \hat{x})^2$$

$$\alpha, \beta \geq 0$$

şeklinde belirtilmektedir (Diamond 1988).

Wang ve Tsaur (2000a) ve Wang ve Tsaur (2000b) tarafından yapılan çalışmalarda Diamond (1988)'in önerdiği yöntem geliştirilmiştir. Bulanık doğrusal regresyon modeli,

$$\tilde{Y}_i = \tilde{A}_0 + \tilde{A}_1 X_i$$

veya

$$\tilde{Y}_i = (a_0 + a_1 X_i, c_{0,L} + c_{1,L} X_i, c_{0,R} + c_{1,R} X_i) \quad i = 1, 2, \dots, n$$

şeklinde ifade edilmektedir. Burada parametreler $\tilde{A}_0 = (\alpha_0, c_0)$, $\tilde{A}_1 = (\alpha_1, c_1)$ ve $Y = (y_i, e_i)$ olarak tanımlanmaktadır. α_0 ve α_1 merkez, c_0 ve c_1 yayılım değerlerini temsil etmektedir. Bulanık çıktı ($\tilde{A}_0 + \tilde{A}_1 X_i$) ve tahmin değeri arasındaki uzaklığı minimize etmeyi amaçlayan yöntemde, merkez ve yayılım değerlerinin alacağı işaretlere göre farklı durumlara uygun çözümler geliştirilmiştir. İncelenen durumlara göre elde edilen türev eşitlikleri şu şekildedir:

a) $\alpha_0 > 0$, $\alpha_1 > 0$, ve c_0, c_1 kısıtsız olmak üzere Eşitlik 3.119-3.122'de verilmiştir:

$$\frac{\partial r(\bar{A}_0 + \bar{A}_1 X_{i1}, \bar{Y}_i)}{\partial \alpha_0} = 2 \sum_{i=1}^M \{ \alpha_0 - c_0 + (\alpha_1 - c_1) X_{i1} - (y_i - e_i) + \alpha_0 + c_0 + (\alpha_1 + c_1) X_{i1} - (y_i + e_i) + \alpha_0 + \alpha_1 X_{i1} - y_i \} \quad (3.119)$$

$$\frac{\partial r(\bar{A}_0 + \bar{A}_1 X_{i1}, \bar{Y}_i)}{\partial c_0} = 2 \sum_{i=1}^M \{ \alpha_0 - c_0 + (\alpha_1 - c_1) X_{i1} - (y_i - e_i)(-1) + \alpha_0 + c_0 + (\alpha_1 + c_1) X_{i1} - (y_i + e_i) + \alpha_0 + \alpha_1 X_{i1} - y_i \} \quad (3.120)$$

$$\frac{\partial r(\bar{A}_0 + \bar{A}_1 X_{i1}, \bar{Y}_i)}{\partial \alpha_1} = 2 \sum_{i=1}^M X_{i1} \{ \alpha_0 - c_0 + (\alpha_1 - c_1) X_{i1} - (y_i - e_i) + \alpha_0 + c_0 + (\alpha_1 + c_1) X_{i1} - (y_i + e_i) + \alpha_0 + \alpha_1 X_{i1} - y_i \} \quad (3.121)$$

$$\frac{\partial r(\bar{A}_0 + \bar{A}_1 X_{i1}, \bar{Y}_i)}{\partial c_1} = 2 \sum_{i=1}^M X_{i1} \{ - [\alpha_0 - c_0 + (\alpha_1 - c_1) X_{i1} - (y_i - e_i)] + [\alpha_0 + c_0 + (\alpha_1 + c_1) X_{i1} - (y_i + e_i)] \} \quad (3.122)$$

Denklem sisteminde merkez ve yayılım değerlerine göre türev alınıp sıfıra eşitlendiğinde çözümler Eşitlik 3.123-3.126'deki gibi elde edilmiş olunur:

$$\alpha_1 = \frac{N \sum_{i=1}^M X_{i1} y_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M y_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.123)$$

$$\alpha_0 = \bar{y} - \alpha_1 \bar{X}, \quad (3.124)$$

$$c_1 = \frac{N \sum_{i=1}^M X_{i1} e_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M e_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.125)$$

$$c_0 = \bar{e} - c_1 \bar{X} \quad (3.126)$$

Burada \bar{e} , \bar{X} ve \bar{y} , Eşitlik 3.127'de tanımlanmaktadır:

$$\bar{e} = \frac{\sum_{i=1}^M e_i}{M}, \quad \bar{X} = \frac{\sum_{i=1}^M X_{i1}}{M}, \quad \bar{y} = \frac{\sum_{i=1}^M y_i}{M} \quad (3.127)$$

b) $\alpha_0 < 0$, $\alpha_1 > 0$, ve c_0, c_1 kısıtsız olmak üzere Eşitlik 3.128-3.131'da verilmektedir:

$$\alpha_1 = \frac{N \sum_{i=1}^M X_{i1} y_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M y_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.128)$$

$$\alpha_0 = \bar{y} - \alpha_1 \bar{X}, \quad (3.129)$$

$$c_1 = \frac{N \sum_{i=1}^M X_{i1} e_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M e_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.130)$$

$$c_0 = -(\bar{e} - c_1 \bar{X}). \quad (3.131)$$

c) $\alpha_0 > 0$, $\alpha_1 < 0$, ve $c_0 < 0$ ve c_1 kısıtsız olmak üzere Eşitlik 3.132-3.135'de verilmektedir:

$$\alpha_1 = \frac{N \sum_{i=1}^M X_{i1} y_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M y_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.132)$$

$$\alpha_0 = \bar{y} - \alpha_1 \bar{X}, \quad (3.133)$$

$$c_1 = \frac{N \sum_{i=1}^M X_{i1} e_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M e_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.134)$$

$$c_0 = \bar{e} - c_1 \bar{X}. \quad (3.135)$$

d) $\alpha_0 < 0$, $\alpha_1 < 0$, ve $c_0 < 0$ ve $c_1 < 0$ olmak üzere Eşitlik 3.136-3.139'de verilmektedir:

$$\alpha_1 = \frac{N \sum_{i=1}^M X_{i1} y_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M y_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.136)$$

$$\alpha_0 = \bar{y} - \alpha_1 \bar{X}, \quad (3.137)$$

$$c_1 = \frac{N \sum_{i=1}^M X_{i1} e_i - \sum_{i=1}^M X_{i1} \sum_{i=1}^M e_i}{N \sum_{i=1}^M X_{i1}^2 - (\sum_{i=1}^M X_{i1})^2}, \quad (3.138)$$

$$c_0 = -(\bar{e} - c_1 \bar{X}). \quad (3.139)$$

3.5.2. Bulanık Doğrusal Olmayan Regresyon Analizi

Bulanık doğrusal regresyon analizinde doğrusal programlama ve en küçük kareler tekniğine dayalı parametre tahmin yöntemleri oldukça yaygın kullanıma sahiptir. Bununla birlikte, girdi ve çıktı arasında doğrusal olmayan ilişkilerin modellenmesinde gerek kesin girdi- bulanık çıktı gerekse bulanık girdi- bulanık çıktı ile çalışan sistemlerde de bulanık regresyon analizi başarılı şekilde kullanılmaktadır. Doğrusal olmayan bulanık regresyon analizinde, bulanık çıktıların ifade edilmesinde doğrusal regresyon analizinde kullanılan parametre tahmin yöntemlerine göre daha gelişmiş ve çok yönlü yöntemlere ihtiyaç duyulmaktadır. Bu bağlamda araştırmacılar doğrusal olmayan bulanık regresyon analizi çözümlerinde yapay sinir ağları ve destek vektör makineleri gibi yapay zeka temelli yöntemleri tercih etmektedir.

Yapay sinir ağları yöntemi özellikle doğrusal olmayan fonksiyonların çözümlenmesinde sahip olduğu tahmin yeteneği ile birçok farklı araştırmaya konu olmuştur.

Doğrusal regresyon analizini doğrusal olmayan bulanık regresyon analizine genişletmek amacıyla yapılan çalışmaların büyük bir bölümünde çok katmanlı ileri beslemeli yapay sinir ağları kullanılmıştır. Bu çalışmalardan bazıları alt ve üst regresyon eğrilerini elde etmek üzere standart iki farklı sinir ağı kullanırken (Ishibuchi ve Tanaka, 1992; Xu ve diğ. 2000; Xu ve Khoshgoftaar, 2001), bazıları bulanıklaştırılmış sinir ağı kullanmışlardır (Miyazaki ve diğ. 1994; Ishibuchi ve Nii, 1996a; Ishibuchi ve Nii, 2001; He ve diğ. 2016; He ve diğ. 2018). Desen tanımlama ve tahmin problemlerinin çözümlenmesinde oldukça başarılı uygulamalara konu olan destek vektör makineleri, doğrusal olmayan bulanık regresyon çözümlenmesinde kullanılan bir diğer yöntemdir (Hong ve Hwang, 2003; Hong ve Hwang, 2006; Hong ve diğ. 2006). Doğrusal olmayan bulanık regresyon çalışmalarında

en küçük kareler destek vektör makineleri yaygın şekilde tercih edilmektedir (Hong ve Hwang, 2006; Xie, 2010; Yongqi, 2012).

3.5.2.1. Yapay Sinir Ağları

Makine öğrenmesi kavramı, bilgisayarların uyarlamalı mekanizmalar aracılığı ile insanların tecrübe ve bilgilerinden yararlanılması amacıyla ortaya çıkmıştır. Karar alma ve öğrenme gibi yeteneklerin bilgisayarlara kazandırılmasını amaçlayan bu kavram, örnekler ve benzerlik ilişkilerinden yola çıkarak zeki sistemlerin performans gelişimine önemli katkılar sunmaktadır. Yapay zekânın önemli bir parçası olan makine öğrenmesi çalışmaları bilgisayarlara deneysel veriler ile çalışma davranışını kazandırmaktadır. Günümüzde gittikçe artan teknolojik gelişmeler sayesinde algoritmaların tasarım ve gelişimi iyileştirilmekte böylece karar verme, problem çözme ve karmaşık örüntülerin tanımlanması gibi işlevlerin bilgisayarlar tarafından gerçekleştirilmesi sağlanmaktadır.

Yapay sinir ağları makine öğrenmesi gerçekleştiren yöntemlerden birisidir. Araştırmacılar tarafından pek çok farklı alanda oldukça başarılı şekilde kullanılmakta olan yöntem insan beyninde bulunan sinir hücrelerinin çalışma ilkelerinden yola çıkılarak geliştirilmiştir. Yapay sinir ağları insan beynine benzer şekilde öğrenme süreci boyunca çevresinden edindiği bilgileri toplar ve çeşitli bağlantılar aracılığı ile bu bilgilerin depolanmasını sağlar. Yapay sinir ağlarının öğrenme işlevi insanlara benzer şekilde deneyimlerden yararlanarak gerçekleşir. Öğrendiği bilgiler üzerinden gelecekte karşılaştığı yeni problemlerin çözümünü sağlar.

Yapay sinir ağlarının diğer analiz yöntemlerine göre en önemli avantajı; örnekler üzerinden öğrenebilme yeteneği ve farklı öğrenme algoritmalarını kullanabilmesidir. Matematiksel olarak çözümlenmesi zor ve karmaşık problemlerde özellikle doğrusal olmayan ilişkilerin modellenmesinde oldukça etkilidir. Uyarlanabilirlik özelliği sayesinde çözüm sürecinde ortamda meydana gelebilecek değişikliklere karşı yeniden eğitilebilirler. Bir başka ifade ile sinaptik ağırlıklar değiştirilerek çevreye uyum sağlayabilir. Bazı durumlarda sinaptik ağırlıklar eş zamanlı değiştirilebilmektedir. Yapay sinir ağları eksik veri ile çalışabilir, analizlerde veri eksik olmasına rağmen sonuca ulaşılabilir. Ayrıca sinir ağları hata toleransına sahiptir. Ağ yapısında hatalı nöron veya bağlantı olması durumunda da çalışmayı sürdürmektedir. Bu durum yapay sinir ağlarında dereceli bozulmayı sağlamaktadır (Haykin, 1999; Öztemel, 2006).

Yapay sinir ağı çalışmalarında bazı kısıtlar mevcuttur. Ağ topolojisinin belirlenmesinde kesin bir kural düzeni bulunmamaktadır, bu durum araştırmacının tercihine bırakılmıştır. Ayrıca veri setinin hazırlanmasında eğitim ve test setlerinin tasarımında da kesin bir formülasyon bulunmamaktadır. Bazı durumlarda eğitim süresi uzun olabilmektedir.

Yapay sinir ağları hakkında ilk çalışmalar 1943 yılında Warren McCulloch ve Walter Pitts'in nöronların işleyişi hakkında oluşturdukları teori ile başlamıştır. 1949 yılında Donald Hebb "*The organization of behaviour*" başlıklı kitabında fizyoloji ve psikoloji arasında bir bağlantıyı ortaya koymuştur. Nöronların sinapsları için önerdiği öğrenme kuralı sayesinde yapay sinir ağı çalışmalarına oldukça önemli katkılar sağlamıştır. Hebb kuralından esinlenerek bir çok araştırmacı farklı kural yapılarının ortaya çıkmasına ve yapay sinir ağları çalışmalarının hızlanmasına etki etmişlerdir. Frank Rosenblatt "*Neurocomputing*" kavramını keşfeden bilim insanıdır, özellikle örüntü tanımlama alanında çalışmaları yoğunlaşmıştır. Frank Rosenblatt 1957 yılında ilk yapay sinir ağı perseptronu geliştirmiştir. 1959 yılında Bernard Widrow ve Marcial Hoff perseptron öğrenme kuralından farklı bir öğrenme kuralına sahip Adaline ve Madaline modelini oluşturdu. Adaline modeli farklı sinir ağı mimarilerinin oluşturulmasında ve uygulamaya yönelik çalışmaların gelişiminde bir yapı taşı niteliğindedir.


1969 yılında Marvin Minsky ve Seymour Papert "*Perceptrons*" isimli kitaplarında yapay sinir ağlarının bazı eksiklerine dikkat çekmişler ve XOR probleminin çözümünde yetersiz kaldığını ispatlamışlardır. XOR problemi günlük hayatta karşılaşılan birçok problemi matematiksel açıdan temsil etmektedir. Bu durum yapay sinir ağları çalışmalarını olumsuz yönde etkilemiş, finansal desteklerin durmasına yol açmış ve bir durgunluk dönemine girmesine neden olmuştur. 1970'li yıllara gelindiğinde Minsky ve Papert tarafından perseptrona ilişkin sunulan kısıtlamalara ve finansal kesintilere rağmen sinir ağı çalışmaları devam etmiştir. Geriye yayımlı modeller ve çok katmanlı algılayıcıya ilişkin çalışmaların temelleri bu yıllarda atılmıştır.

1980'li yıllar yapay sinir ağı çalışmaları için bir dönüm noktası niteliğindedir. Bu yıllarda sinirsel hesaplama alanında çalışan James Anderson, Kunihiko Fukushima, Teuvo Kohonen ve John Hopfield gibi bilim insanları sundukları çalışmalarda sinir ağları uygulamalarına olan ilginin yeniden doğuşunu sağlayan önemli çalışmalar yapmışlardır. Dünyaca ünlü fizikçi John Hopfield yapay sinir ağlarının genelleme özelliğine sahip olabileceğini ve gezgin satıcı gibi problem yapılarına çözüm üretebileceğini göstermiştir.

1982 yılında Hopfield ağı ve çok katmanlı algılayıcı geliştirilmiştir. 1984 yılında Kohonen danışmansız öğrenen ağı geliştirmiştir. SOM ağı, Boltzman makinesi ve genelleştirilmiş delta kuralı ile çalışan çok katmanlı algılayıcıların geliştirilmesini izleyen dönemde, 1988 yılında radyal tabanlı fonksiyonlar ortaya çıkmıştır. Bunu takiben probabilistik ağılar ve genel regresyon ağı geliştirilmiştir. 1980'li yıllarda gerçekleştirilen çalışmalar yapay sinir ağı çalışmalarına olan ilgiyi oldukça arttırmıştır. Günümüzde yapay sinir ağı ile ilgili teori ve uygulama çalışmaları gittikçe artmakta ve oldukça başarılı sonuçlar göstermektedir. Teknolojik gelişmelerin artması ve bilgisayarların donanımsal olarak gittikçe yükselen bir grafiğe sahip olması yapay sinir ağlarının gelişimine olumlu yönde etki etmektedir. Yapay sinir ağlarının diğer yapay zeka yöntemleri ile entegreli veya istatistiksel analiz yöntemleri ile birlikte tasarlanan zeki sistem yapılarında yer alması bilimsel çalışmalara büyük kazanç sağlamaktadır.

Yapay sinir ağı genelleme özelliği sayesinde sınıflandırma, kümeleme, tahmin, görüntü işleme, ses tanıma, desen tanıma, kontrol, filtreleme, veri ilişkilendirme, teşhis gibi işlevleri başarılı şekilde yerine getirmektedir. Günümüzde endüstri, finansal, askeri, sağlık, yaşam bilimleri, mühendislik bilimleri gibi bir çok farklı alanda oldukça geniş bir kullanım alanına sahiptir (Haykin 2009; Öztemel, 2006).

Sinir hücreleri insanların sinir sistemlerinde bulunan ve yaşamsal faaliyetlerinin yürütüldüğü en küçük birimlerdir. Dışarıdan gelen bilgiler sinir sistemi tarafından beyine iletilir. Beyinin verdiği karar neticesi diğer organlara davranış olarak gönderilir (Şen, 2004; Öztemel, 2006). Şekil 3.13'de görüleceği üzere biyolojik bir sinir hücresi; hücre gövdesi (soma), dendrit, akson ve sinapslardan oluşmaktadır. Burada sinapslar hücreler arasındaki geçişleri veya iletişimi sağlamaktadır. Sinapslardan alınan bilgiler dendritler tarafından hücre gövdesine iletilir. Burada çıktı aktivasyonuna dönüştürülen ve işlenen bilgiler ile sinir hücresi kendi elektrik sinyalini oluşturur ve bu sinyaller akson aracılığı ile dendritlere, sonrasında sinapslara gönderilir ve böylece bir başka sinir hücresine iletilmiş olunur. Burada aksonlar iletim hattına benzer bir davranış sergilerler.




Şekil 3.13: Biyolojik Sinir Hücresi (Negnevitsky, 2005).

Yapay sinir ağlarının yapısında çok sayıda yapay sinir hücreleri bulunmaktadır. Nöron veya işlemci olarak da adlandırılan yapay sinir hücreleri, biyolojik sinir hücrelerine benzer şekilde yapılandırılmıştır. Yapay bir sinir hücresinin temel bileşenleri girdiler, ağırlıklar, transfer fonksiyonu, aktivasyon fonksiyonu ve çıktıdır. Nöronlar bağlantılar tarafından bir araya getirilir. Her bağlantı sayısal bir ağırlıkla ilişkilendirilmiştir. Ağırlıklar girdilerin model içindeki önemini ifade etmektedir. Örneğin birinci ağırlık, birinci girdi değişkeninin önemini ifade eder. Yapay sinir ağlarının öğrenme işlevi ağırlıkların tekrarlanan bir süreçte düzenlenmesi ile gerçekleşir. Tablo 3.1’de biyolojik ve yapay sinir hücrelerinin işlevsel açıdan karşılaştırması yer almaktadır.

Tablo 3.1: Biyolojik Sinir Hücresi ile Yapay Sinir Hücresi İşlevsel Karşılaştırması.

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi	Açıklama
Nöron	İşlemci elemanı	Sinir hücresi
Akson	Çıkış	Bilginin tek yönlü iletimi
Dendrit	Girdiler	Hücre gövdesine iletim
Sinaps	Ağırlıklar	Sinir hücreleri arasında iletişim



Şekil 3.14: Yapay Sinir Hücresi.

Şekil 3.14’de McCulloch ve Pits (1943) tarafından sunulan bir yapay sinir hücresi yer almaktadır. Yapay sinir hücresinin girdileri incelenen probleme ilişkin dışarıdan alınan bilgileri temsil etmektedir. Sisteme gelen girdi değerleri, bir transfer fonksiyonu ile net girdiyi elde etmek üzere ağırlıklarla çarpılarak toplanır. Bahsedilen transfer fonksiyonunun matematiksel ifadesi Eşitlik 3.140’da yer almaktadır.

$$NET\ Girdi = \sum_{i=1}^n w_i x_i \quad (3.140)$$

Burada x girdileri, w ise ağırlıkları, yapay sinir hücresine gelen toplam girdi miktarı ise n ile ifade edilmektedir. Eşitlik 3.140'da yer alan transfer fonksiyonu en fazla kullanılan formüllerden birisidir. Bunun dışında Eşitlik 3.141- 3.145'de yer alan formüller de yapay sinir ağı çalışmalarında kullanılmaktadır ($i = 1, \dots, n$) (Öztemel 2006).

$$Net\ Girdi = \prod_i w_i x_i \quad (3.141)$$

$$Net\ Girdi = Max (w_i x_i) \quad (3.142)$$

$$Net\ Girdi = Min (w_i x_i) \quad (3.143)$$

$$Net\ Girdi = \sum_i sgn (w_i x_i) \quad (3.144)$$


$$Net\ Girdi = Net_i(eski) + \sum(w_i x_i) \quad (3.145)$$

Yapay sinir ağları ile gerçekleştirilecek analizlerde Eşitlik 3.140-3.145'de yer alan transfer fonksiyonlarından ideal olanın seçimine ilişkin kesin bir bilgi literatürde bulunmamaktadır. Araştırılan problemin ve kullanılacak olan modelin yapısına göre değişkenlik gösteren fonksiyonlar genellikle deneme yanılma yolu ile tespit edilmektedir. Transfer fonksiyonu ile elde edilen net girdiler aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonlarının büyük bir bölümü doğrusal olmayan niteliktedir. Bu durum, günümüzde yapay sinir ağlarının yaygın şekilde kullanılmasında önemli rol oynamaktadır. Sisteme gelen net girdilerin belirli bir aralıkta dönüşümünü gerçekleştirmektedir. Belirlenen bu aralık seçilen aktivasyon fonksiyonuna göre değişmektedir. Literatürde farklı türlerde aktivasyon fonksiyonları bulunmaktadır. Bunların arasından en fazla karşılaşılan aktivasyon fonksiyonları sign, step, doğrusal, sigmoid, hiperbolik tanjant ve sinüs aktivasyon fonksiyonlarıdır. Net girdi iki değerli olacak şekilde ifade edildiğinde belli bir eşik değeri (θ) belirlenir; net girdi bu değer üzerinde veya altında olmasına bağlı olarak üretilmektedir (Nabiyev, 2003). Bu durumun matematiksel ifadesi Eşitlik 3.146'daki gibidir:

$$Y^{sign} = \begin{cases} +1, & \sum_{i=1}^n w_i x_i \geq 0 \\ -1, & \sum_{i=1}^n w_i x_i < 0 \end{cases} \quad (3.146)$$

Eşitlik 3.146'da yer alan ifade sign aktivasyon fonksiyonudur ve eşik değerinin sıfır olduğu grafiksel gösterimi Şekil 3.15(a)'da yer almaktadır. Step aktivasyon fonksiyonunun matematiksel ifadesi ise Eşitlik 3.147'deki gibidir:

$$y_{step} = \begin{cases} +1, & \sum_{i=1}^n w_i x_i \geq 0 \\ 0, & \sum_{i=1}^n w_i x_i < 0 \end{cases} \quad (3.147)$$




Şekil 3.15: Sign Aktivasyon Fonksiyonu (a), Step Aktivasyon Fonksiyonu (b).

Şekil 3.15(b)'de step aktivasyon fonksiyonunun grafiksel gösterimi yer almaktadır. Step ve sign aktivasyon fonksiyonları karar verme nöronlarında sınıflandırma ve örüntü tanıma görevlerini yerine getirmek üzere kullanılmaktadır.

Sigmoid aktivasyon fonksiyonu $-\infty$ ve $+\infty$ arasında sonsuz değer alabilen girdileri 0 ve 1 arasında uygun bir değere dönüştürür. Sigmoid aktivasyon fonksiyonu ile çalışan nöronlar geri yayılım algoritmaları yapay sinir ağları modellerinde sıkça tercih edilmektedir. Fonksiyonun yapısı doğrusal olmayan niteliktedir ve bu nitelikte problemlerin çözümünde oldukça yoğun tercih edilmektedir. Sigmoid aktivasyon fonksiyonunun grafiksel gösterimi Şekil 3.16(a), $X = \text{Net Girdi}$ olmak üzere matematiksel gösterimi Eşitlik 3.148'de yer almaktadır.

$$y_{sigmoid} = \frac{1}{1+e^{-X}} \quad (3.148)$$

$$X = \sum_{i=1}^n w_i x_i$$



Şekil 3.16: Sigmoid Aktivasyon Fonksiyonu (a), Doğrusal Aktivasyon Fonksiyonu (b).


Doğrusal aktivasyon fonksiyonu ile çalışan nöronlar genellikle doğrusal nitelikte tahminlerin yapıldığı çalışmalarda yer almaktadır. Doğrusal aktivasyon fonksiyonunun grafiksel gösterimi Şekil 3.16(b)'de, $X = Net\ Girdi$ olmak üzere matematiksel ifadesi Eşitlik 3.149'de yer almaktadır.

$$Y^{doğrusal} = X \quad (3.149)$$

Hiperbolik Tanjant ve sinüs aktivasyon fonksiyonlarının matematiksel gösterimleri sırasıyla Eşitlik 3.150 ve Eşitlik 3.151'de yer almaktadır. Tanjant hiperbolik fonksiyonun sigmoid fonksiyondan ayrıldığı nokta tanımlı aralığın -1 ve +1 arasında olmasıdır. Sinüs aktivasyon fonksiyonu ise fonksiyon yapısına uyumlu dağılım gösterildiği takdirde kullanılabilir. Fonksiyonlara ilişkin grafik gösterimleri Şekil 3.17'de yer almaktadır (Vojvoda ve Gold, 2002; Şen, 2004; Öztemel 2003; Chaturvedi, 2010).

$$Y^{hiperbolik\ tanjant} = \frac{(1-e^{-2x})}{(1+e^{2x})} \quad (3.150)$$


$$Y^{sinüs} = Sin(X) \quad (3.151)$$



Şekil 3.17: Hiperbolik Tanjant Aktivasyon Fonksiyonu (a), Sinus Aktivasyon Fonksiyonu (b).

Dışarıdan gelen girdiler transfer fonksiyonu tarafından toplanır ve aktivasyon fonksiyonu tarafından işlenerek dış dünyaya veya bir başka yapay sinir hücresine aktarılır. Elde edilen bu değer, sistem girdilerine karşılık gelen çıktı değeridir.

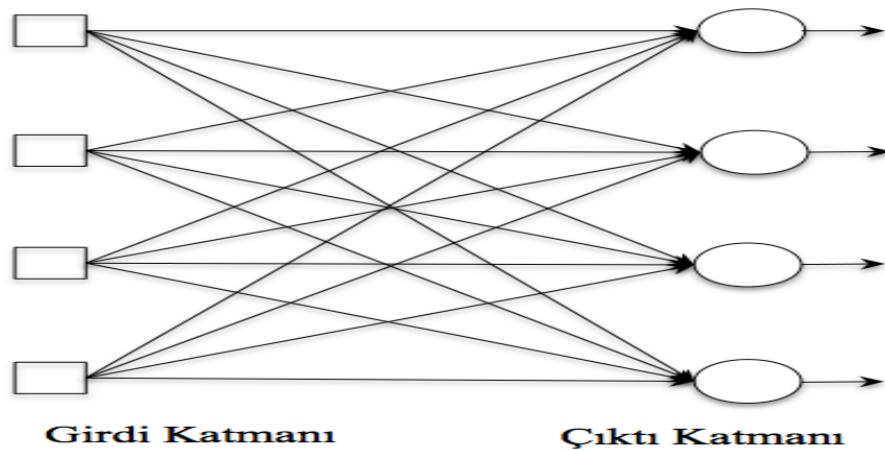
Yapay sinir ağları; girdi katmanı, ara katman ve çıktı katmanlarının her birinde sistemli şekilde bir araya gelen yapay sinir hücrelerinden oluşmaktadır. Girdi katmanında dışarıdan alınan veriler, ara katmanda işlenmek üzere aktarılır. Çalışılan problemin yapısına göre ara katman sayısı farklılık gösterebilir. Ara katmanda işlenen veriler çıktı katmanına iletilir ve girdilere karşılık gelen çıktı değeri üretilir. Yapay sinir ağlarını birbirine bağlayan bağlantıların değerlerine ağırlık değerleri, ağırlık değerlerinin belirlenmesi işlemine ise ağırlık eğitimi denilmektedir. Ağırlık değerlerinin doğru şekilde tespit edilmesi yapay sinir ağlarının örnekler üzerinden genelleme yapabilme yeteneğini önemli ölçüde etkilemektedir. Böylece yapay sinir ağları öğrenme işlemi gerçekleştirilmiş olur (Akıllı ve Atıl, 2014). Ağırlıklar bir yapay sinir ağının zekasının saklı olduğu yerdir. Şekil 3.18’de yapay sinir ağına ilişkin genel bir görünüm yer almaktadır. Burada çok sayıda girdi ve tek bir çıktı bulunmaktadır. Bu tip yapay sinir modelleri tahmin çalışmalarında yoğun şekilde kullanılmaktadır. Tahmin işlevini gerçekleştirmek üzere probleme ilişkin geçmişte yer alan veriler yapay sinir ağına sunulur ve daha sonra hiç görmediği veriler üzerinden ağırlık tahmin yapması beklenir. Bu durumdan farklı olarak çok sayıda girdi ve çok sayıda çıktının sınıflandırma işlevinde kullanıldığı yapay sinir ağları da araştırmalarda yer almaktadır.



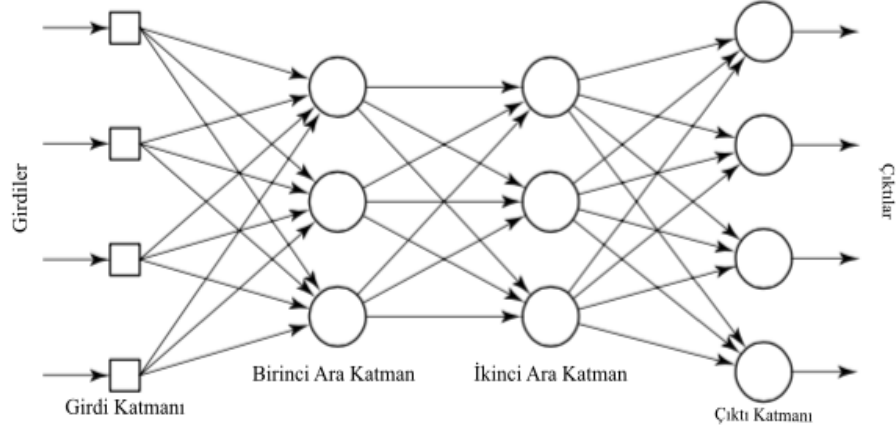
Şekil 3.18: Yapay Sinir Ağının Genel Görünümü.

Yapay sinir ağları sinir hücrelerinin bağlantı şekli ve bilginin akış yönüne göre ileri beslemeli ve geri beslemeli olarak iki farklı topolojide incelenmektedir.

İleri beslemeli ağlarda girdiler ve çıktılar arasında tek yönlü bir iletim söz konusudur. Herhangi bir geri bildirim veya iletim söz konusu değildir. İleri beslemeli ağlarda işlemci elemanlar tam bağlantılı katmanlara ayrılmışlardır. Girdi bilgileri ara katmanda ağırlıklarla birlikte işlendikten sonra ikinci ara katmana aktarılır. Benzer şekilde burada da işlendikten sonra çıktı katmanında da işleme tabi tutulur ve işleyiş sona erer. Bahsi geçen işleyişin yer aldığı yapay sinir tipi çok katmanlı ileri beslemeli ağlar olarak adlandırılır. Çok katmanlı algılayıcı ve LVQ (öğrenme vektör nitelendirilmesi) ağları ileri beslemeli ağların oldukça yoğun kullanılan örneklerindedir. Şekil 3.19 ve Şekil 3.20’de sırasıyla tek ve çok katmanlı ileri beslemeli ağların gösterimi yer almaktadır. İleri beslemeli ağlara örnek olarak çok katmanlı algılayıcı ve LVQ ağları verilebilir (Elmas 2011; Nabiyev 2003).



Şekil 3.19: Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları (Haykin, 2009).



Şekil 3.20: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları.

Geri beslemeli yapay sinir ağlarında, çıktılarından girdilere geri besleme döngüsü vardır. Bir başka ifade ile çıktı ve ara katmanlardaki çıktılar, giriş birimlerine veya önceki ara katmanlara geri besleme yapmaktadır. Böylelikle girdilerin ileri ve geri yönlü iletimi sağlanmış olmaktadır. Danışmansız öğrenme kurallarının kullanıldığı ağların yapısına uygundur. Bu ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir (Elmas, 2010; Nabiyev, 2003).

Yapay sinir ağlarında öğrenme kavramı, ağırlık ve sapmaların düzenlenmesi sürecidir. Dışarıdan gelen girdi bilgileri ağırlıklarda birikmektedir, bir başka ifade ile yapay sinir ağlarının zekasının saklı olduğu yerde depolanmaktadır. Öğrenme işlemi için birçok farklı öğrenme kuralı kullanılmaktadır. Bunların bir kısmı önceden tanınmış bazı eski kural yapılarının varyasyonu şeklindedir. Hebb öğrenme kuralı bu duruma örnek teşkil etmektedir ve 1950’li yıllardan günümüze bu konuda yapılan çeşitli çalışmalar bulunmaktadır. Bazı araştırmacılar ana hedefleri olarak biyolojik öğrenme modeline sahiptirler. Diğerleri ise doğanın öğrenmeyi nasıl ele aldığına dair görüşlerini deneylemektedirler. Yapay sinir ağlarında öğrenme, kullanılan öğrenme kuralları tarafından ortaya konan basitleştirmelerden daha karmaşık bir yapı arz etmektedir (Negnevitsky, 2005).

Yapay sinir ağları çıktı değerini üretme sürecinde bir çok farklı öğrenme kuralı kullanılabilir. Bu kuralların çoğu, temelde bilinen en eski kural olan Hebb kural yapısını kullanmaktadır. Literatürde en fazla karşılaşılan öğrenme kurallarından bazıları Hebb, Hopfield, Delta ve Kohonen kuralı olarak belirtilmiştir (Sumathi ve Suretha, 2010; Elmas, 2011).

Hebb kuralı, 1949 yılında Donald Hebb tarafından geliştirilmiştir. En eski ve en iyi bilinen kural yapısıdır. Danışmansız öğrenme gerçekleştiren sinir ağlarında kullanılmaktadır. Hebb kural yapısına göre “Eğer bir sinir hücresi bir başka sinir hücresinden girdi alıyorsa ve her iki sinir hücresi aktif ise (matematiksel açıdan aynı işareti taşıyorlarsa) iki sinir hücresi arasında var olan bağlantı kuvvetlendirilir” (Sumathi ve Suretha, 2010). Eğitilen sinir ağı için kurallar cebirsel formulasyon ile ifade edilir. Hebb kural yapısı Eşitlik 3.152’de yer almaktadır.

$$\Delta w_{ij} = \mu \alpha_i \alpha_j \quad (3.152)$$

Eşitlik 3.152’de yer alan formül, i’inci nöron ile j’inci nöron arasındaki bağlantı ağırlıklarında gerekli değişikliği (Δ) hesaplamaktadır. Formülde μ öğrenme oranını temsil eder. Nöronlara ilişkin aktivasyon α_i ve α_j olarak verilmiştir (Sumathi ve Suretha, 2010).

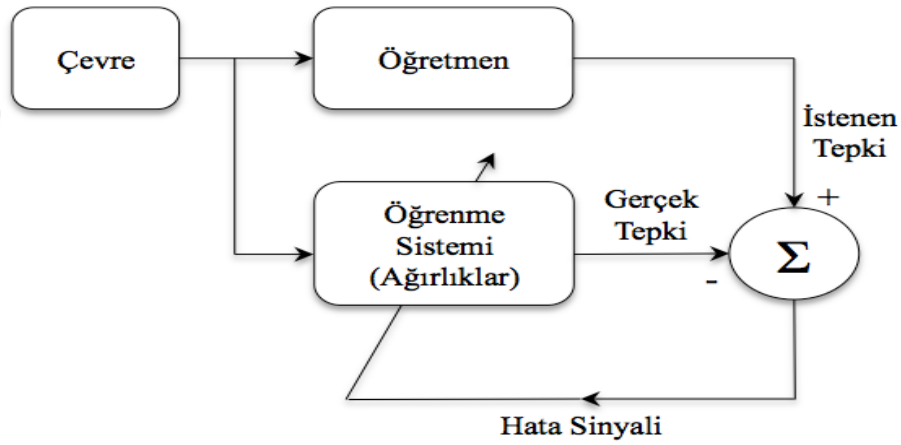
Hopfield kuralı, Hebb kural yapısına oldukça benzerdir ancak bağlantıların kuvvetlendirilmesi veya zayıflatılmasına ilişkin işareten başka miktarını da değiştirmektedir. Bu işlev öğrenme oranı aracılığı ile gerçekleştirilir. Örneğin istenen girdi ve çıktının her ikisinin de işaretleri aynı bir başka ifade ile aktif veya pasif ise öğrenme oranı (η) kadar artırılır (kuvvetlendirilir) veya azaltılır (zayıflatılır). Öğrenme oranı sıfır ve bir arasında araştırmacı tarafından belirlenir (Şen, 2004).

Delta kuralı, temelde Hebb kural yapısına dayanan ve günümüzde en fazla kullanılan kural tiplerinden biridir. Delta kuralında amaç gerçek çıktı değerleri ile yapay sinir ağı çıktı değerleri arasındaki farkın en aza indirgenmesi için bağlantı ağırlıklarının değiştirilmesidir.

Kohonen Kuralı, danışmansız öğrenme gerçekleştiren ağ yapıları için uygundur. Kazanan hepsini alır veya rekabetçi öğrenme kavramlarını esas alarak çalışmaktadır. Yapay sinir ağının nöronları arasındaki rekabet veya yarış sonucunda en büyük değere sahip olan hücre kazanmakta ve ağırlığını değiştirmektedir. Kazanan hücre çıktısını vermektedir ancak ağırlık değişimine hem kendisi hem de komşu olan hücreler dahil olmaktadır.

Yapay sinir ağları danışmanlı, danışmansız ve takviyeli olmak üzere üç farklı öğrenme stratejisine göre tasarlanabilmektedir. Karşılaşılan problem yapılarının farklılığına göre çeşitli yapay sinir ağı modelleri geliştirilmiştir. Geliştirilen yapay sinir ağı modelleri farklı öğrenme kuralları ve stratejilerine sahip olabilmektedir.

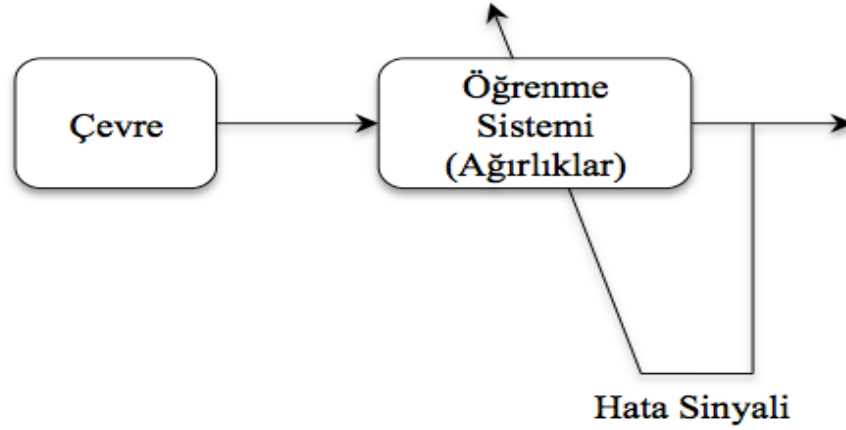
Danışmanlı öğrenme stratejisinde, yapay sinir ağına hem girdi hem çıktıya ilişkin bilgiler sağlanmaktadır. Ağ girdileri işledikten sonra elde edilen ve istenilen çıktıları karşılaştırır. Ortaya çıkan hatalar sistem üzerinden geri yayılır ve ağırlıkların ayarlaması sağlanır. Danışmanlı öğrenme stratejisinde verilerin eğitiminin gerçekleştiği veri seti eğitim setidir. Ağın eğitimi boyunca aynı veri seti pek çok defa döngüsel olarak hatayı minimize edecek şekilde işlenir. İşlemci elemanların bağlantı ağırlıkları en uygun çıktıyı elde etmek üzere sonradan düzenlenebilir. Yapay sinir ağlarına girdi ve çıktı bilgilerinin doğru şekilde sunulması oldukça önemlidir. Bilgilerin doğruluğu sinir ağının işlevini doğru şekilde yapmasını sağlar, dolayısı ile ortaya çıkacak analiz sonuçlarının da başarısı artar. Bunun için ham veriler doğrudan sunulabileceği gibi kodlanabilir veya ölçeklendirilebilir. Literatürde bununla ilgili çeşitli yöntemler mevcuttur. Çok katmanlı algılayıcı danışmanlı öğrenme stratejisine göre çalışan ağ yapısına örnek teşkil etmektedir. Danışmanlı öğrenme algoritmalarına örnek olarak delta kuralı ve genelleştirilmiş delta kuralı, geri yayılım algoritması, eğim iniş algoritması verilebilir. Şekil 3.21’de danışmanlı öğrenme yapısının şekilsel gösterimi yer almaktadır.



Şekil 3.21: Danışmanlı Öğrenme Yapısı (Haykin, 1999).


Danışmansız öğrenme stratejisinde, danışmanlı öğrenmenin aksine dışarıdan bir öğretmene ihtiyaç duyulmaz. Eğitim sürecinde, yapay sinir ağı bir miktar farklı girdi deseni alır, bu desenlerde önemli özellikler keşfeder ve uygun kategoriler halinde girdi verilerini nasıl sınıflandıracağını öğrenir. Ağın girdi verilerine ait istatistiksel düzenlemeler ayarlanır, girdi özelliklerinin kodlanmasını sağlayan temsilleri oluşturma yeteneğini geliştirir. Böylece otomatik olarak yeni sınıflar oluşturulur (Haykin, 1999). Danışmansız öğrenme stratejisinde, bilgiler sinir ağına girdiler kullanılarak sağlanır ancak istenilen çıktılara ait bilgiler olmadan bu işlem gerçekleşir. Sinir ağı ağırlıkları sadece girdi bilgilerine göre

ayarlar. Bu özellik kendini örgütlenme veya adaptasyon olarak adlandırılmaktadır. Kohonen, ART (Adaptive Resonance Theory) ve Som (Self Organizing Map) örnek mimariler olarak bilinmektedir. Şekil 3.22’de danışmansız öğrenme yapısı yer almaktadır. Danışmansız öğrenme stratejisinde rekabete dayalı öğrenme kuralı, Hebbian öğrenme kuralı ve Kohonen kuralı kullanılabilir.



Şekil 3.22: Danışmansız Öğrenme Yapısı (Elmas, 2011).

Takviyeli öğrenme stratejisi danışmanlı öğrenmeye benzerlik göstermektedir ancak burada dışarıdan bir destek söz konusudur. Ara katmanda yer alan nöronlar arasındaki bağlantılar rastgele olacak şekilde düzenlenmiştir. Bu öğrenme stratejisinde çıktı bilgileri bulunmamaktadır ancak problemin çözümüne ne kadar yakın olduğunun bilinmesi için bir iyileştirme kriteri bulunmaktadır. Bir başka ifade ile hedef çıktı yerine, ağız üretmiş olduğu çıktının doğru veya yanlışlığını değerlendirebilmek adına derecelendirme ile işlemler devam etmektedir. Takviyeli öğrenme bazı kaynaklarda danışmanlı öğrenme kapsamında değerlendirilmektedir. Danışmanlı öğrenmeye benzer şekilde bir öğretici bulunur ancak istenen çıktıya ilişkin bilgilere yer verilmez, sadece hesaplanan çıktının doğru veya yanlışlığı ile ilgili bilgiler sunulur. Bu bilgiler ağız öğrenme sürecinde yardımcı olmaktadır. Şekil 3.23’de takviyeli öğrenme yapısına ilişkin görünüm yer almaktadır. LVQ (Learning Vector Quantization) ağızları takviyeli öğrenme stratejisine göre çalışan ağız yapılarından birisidir.



Şekil 3.23: Takviyeli Öğrenme Yapısı (Haykin, 1999).

Tek katmanlı algılayıcı modellerinden basit algılayıcı (perceptron) modeli, danışmanlı öğrenme stratejisi ile çalışan ilk yapay sinir ağı modelidir. Frank Rosenblatt tarafından 1958 yılında geliştirilen basit algılayıcı modeli, 1960'lı yıllarda öğrenme ve basit örüntüleri tanımlama yeteneklerinden dolayı bilim çevrelerinde oldukça ilgi uyandırmıştır (Rosenblatt, 1962). Basit algılayıcı modeli girdi ve çıktı katmanı olmak üzere iki katmandan oluşmaktadır. Dışarıdan gelen bilgiler girdi katmanı ile alınır ve çıktı katmanına gönderilir. Ağıın çıktısı sıfır veya bir olmaktadır. Basit algılayıcı modeli tek bir nörondan oluşmaktadır ve hesaplamalar bu nöronda gerçekleşmektedir. Bunun yanı sıra sinaptik ağırlıklar ve aktivasyon fonksiyonu mevcuttur. Çıktı değerleri eşik değer fonksiyonu ile elde edilir. Burada eşik değeri (θ), aktivasyon fonksiyonunun konumunu belirtmek amacıyla kullanılmaktadır. İşleyiş prosedürü eşik değerinin girdilerin ağırlıklı toplamları ile karşılaştırılması ile gerçekleşir. Burada çıktı değeri, girdilerin ağırlıklı toplamı eşik değerinden büyük ise bir; küçük ise sıfır şeklinde belirlenmektedir. Basit algılayıcı modelin çalışma prensibinin temel ilkesi yanlış sınıflandırma sayısını azaltmak amacıyla ağırlıkların düzenlenmesidir (Mehrotra ve diğ. 1997).

x_i girdi değeri, w_i ağırlık değeri ($i = 1, \dots, n$); θ eşik değeri ve y çıktı değeri olmak üzere basit algılayıcı modelinin işleyişi dört aşamada gerçekleşmektedir. Bu aşamalar şu şekilde özetlenmiştir:

Adım 1: Birinci adım başlatmadır. Girdi veya girdilere karşılık gelen çıktı tanımlanır. Burada girdiler bir veya birden fazla olabilmektedir ancak çıktı bir ve sıfır değerlerinden birisini almaktadır.

Adım 2: İkinci adım aktivasyon aşamasıdır. Burada girdiler ve istenen çıktı tarafından basit algılayıcı aktive edilir, net girdi Eşitlik 3.153'de yer alan matematiksel ifade ile hesaplanır.

$$NET\ Girdi = \sum_{i=1}^n w_i x_i \quad (3.153)$$

Adım 3: Adım 3'de ağırlıklar ile ilgili düzenlemeler yapılmaktadır. Bunun için öncelikle çıktı değeri hesaplanır ve net girdi ile belirlenen eşik değeri karşılaştırılır. Bu durumun matematiksel ifadesi Eşitlik 3.154'de yer almaktadır.

$$y = \begin{cases} 1 & \text{Eğer } NET\ Girdi > \theta \\ 0 & \text{Eğer } NET\ Girdi \leq \theta \end{cases} \quad (3.154)$$

y çıktı değerinin gerçek değeri ile beklenen çıktı aynı olduğu takdirde ağırlıklarda herhangi bir değişiklik söz konusu değildir. Ancak çıktı beklenen durumdan farklı olduğunda ağırlıklar λ öğrenme katsayısı ve girdiler kullanılarak artırılabilir ($w_n = w_0 + \lambda x$) veya azaltılabilir ($w_n = w_0 - \lambda x$).

Adım 4: Basit algılayıcı modelinin işleyişinin son aşaması iterasyondur. Burada sınıflandırma tüm veri seti için doğru şekilde gerçekleşene kadar ilk üç adımda yer alan işlemler tekrarlanır.

Yapay sinir ağlarının tek katmanlı algılayıcı modellerinden Adaline (Adaptive Linear Element) ve Madaline (Multiple Adaline) bir diğer önemli ağ yapılarıdır. Bernie Widrow tarafından 1960 yılında geliştirilen Adaline modelinin mimarisi basit algılayıcı model ile oldukça benzerdir (Widrow, 1962). Ağırlıkların eğitimi safhasında en küçük kareler yöntemi kullanılmaktadır. Adaline modelinde öğrenme Eşitlik 3.155'de yer alan ifadeler ile gerçekleşmektedir.

$$NET = \sum_{i=1}^n w_i x_i + \theta$$

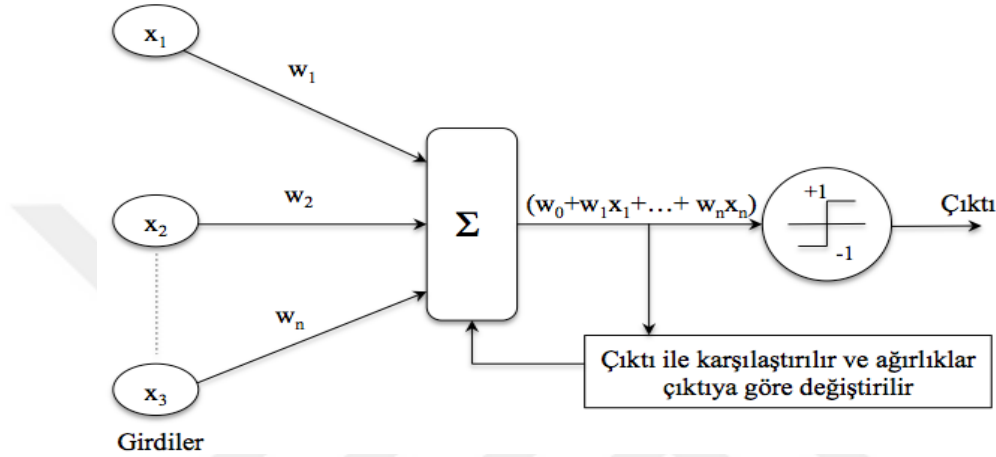
$$NET = \emptyset + w_1 x_1 + w_2 + \dots + w_n x_n \quad (3.155)$$

$$Çıktı\ (y) = \begin{cases} 1 & \text{Eğer } NET \geq 0 \\ -1 & \text{Eğer } NET < 0 \end{cases}$$

Adaline y çıktısını ürettikten sonra hata miktarı beklenen (B) ve gerçekleşen çıktı (y) değerlerinin farkı alınarak hesaplanır. Ağırlıklar değiştirilerek bu hatanın minimum olması


istenir. Basit algılayıcı modeline benzer şekilde öğrenme katsayısı (α) ve girdiler (x) ile oluşturulan Eşitlik 3.156'da yer alan kural aracılığı ile hatanın azaltılması sağlanır. Burada çıktı step fonksiyonu ile üretilir. Adaline modelinin genel görünümü Şekil 3.24'de yer almaktadır.

$$w_y = w_e + \alpha(B - y)x \quad (3.156)$$



Şekil 3.24: Adaline Yapısı.

Madaline ise tek bir ağ içinde birden fazla adaline modelinin kombinasyonundan oluşan yapıdır. Adaline ile aynı öğrenme kuralını kullanmaktadır. Madaline yapısında yer alan Adaline modelleri birbirine “ve - veya” (AND- OR) operatörleri ile bağlanmaktadır. Madaline genel görünümü Şekil 3.25'de yer almaktadır.



Şekil 3.25: Madaline Yapısı.

Minsky ve Papert (1969) tarafından yayınlanan çalışmada tek katmanlı algılayıcıların bazı sınırlamalarına dikkat çekilmiştir. Araştırmacılar tek katmanlı algılayıcıların sadece doğrusal ayrılabilen fonksiyonları çözümlenebildiğini belirtmiştir. XOR problemi günlük

hayatta karşılaşılan ve doğrusal olmayan nitelikte çeşitli problemleri temsil etmektedir. Tek katmanlı algılayıcılar XOR problemini çözümlenemede yetersiz kalmaktadır. Bu durum yapay sinir ağları ile ilgili yapılan çalışmaların bir süre yavaşlamasına neden olmuştur. Bu sınırlamanın ötesine geçebilmek amacıyla tek katmanlı algılayıcılara ilişkin çalışmalar 1980’li yıllara gelindiğinde gelişim göstermiş ve yapay sinir ağları çalışmaları çok katmanlı algılayıcıların ortaya çıkması ile birlikte hız kazanmıştır (Graupe, 2013).

Çok Katmanlı Algılayıcı Modeli

Çok katmanlı algılayıcı modeli ileri beslemeli topolojiye sahiptir, girdi sinyalleri katmandan katmana ileri doğru yayılmaktadır. Çok katmanlı algılayıcılar girdi katmanı, ara katman ve çıktı katmanından oluşmaktadır. Yapısında bir veya birden fazla ara katman bulunabilmektedir. Her katman kendine özgü bir fonksiyona sahiptir. Girdi katmanı dış dünyadan gelen girdi sinyallerini kabul eder ve bu sinyalleri gizli katmandaki tüm nöronlara tekrar dağıtır. Çıktı katmanı gizli katmandan çıktı sinyallerini kabul eder ve tüm ağın çıktı desenini oluşturur. Gizli katmandaki nöronlar girdi desenlerindeki özellikleri belirler ve işler. Gizli katman istenen çıktıları içinde barındırır. Gizli katmanda yer alan nöronlar sinir ağının girdi-çıkıtı davranışı aracılığı ile gözlenememektedir. Yapay sinir ağı içindeki gizli katman sayısı ve bu katmanlar içinde yer alan nöron sayılarının ideal değerinin ne olması gerektiğine ilişkin kesin bir bilgi bulunmamaktadır.

Çok katman algılayıcı modelinin öğrenme sürecinde günümüzde onlarca öğrenme algoritması kullanılabilir. Bunların içerisinde geri yayılım algoritması araştırmalarda yoğun şekilde yer almakta ve geniş bir uygulama alanına sahip olmaktadır. Geri yayılım algoritmasına ilişkin ilk çalışmalardan bir tanesi 1969 yılında Bryson ve Ho tarafından önerilmiştir (Bryson ve Ho, 1969) ancak o yıllarda hesaplama zorluklarından dolayı göz ardı edilmiştir. 1980’li yıllara gelindiğinde teknolojik gelişmelerin artması ve yapay sinir ağları çalışmalarının hız kazanması ile geri yayılım algoritması tekrar kullanılmaya başlanmıştır.

Çok katmanlı algılayıcı modelinin öğrenme süreci perseptrona benzer şekilde işlemektedir. Yapay sinir ağlarında geri yayılım algoritmasının işleyişi ileri ve geriye doğru hesaplama olmak üzere iki aşamada gerçekleşmektedir. Öncelikle girdi desenine ilişkin bir eğitim seti sinir ağına sunulur. Çıktı deseni, çıktı katmanı tarafından üretilinceye kadar sinir ağı girdi desenini katmandan katmana yayar. Sonraki aşamada istenen çıktı ile gerçek çıktı arasında bir farklılık diğer bir deyişle hata hesaplanır. Hata kareler toplamını en aza indirmeyi

amaçlayan geri yayılım algoritmasında hatanın çıktı katmanından girdi katmanına doğru geri yayılımı gerçekleştirir. Söz konusu hata geri yayılarak ağırlıklar ayarlanır. Hatanın minimize edilme sürecinde eğim iniş yöntemi kullanılır.

Geri yayılım algoritması eğitim sürecinde delta kuralı ve genelleştirilmiş delta kuralını kullanmaktadır. Delta kuralının işleyiş süreci tek katmanlı bir yapay sinir ağı üzerinden anlatılmıştır. i 'inci nöron çıkışı Eşitlik 3.157'de ifade edilmektedir. Burada n girdi nöronu, m ise çıktı nöronu sayısını temsil eder.

$$y_i = (w_i, x) = w_{i1}x_1 + \dots + w_{in}x_n \quad (3.157)$$

$$i = 1 \dots m$$

Sinir ağında K , eğitim setinde yer alan girdi-çıkış çifti sayısını göstermek üzere, $\{(x^1, x^1), \dots, (x^K, x^K)\}$ şeklinde ifade edildiğinde; sinir ağının toplam hata miktarı (E) Eşitlik 3.158'de yer alan ifade ile elde edilir. Burada b_i i 'inci çıkış nöronunun beklenen çıkış değerini; h_i hesaplanan çıkış değerini, k eğitim çifti sırasını, temsil etmektedir.

$$E = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^m (b_i - h_i)^2 \quad (3.158)$$

Hatanın minimize edilmesi ve ağırlıkların düzenlenmesi sürecinde eğim iniş yöntemi kullanılmaktadır. Burada hatanın ağırlıklara göre kısmi türevlerinin alınması, ağırlıkların düzenlenmesi işlemi tanımlamaktadır. Bu durumun matematiksel ifadesi Eşitlik 3.159'da yer almaktadır. Burada η öğrenme sabitidir ve sıfırdan büyük bir değer almaktadır.

$$w_{ij} = w_{ij} + \eta \frac{\partial E_k}{\partial w_{ij}} \quad (3.159)$$

$$\frac{\partial E_k}{\partial w_{ij}} = \frac{\partial E_k}{\partial y_i} \frac{\partial y_i}{\partial w_{ij}} = -(b_i - h_i)x_i$$

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

Delta kuralı kullanılarak elde edilen yeni ağırlık değerleri Eşitlik 3.160'daki gibidir (Kınacı, 2006; Elmas, 2011).

$$w_{ij} = w_{ij} + \eta (b_i - h_i)x_i \quad (3.160)$$

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

Delta kuralının işleyişinde amaç beklenen ve hesaplanan çıktı arasındaki farkı en aza indirmek için ağırlıkları düzenlemektir. Delta kuralı literatürde Widrow- Hoff kuralı olarak da adlandırılmaktadır. Delta kuralının kullanılmasında eğitim girdi setinin tamamen şansa bağlı şekilde hazırlanması büyük önem taşımaktadır. Sıralı veya araştırmacı tarafından yapılandırılmış veri setleri sinir ağında bazı öğrenme problemlerine yol açabilmektedir. Delta öğrenme kuralının işleyişi şu şekilde özetlenebilir:

Adım 1: Öğrenme sabiti ($\eta > 0$) ve toplam hata ($E_{max} > 0$) belirlenir.

Adım 2: $k = 1$ ve $E = 0$ olmak üzere ağırlık değerlerine olabildiğince düşük değerler atanır.

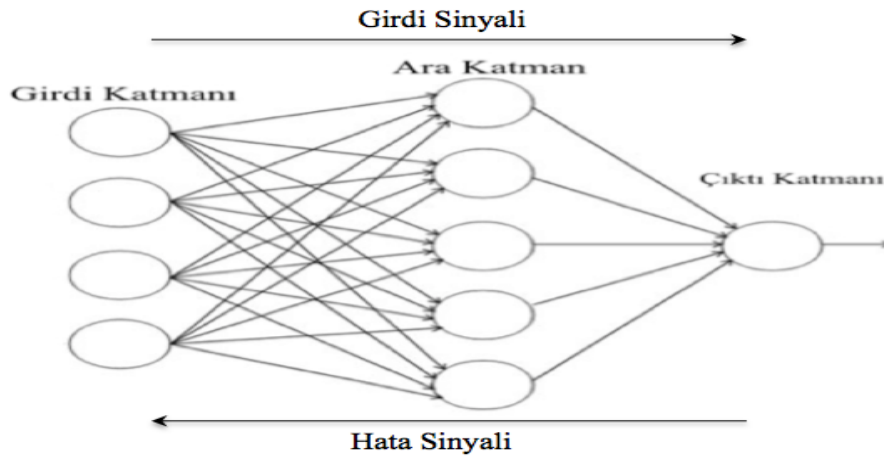
Adım 3: Sistem çıkışı (y_i) hesaplanır. $y_i(x) = w_i x$, $i = 1, \dots, m$

Adım 4: İşlem sürecinde gerçekleşen hata değerleri toplanarak toplam hata değeri elde edilir. $E = E + 1/2 (b_i - h_i)^2$

Adım 5: $k < K$ ise $k = k + 1$ şeklinde belirlenir ve üçüncü adımdan itibaren işlemler tekrar edilir.

Adım 6: Sonuncu adıma gelindiğinde $E < E_{max}$ ise ağırlıklar daha fazla değişikliğe uğramaz ve böylece eğitim işlemi sonlanmış olur. Aksi durumda tekrar $E = 0$ olarak kabul edilir ve üçüncü adımdan itibaren eğitim işlemi yinelenir (Elmas, 2011).

Genişletilmiş delta kuralı, delta kuralının geliştirilmiş halidir. Çok katmanlı algılayıcılar öğrenme sürecinde bu kural yapısını kullanmaktadır. Çok katmanlı ileri beslemeli geri yayımlı yapay sinir ağının genel görünümü Şekil 3.26'da yer almaktadır.



Şekil 3.26: Çok Katmanlı İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağının Şekilsel Gösterimi.

Geniştirilmiş delta kuralının işleyişi temelde iki aşamalı olarak sürmektedir. Birincisi ileriye doğru hesaplama, ikincisi ise geriye doğru hesaplama. İleriye doğru hesaplama, eğitim setinde yer alan verilerin girdi katmanına sunulması ve gizli katmana gönderilmesi ile başlar ve sonrasında net girdi hesaplanır. Girdi katmanındaki nöron sayısı k ve gizli katmandaki nöron sayısı j olmak üzere, k . nöronun çıktısı ζ_k ve ağırlık değeri w_{kj} ile temsil edilmektedir. Net girdi (Net) Eşitlik 3.161'deki gibi ifade edilir.

$$Net_j^a = \sum_{k=1}^n w_{kj} \zeta_k \quad (3.161)$$

Elde edilen net girdi aktivasyon fonksiyonundan geçirilir ve böylece gizli katmandaki nöronun çıktısı hesaplanmış olur. Burada sigmoid aktivasyon fonksiyonu ele alınmıştır. Çıktı Eşitlik 3.162'deki gibi ifade edilmektedir. Eşitlik 3.162'de yer alan ifadede β_j gizli katmanda yer alan nörona bağlanan eşik değer elemanının ağırlığını ifade etmektedir (Öztemel, 2003).

$$\zeta_j = \frac{1}{1 + e^{-(Net_j^a + \beta_j^a)}} \quad (3.162)$$

Gizli katman ve çıktı katmanında bulunan nöronların net girdilerinin hesaplanması ve aktivasyon fonksiyonundan geçirilmesi sürecinden sonra çıktı katmanını çıktılarının elde edilmesi ile ileri hesaplama aşaması sona ermiş olur. Bu noktada yapay sinir ağı çıktıları ile beklenen çıktılar arasındaki fark hesaplanır. Hata olarak nitelendirilen bu farklılığın en aza indirgenmesi amacıyla geriye doğru sinir ağının ağırlık değerlerine dağıtılır. Gerçekleştirilen her iterasyonda bu farklılığın azaltılması beklenir. Çıktı katmanında yer alan m . nöronun hesaplanan ve beklenen çıktısı arasındaki farklılık E_m olarak ifade edildiğinde çıktı katmanının toplam hatası (TH) Eşitlik 3.163'deki gibi ifade edilmektedir (Öztemel, 2003).

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (3.163)$$

Gizli katmanın diğer katmanlar ile arasında var olan ağırlıkların değiştirilmesi ile toplam hatayı en aza indirmek amaçlanır. Gizli katmanda yer alan j . nöron ile çıktı katmanında yer alan m . nöron arasındaki bağlantı ağırlığındaki değişim ΔA^a olarak ifade edildiğinde t . iterasyonda gerçekleşen değişim miktarı Eşitlik 3.164'deki gibi hesaplanabilmektedir. Eşitlikte λ öğrenme katsayısı, α momentum katsayısını temsil etmektedir.

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j + \alpha \Delta A_{jm}^a(t-1) \quad (3.164)$$

δ_m çıktı katmanında yer alan m . çıktı ünitesinin hatasıdır. Eşitlik 3.165'deki gibi hesaplanmaktadır. $f'(Net)$ kullanılan aktivasyon fonksiyonunun türevini temsil eder.

$$\delta_m = f'(Net) E_m \quad (3.165)$$

Eşitlik 3.164 ve 3.165'deki ifadeler yardımı ile toplam değişim miktarı hesaplanmış olur. t . iterasyonda ağırlıkların yeni değeri Eşitlik 3.166'de yer alan ifade ile elde edilebilmektedir.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.166)$$

Son olarak bağlantı ağırlıklarına benzer şekilde eşik değer ünitesinin ağırlık değerindeki değişim Eşitlik 3.167'de yer alan ifade ile elde edilmektedir. t . iterasyonda ağırlığın yeni değeri Eşitlik 3.168'de yer almaktadır.

$$\Delta \beta_m^c(t) = \lambda \delta_m + \alpha \Delta \beta_m^c(t-1) \quad (3.167)$$

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t) \quad (3.168)$$

Girdi katmanı ve gizli katman arasındaki bağlantı ağırlıklarının değişimi incelenecek olursa; değişim miktarı Eşitlik 3.169'daki gibi ifade edilir. Eşitlikte yer alan δ_j^a hata terimi Eşitlik 3.170'de yer alan ifade ile hesaplanmaktadır.

$$\Delta A_{km}^i(t) = \lambda \delta_j^a \zeta_k + \alpha \Delta A_{kj}^i(t-1) \quad (3.169)$$

$$\delta_j^a = f'(Net) \sum_m \delta_m A_{jm}^a \quad (3.170)$$

Girdi katmanı ve gizli katman arasındaki bağlantı ağırlıklarına ilişkin yeni değer Eşitlik 3.171'deki gibi hesaplanmaktadır.

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta i(t) \quad (3.171)$$

Eşik değer ünitesinin ağırlık değerindeki değişim Eşitlik 3.172'de; t . iterasyonda ağırlığın yeni değeri Eşitlik 3.173'de yer almaktadır (Öztemel, 2003).

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1) \quad (3.172)$$

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (3.173)$$

Genelleştirilmiş delta kuralının işleyişi her bir örnek için ileri ve geriye doğru hesaplamaların yapılması ile tamamlanmış olur.

Geri yayılım algoritmasının işleyişi aşağıdaki gibi özetlenebilir:

Adım 1: Başlangıç aşamasında ağırlık ve eşik değerlere rastgele sayılar atanır. Sıfır ve bir arasında öğrenme katsayısı belirlenir.

Adım 2: İleriye doğru hesaplama bu aşamada başlamaktadır. Sinir ağının eğitim verileri için bundan sonraki adımlar gerçekleştirilir. Aktivasyon aşaması ikinci aşamadır. Burada gizli katmanda yer alan nöronların ağırlık toplamları hesaplanır aktivasyon fonksiyonundan geçirilir ve çıktı katmanına iletilir. Çıktı katmanındaki nöronlar için aynı işlem gerçekleştirilir. Bunun için genellikle sigmoid aktivasyon fonksiyonu kullanılır.


Adım 3: Bu aşamada geriye doğru hesaplamalar başlamaktadır. Geri yayılım ağında ağırlıklar güncellenir, çıktı nöronları ile ilişkili hatalar geri yayılır.

Adım 4: Hata kriteri (hata kareler toplamı) uygun seviyeye gelinceye kadar ikinci adımdan itibaren iterasyona devam edilir.

Hata kareler toplamı sinir ağlarının performans değerlendirmesinde oldukça kullanışlı bir göstergedir. Geri yayılım algoritması bu kriteri en aza indirmeyi amaçlar.

Geri Dönüşümlü Ağlar- Hopfield Ağı

Geri dönüşümlü ağlar 1960 ve 1970'li yıllarda birçok araştırmacının ilgisini çekmiştir ancak ağ tahminlerinin durağan olması ile ilgili bazı olumsuz düşünceler de bulunmaktaydı. Bu problem 1982 yılında ünlü fizikçi John Hopfield isimli bilim insanı tarafından çözümlenmiştir. Hopfield bilgi depolamanın fiziksel prensibini formülize etmiştir (Hopfield, 1982).



Şekil 3.27: Tek Katmanlı n Nöronlu Hopfield Ağı (Negnevitsky, 2005).

Hopfield ağı geri beslemeli ağ yapısındadır ve optimizasyon problemlerinin çözümünde kullanılmaktadır. Şekil 3.27’de tek katmanlı n adet nörona sahip Hopfield ağı görülmektedir. Her nöronun çıktısı diğer tüm nöronların girişlerine geri beslenir. Bir başka ifade ile diğer nöronlara girdi olarak dağıtılır.

Kesikli ve sürekli olmak üzere iki tip Hopfield ağı bulunmaktadır. Kesikli Hopfield ağı hesaplamalarında McCulloch ve Pitts tarafından geliştirilen nöron ile sign aktivasyon fonksiyonunu kullanır. Hücreler ikili mantık çerçevesinde çalışır. Eğer ağırlıklı nöron sıfırdan küçükse çıktı “-1”; sıfırdan büyükse “+1” değerini almaktadır. Eğer ağırlıklı nöron girişi sıfıra eşitse çıktı değişmeden kalır, önceki halini korur. Bu durumun matematiksel gösterimi Eşitlik 3.174’de yer almaktadır (Negnevitsky, 2005). Burada Y çıktısı ifade etmektedir.

$$Y^{sign} = \begin{cases} +1, & \text{Eğer } X > 0 \\ -1, & \text{Eğer } X < 0 \\ Y, & \text{Eğer } X = 0 \end{cases} \quad (3.174)$$

Hopfield ağının t gibi bir zamanda girdisi G_i^t Eşitlik 3.175’de yer almaktadır. Burada A bağlantı ağırlık değerini, θ eşik değer sabitini $Y(t - 1)$ nöronun bir önceki zamanda çıktısını göstermektedir. Nöron çıktısı $Y(t)$ ise Eşitlik 3.176’daki gibi hesaplanmaktadır (Haykin, 1999).

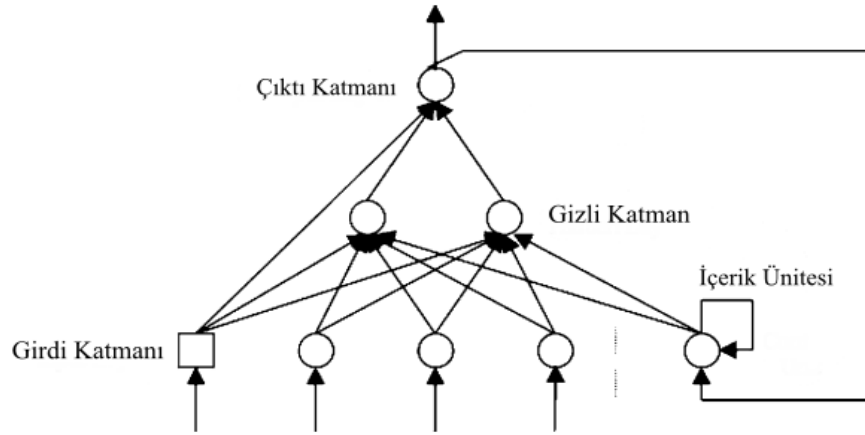
$$G_k(t) = \sum_{j \neq k}^n A_{jk} Y_j(t - 1) - \theta_k \quad (3.175)$$

$$Y_t = \text{sgn}(G(t)) \quad (3.176)$$

Sürekli Hopfield ağında ise sign aktivasyon fonksiyonu yerine sigmoid aktivasyon fonksiyonu kullanılır. Böylece nöron çıktı değeri “0-1” arasında sürekli değerler almaktadır (Hopfield ve Tank, 1985).

Geri Dönüşümlü Ağlar- Jordan Ağı

Jordan ağları ilk geri dönüşümlü sinir ağlarından birisi olarak bilinmektedir. Jordan ağı Şekil 3.28’de görüleceği üzere girdi katmanı, gizli katman, çıktı katmanı ve içerik ünitelerinden oluşmaktadır. Çıktı katmanında üretilen çıktıların aktivasyon değerleri içerik ünitesi olarak adlandırılan ekstra girdi üniteleri ile girdi katmanına geri beslenir. Çıktı ve içerik ünitesi arasındaki bağlantı ağırlığı değeri sabittir ve “+1” olarak belirlenmektedir (Kröse ve Smagt, 1996). Öğrenme süreci çok katmanlı algılayıcıda kullanılan öğrenme kuralları ile gerçekleşir.

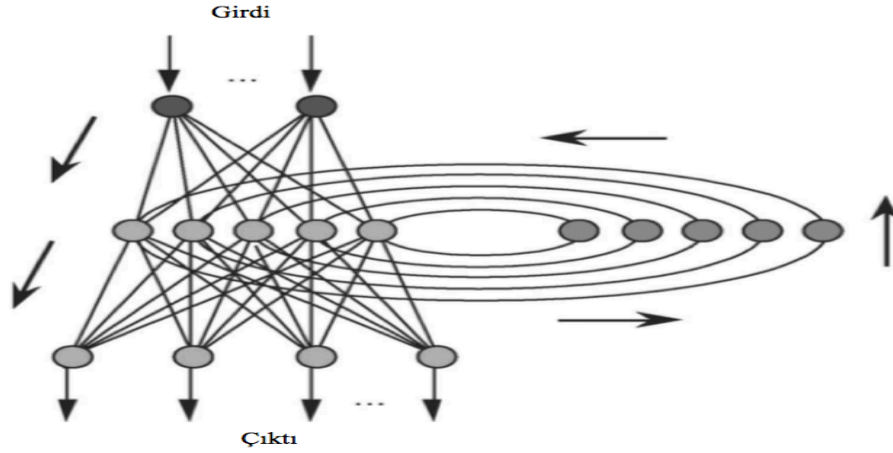


Şekil 3.28: Jordan Ağı Yapısı (de Mulder ve diğ., 2015).

Geri Dönüşümlü Ağlar- Elman Ağı

Elman ağı geri beslemeli ağ yapısına sahip çok katmanlı yapay sinir ağı modellerinden birisidir. Elman ağı ilk olarak 1990 yılında Elman tarafından tanıtılmıştır (Elman, 1990). Elman ağı çok katmanlı algılayıcıdan gizli katmanda yer alan nöron çıktılarının tekrar girdi katmanına geri dönüştürülmesi yönüyle farklılık göstermektedir. Elman ağında bir dizi içerik katmanı tanımlanmaktadır. İçerik katmanı geri besleme katmanı olarak da adlandırılmaktadır. Bu katman ağın çalışma sırasında zamanla değişen koşullara uyum sağlamasına izin verir. İçerik katmanı gizli katmandan geri beslenen aktivasyon değerlerine sahiptir ve ekstra girdi katmanı niteliğindedir. Bu aktivasyon değerleri içerik elemanlarına girdi olarak gönderilmektedir. Bu yönüyle Jordan ağına benzerlik göstermektedir. Jordan ağından ayrıldığı iki nokta şunlardır: Birincisi Elman ağı gizli

katman üzerinden, Jordan ağı ise çıktı katmanını üzerinden geri beslenmektedir, ikincisi ise ekstra girdi katmanını kendi öz bağlantısına sahip değildir. Elman ağı zamanda gecikmeleri kullandığından zaman serisi analizlerinde kullanılmaktadır (Liu ve diğ. 2018). Şekil 3.29’da Elman ağına ilişkin şekilsel gösterim yer almaktadır.



Şekil 3.29: Elman Ağı Gösterimi (Priddy ve Keller, 2005).

Elman ağında eğitim süreci çok katmanlı algılayıcılarda olduğu gibi genelleştirilmiş delta kuralı ile sağlanır. Elman ağında net girdi gizli katmandan gelen geri beslemelere göre hesaplanır. Bu durumun matematiksel gösterimi; N girdi sayısı, M ara katmandaki eleman sayısı olmak üzere Eşitlik 3.177’de yer almaktadır.

$$Net_i(k) = \sum_{j=1}^N A_{ji}^g u(k) + \sum_{i=1}^M A_{ij}^i x(k-1) \quad (3.177)$$

Eşitlik 3.177’de girdi katmanındaki elemanın girdi değeri u , girdi katmanı ve gizli katman arasındaki bağlantı ağırlığı A^g ; gizli katman ile içerik katmanı arasındaki bağlantı ağırlığı A^i ; gizli katman elemanının çıktısı x ; k ise zaman dilimini temsil etmektedir. Bu aşamada genelleştirilmiş delta kuralının çalışma prensibi uyarınca işlemci elemanların çıktıları ve ağırlıklarındaki değişim miktarı belirlenir. Net girdi hesaplandıktan sonra çıktı katmanında yer alan j . elemana ilişkin çıktı değeri Eşitlik 3.178’deki gibi hesaplanmaktadır. Burada A^a gizli katman ile çıktı katmanını arasındaki bağlantı elemanının ağırlık değerini temsil etmektedir.

$$y_j(k) = \sum_{i=1}^M A_i^a(k) x_i(k) \quad (3.178)$$

Elman ağında hata Eşitlik 3.179’deki gibi hesaplanmaktadır. Burada E_j hesaplanan hata miktarı, B beklenen çıktıyı ve $y_j(k)$ hesaplanan çıktıyı temsil eder.

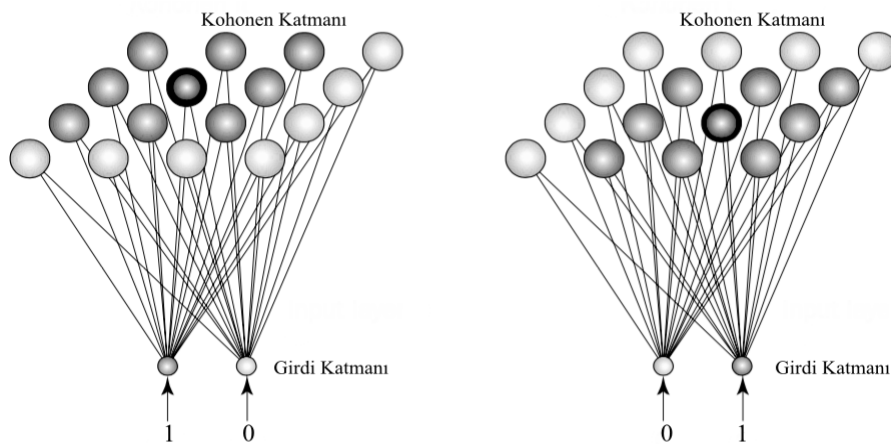
$$E_j = B - y_j(k) \quad (3.179)$$

Hesaplanan hata miktarı sigmoid aktivasyon fonksiyonu kullanıldığı takdirde Eşitlik 3.180 kullanılarak değişebilen ağırlıklara dağıtılmaktadır. Burada δ dağıtılan hata oranını temsil etmektedir. Elman ağında geri dönüşüm ağırlıkları sabit kalmaktadır, bu ağırlıklar üzerinde değişiklik yapılmamaktadır (Şen, 2004; Priddy ve Keller, 2005; Öztemel 2003).

$$\delta(k) = y(k) - [1 - y(k)]E(k) \quad (3.180)$$

Rekabetçi Öğrenme Gerçekleştiren Ağlar- Kohonen SOM (Self-Organized-Maps) Ağları

Kohonen (1989) tarafından geliştirilen SOM (Self- Organized- Maps) ağları veri madenciliği, sınıflandırma, görselleştirme gibi sayısal uygulamalar üzerinde oldukça etkili ve güçlü bir araçtır. Literatürde Kohonen ağları olarak da yer almaktadır. Danışmansız öğrenme stratejisine göre çalışan SOM ağlarında, ağı eğitimi için bir danışman veya veri seti bulunmamaktadır. En fazla karşılaşılan danışmansız öğrenme türlerinden birisi rekabetçi öğrenmedir. Bu öğrenme ile çalışan ağlarda çıktı nöronları kendi aralarında aktive olmak veya olmamak için yarışır (Haykin, 2009). Yarışmayı kazanan çıktı nöronu “kazanan-hepsini-alır” nöronu olarak isimlendirilmektedir. Burada kazanan nöron merkezde yer almak üzere belirli bir sınır içinde kalan nöronlar da (merkezdeki nöron ve komşuları) kazanan elemanlar olmaktadır (Kınacı, 2006). Eğitim sürecinde ağırlıkların değişimi kazanan nöron ile kazanan nöronun komşuları üzerinde gerçekleşir. Girdi ve çıktı katmanından oluşan SOM ağları diğer yapay sinir ağı modellerinden farklı bir yapı sergiler. Şekil 3.30’da Kohonen Som ağına ilişkin şekilsel gösterim yer almaktadır.



Şekil 3.30: Kohonen Modeli (Negnevitsky, 2005).

SOM ağlarında öğrenme süreci aşağıda yer alan adımlarda özetlenmiştir:

Adım 1: Başlangıç ağırlıkları $[0, 1]$ aralığında pozitif bir sayı olmak üzere belirlenir.

Adım 2: Aktivasyon aşamasıdır. X girdi vektörü kullanılarak ağ aktive edilir, böylece kazanan nöron (j_X) bulunur. Euclidean uzaklık kriteri kullanılarak gerçekleştirilen hesaplamaların matematiksel ifadesi Eşitlik 3.181'de yer almaktadır. Burada p iterasyon sayısını; n girdi katmanındaki nöron sayısını; m ise Kohonen katmanında (çıkı katmanı) bulunan nöron sayısını temsil etmektedir.

$$j_X(p) = \min_j \|X - W_j(p)\| = \left\{ \sum_{i=1}^n [x_i - w_{ij}(p)]^2 \right\}^{1/2} \quad (3.181)$$

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

Adım 3: Öğrenme aşamasıdır. Ağırlıklar Eşitlik 3.182'de yer alan formül yardımıyla güncellenir. Burada $\Delta w_{ij}(p)$; p . iterasyonda değiştirilen ağırlıktır.

$$w_{ij}(p+1) = w_{ij}(p) + \Delta w_{ij}(p) \quad (3.182)$$

Ağırlık değişimi Eşitlik 3.183'de ifade edilen rekabetçi öğrenme kuralına göre gerçekleşmektedir. Burada α ; öğrenme oranı parametresi ve $\Lambda_j(p)$; kazanan nöronun çevresindeki komşuluk fonksiyonu merkezidir.

$$\Delta w_{ij}(p) = \begin{cases} \alpha [x_i - w_{ij}(p)], & j \in \Lambda_j(p) \\ 0, & j \notin \Lambda_j(p) \end{cases} \quad (3.183)$$

Komşuluk fonksiyonu dörtgen şekilde ele alındığında ve ikili karakteri olduğunda nöron çıktısı Eşitlik 3.184'deki gibi ifade edilebilmektedir. Komşuluk fonksiyonu zamanla azalan niteliktedir.


$$y_i = \begin{cases} 1, & j \in \Lambda_j(p) \\ 0, & j \notin \Lambda_j(p) \end{cases} \quad (3.184)$$

Adım 4: İterasyon aşamasıdır. Durdurma koşulu olan minimum uzaklıklı Euclidean kriteri kabul edilinceye kadar p iterasyonu artırılır ve ikinci adıma geri dönlür. Bu adımla birlikte SOM ağının işleyişi sona erer (Kohonen, 1982; Negnevitsky, 2005; Haykin, 2009).

Rekabetçi Öğrenme Gerçekleştiren Ağlar- LVQ Ağları (Learning Vector Quantization)

Danışmansız ve takviyeli öğrenme stratejisi ile çalışan yapay sinir ağları oldukça geniş araştırma alanına sahiptir. Bu şekilde eğitilen sistemler sınıflandırma ve tanımlama gibi görevleri başarı ile gerçekleştirmektedirler (Kohonen, 1990). Literatürde ağ yapısı ve algoritmalarına göre farklı LVQ (Learning Vector Quantization) ağı türleri yer almaktadır. 1984 yılında Kohonen tarafından geliştirilen LVQ ağlarının çalışmasındaki temel fikir, farklı gruplar halinde verilen vektörel verileri bazı ölçü birimleri yardımıyla kategorize etmektir. Bir başka ifade ile yüksek boyutlu vektör daha küçük boyutlu vektörler ile açıklanmaktadır. Sınıflandırma tekniklerinin uygulanmasında oldukça geniş bir kullanım alanına sahip olan LVQ ağları takviyeli öğrenme stratejisi ve “kazanan hepsini alır” kuralına göre çalışmaktadır.

Girdi katmanı, gizli katman ve çıktı katmanı olmak üzere LVQ ağları üç katmandan oluşmaktadır. Girdi katmanı ve gizli katman arasında tam bağlantı durumu söz konudur. Gizli katman ile çıktı katmanı arasındaki bağlantı ise kısmi bağlantılıdır. Gizli katman girdilerin sınıflandırılmasına ilişkin öğrenmenin gerçekleştiği katmandır. Girdi katmanından alınan veriler burada işlenmektedir. LVQ ağında girdi vektörü en yakın olduğu çıktı elemanının sınıfına atanır böylece girdi vektörünün eşleşebileceği çıktı vektörü bulunmuş olur (Kınacı, 2006). Burada çıktılardan sadece bir tanesi “1” diğerleri “0” değerini almaktadır. “1” olan çıktı girdi vektörünün sınıfını temsil etmektedir. LVQ ağı yapısına ilişkin genel görünüm Şekil 3.31’de yer almaktadır.



Şekil 3.31: LVQ Ağı Yapısı (Öztemel, 2006).

LVQ ağında girdi katmanı $x(t) \in R^n$ gelen vektörünü alır ve ileri yönlü olacak şekilde gizli katmana $w_j(t) \in R^n$ ağırlıkları kullanarak gönderir. Burada n girdi katmanındaki eleman sayısı temsil etmektedir.

$\|x(t) - w_j(t)\| \leq \varepsilon$ ifadesi oldukça düşük değerli olarak elde edilmektedir. Bunun anlamı $w_j(t)$, $x(t)$ 'ye yakın olduğunda j 'inci elemanın kazanan eleman olarak belirlenmesi şeklindedir. Kazanan hepsini alır kuralı gereğince kazanan nöron "1" olarak ayarlanır geriye kalan tüm nöronlar "0" ile temsil edilir. Kazananın ağırlığı bir ölçek farkı eklenerek güncellenir. Bu durumun matematiksel ifadesi α ölçek faktörünü temsil etmek üzere Eşitlik 3.185'de yer almaktadır.

$$w(t + 1) = w(t) + \alpha[x(t) - w_j(t)] \quad (3.185)$$

LVQ ağının işleyiş algoritması dört adımda, Eşitlik 3.186-188'de, özetlenmektedir (Siddique ve Adeli, 2013):

Adım 1: $w_j(0)$ Başlangıç ağırlıkları belirlenir.

Adım 2: Uzaklık ölçüsü hesaplanır.

$$\|x(t) - w_j(t)\| \quad (3.186)$$

Adım 3: Kohonen katmanındaki p sayıda nöron arasından kazanan nöron belirlenir. Bu işlem $x(t) - w_j(t)$ farkını minimum yapan değerini bulunması ile gerçekleşir.

$$\|x(t) - w_j(t)\| = \min_j \|x(t) - w_j(t)\| \quad (3.187)$$

Adım 4: Ağırlık vektörleri güncellenir:


$$w_j(t + 1) = \begin{cases} w_j(t) + \alpha[x(t) - w_j(t), & j = 1 \\ w_j(t), & dd \end{cases} \quad (3.188)$$

$$j = 1, \dots, p. \quad 0 < a_t < 1$$

LVQ ağına ilişkin LVQ2, LVQ2.1 ve LVQ3 olmak üzere farklı algoritmalar literatürde yer almaktadır.

Rekabetçi Öğrenme Gerçekleştirilen Ağlar- ART (Adaptive Resonance Theory)

ART ağları 1976 yılında Grossberg tarafından biyolojik sistemlerin açıklanmasına yönelik geliştirilen bir yapay sinir ağı modelidir. ART yapısı, birbirlerine uzun dönem hafıza mekanizması ile tam bağlantılı olan F1 ve F2 olarak isimlendirilen katmanlardan oluşmaktadır. F1 katmanı girdi deseninin alındığı ve işlendiği katmandır; F2 katmanı ise sınıflandırma işlevinin gerçekleştiği katmandır. Girdilerin sınıflandırılması sürecinde öncelikle özelliklerin ayrıştırılması yoluyla bir karakterizasyon gerçekleştirilir, bu durum özellikle gösterim alanında aktivasyona sebep olur. İşlemler girdi deseninin kısa dönem hafızaya depolanması ile başlamaktadır. Uzun dönem hafıza, uyarım mekanizmasını sağlamaktadır (ör: sınıflandırma), benzer şekilde kısa dönem hafıza da uzun dönem hafızadaki kademeli değişimlere neden olmaktadır.



Şekil 3.32: ART Yapısı (Sumathi ve Suretha, 2010).

ART ağının yapısı Şekil 3.32’de yer almaktadır. Literatürde ART1, ART2, ART3 ARTMAP ve FuzzyART olmak üzere farklı ART ağları yer almaktadır. Bunların içinden ART1 ve ART2 ağları oldukça yaygın şekilde kullanılmaktadır. Temelde çalışma prensipleri benzer olmakla birlikte ART1 ve ART2 ağları arasındaki farklılık girdi desenlerinin kesikli ve sürekli olmasından kaynaklanmaktadır.

3.5.2.2. Yapay Sinir Ağları Kullanılarak Bulanık Doğrusal Olmayan Regresyon Modellemesi

Sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizi ile ilgili çalışmalar 1990’lı yılların başlarında hız kazanmıştır. Ishibuchi ve Tanaka (1989) çalışmalarında geri yayımlı yapay sinir ağını esas alan aralık regresyonunu tanıtmışlardır. Veri aralığının alt ve üst sınırları için iki farklı sinir ağı ile çalışmışlar ve burada stepwise maliyet

fonksiyonuna odaklanmışlardır. Ancak bu yöntem eğitim verilerinde oluşabilecek kutuplaşmalar nedeniyle uç değerlere karşı oldukça hassastır. 1992 yılında Ishibuchi ve Tanaka tarafından gerçekleştirilen bir başka çalışmada bulanık sayıların üst ve alt sınır değerlerini belirlemek üzere birbirinden bağımsız iki farklı geri yayımlı sinir ağıyla çalışmışlardır. Ağırlık değerleri ve bias değerlerinin kesin sayı olduğu bu iki sinir ağında eğitim sürecinde geri yayılım algoritması kullanılmıştır. Burada girdi ve çıktılar bulanık sayı olarak analizlerde yer almıştır. Bu alanda Ishibuchi ve Tanaka tarafından yapılan bir diğer önemli çalışma 1993 yılında gerçekleştirilmiştir (Ishibuchi ve diğ. 1993). 1992 yılında yapılan çalışmadan farklı olarak burada girdi değişkeni kesin sayı olmak üzere tek bir sinir ağı, ağırlıkları ve sapma değerleri bulanık sayı olacak şekilde ele alınmıştır. Bu çalışmayı takiben 1995 yılında Ishibuchi ve diğ. (1995) sinir ağı ağırlıklarının üçgensel bulanık sayı olduğu yeni bir yöntem önermişlerdir. Xu ve Khoshgoftaar (2001) tarafından gerçekleştirilen çalışmada doğrusal olmayan bulanık regresyon modelini inşa etmek üzere yeni bir algoritma önerilmiştir. Araştırmacılar makul bir aralık hesaplamak ve uç değerlerden daha az etkilenmeyi sağlamak üzere bağımlı değişkenin ortalamasını temel almışlardır. Aralığın alt ve üst sınırlarını belirlemek üzere birbirinden bağımsız iki geri yayımlı sinir ağı kullanılmaktadır. Sinir ağlarından birisi alt sınırı diğeri ise üst sınırı temsil etmektedir ve birbirinden bağımsız şekilde eğitilmektedirler. Bağımlı değişkene ilişkin beklenen yayılım değerleri eğitim sürecinde belirlenmektedir. Günümüzde sinir ağlarına dayalı doğrusal olmayan bulanık regresyon çalışmalarında geri yayılım algoritmaları ile çalışan çok katmanlı algılayıcının yanı sıra, ağ ağırlıklarının iteratif düzenlenmesine ihtiyaç duyulmadığı bunun yerine rassal ağırlıkların kullanıldığı radyal tabanlı fonksiyon sinir ağları da literatürde yer almaktadır (Cheng ve Lee, 2001; Zhang ve diğ. 2005; He ve diğ. 2016; He ve diğ. 2018).

Tez çalışması kapsamında Xu ve Khoshgoftaar (2001) tarafından önerilen yöntem çerçevesinde analizler gerçekleştirilmiştir. Xu ve Khoshgoftaar (2001) tarafından önerilen algoritmanın ayrıntıları şu şekildedir:

Bağımsız değişkeni x_i ve bağımlı değişkeni y_i temsil etmek üzere ($i = 1, 2, \dots, n$) modelde n adet (x_i, y_i) girdi- çıktı çiftinin olduğu varsayılmaktadır. $y_+(x_i)$ ve $y_-(x_i)$ ifadeleri x_i bağımsız değişken vektörüne karşılık gelen iki sinir ağının çıktısını temsil etmektedir. Önerilen algoritmada hedef Eşitlik 3.189'da yer alan koşulun yaklaşık olarak sağlanmasıdır.

$$y_-(x_i) \leq y_i \leq y_+(x_i) \quad (3.189)$$

Bağımlı değişkene ait yayılım $(y_i)^w$ olarak adlandırılmaktadır. $(y_i)^w$ yayılımının Eşitlik 3.190'daki koşulu sağlaması istenmektedir.

$$y_i \in (y_i - y_i^w, y_i + y_i^w) \quad (3.190)$$

Burada yapay sinir ağları, üst sınır $y_i + y_i^w$ 'ya alt sınır $y_i - y_i^w$ 'ya ulaşmak üzere aynı bağımsız ve bağımlı değişkenler kullanılarak eğitilir.

Bağımlı değişkenin yayılımını temsil eden y_i^w 'nin aşağıdaki gereksinimleri karşılaması gerekmektedir. Bunlar:

- y_i^w pozitif bir sayı olmalıdır.
- Sinir ağının doğruluk kısıtı altında mümkün olduğunca küçük bir değere sahip olmalıdır. Böylece iki sınır arasındaki genişlik de küçük olacaktır.
- Bağımlı değişken y_i 'nin dağılımını temsil etmelidir.

y_i^w yayılımının hesaplanması için öncelikle bağımlı değişkenin ortalama ve standart sapmasının hesaplanması gerekmektedir.

Yayılımın hesaplanma sürecinde ortalamanın kullanılmasının nedeni bağımlı değişkenin ortalama etrafında kümeleniyor olmasıdır. Ancak bu durum her zaman sağlanamayabilir. Bazı veri setleri için bağımlı değişken değeri kesin bir nokta etrafında kümelenemeyebilir. Bu nedenle bu yaklaşım her zaman uygun olmayabilir. Önerilen algorithmada sinir ağının salınımını azaltmak amacıyla ortalama etrafında nispeten geniş yayılım gösteren bağımlı değişken verilmiştir. y_i^w Eşitlik 3.191 yardımıyla hesaplanmaktadır.

$$y_i^w = \frac{\phi}{\bar{y}} y_i + f(y_i) \quad (3.191)$$

Eşitlik 3.191'de yer alan ϕ ; sabit bir sayıdır. y_i 'nin orta noktasındaki yayılmayı temsil etmektedir. Ampirik çalışmalar önerilen algoritmanın $0.5\bar{y} \leq \phi \leq 0.7\bar{y}$ aralığında iyi çalıştığını ifade etmektedir. ϕ değerinin küçük olması Eşitlik 3.189'da yer alan koşulun sağlanmasını olumsuz etkileyebilir buna karşılık çok büyük değerli olması da yayılımın çok fazla genişlemesine yol açmaktadır. Eşitlik 3.191'de yer alan $f(y_i)$ telafi fonksiyonu (compensation function), sinir ağlarının bağımlı değişkenin ortalaması etrafındaki

salınımını dengelemek amacıyla kullanılır. Telafi fonksiyonu Eşitlik 3.192'deki gibi tanımlanır:

$$f(y_i) = \begin{cases} \frac{\psi y_i}{1+e^{-\theta_1(y_i-\omega_1)}}, & y_i \leq \omega_1 \\ \psi y_i, & \omega_1 \leq y_i \leq \omega_2 \\ \frac{\psi y_i}{1+e^{-\theta_2(y_i-\omega_2)}}, & y_i \geq \omega_2 \end{cases} \quad (3.192)$$

Eşitlik 3.192'de yer alan ψ bir ölçek sayıdır. Önerilen yöntem "1" olarak analize dahil edilmiştir. Salınım alanında yapılması gereken azaltmayı belirtir. ω_1 salınım alanının alt sınırını, ω_2 ise üst sınırını temsil etmektedir. θ_1 ve θ_2 fonksiyonun her iki tarafının nasıl bir diklikte aşağı yukarı gideceğini belirtir. θ_1 ve θ_2 birbirine eşit olduğu takdirde fonksiyon simetrik olarak nitelendirilir (Xu ve diğ. 2000; Xu ve Khoshgoftaar, 2001; Tekşen, 2008). θ_1 ve θ_2 Eşitlik 3.193'de yer alan ifadeler yardımı ile hesaplanabilmektedir.

$$\theta_1 = \frac{\bar{y}-\omega_1}{s_y}$$

$$\theta_2 = \frac{\omega_2-\bar{y}}{s_y} \quad (3.193)$$

Alt ve üst sınırları elde etmek üzere eğitilen sinir ağları birbirinden bağımsız çalışmaktadır. Bu nedenle $y_-(x_i) > y_+(x_i)$ olması durumu ile karşı karşıya kalınabilmektedir. Böylesi bir durum söz konusu olduğunda aralık modeli anlamsız olmaktadır. Bu olumsuz durumu bertaraf etmek amacıyla $z_-(x_i)$ ve $z_+(x_i)$ olmak üzere iki fonksiyon tanımlanmıştır. Bu fonksiyonlar Eşitlik 3.194'deki ifadeler yardımıyla elde edilmektedir.

$$z_-(x_i) = \begin{cases} y_-(x_i), & y_-(x_i) \leq y_+(x_i) \\ \frac{1}{2}[y_-(x_i) + y_+(x_i)], & y_-(x_i) > y_+(x_i) \\ 0, & y_-(x_i) < 0 \end{cases} \quad (3.194)$$

$$z_+(x_i) = \begin{cases} y_+(x_i), & y_-(x_i) \leq y_+(x_i) \\ \frac{1}{2}[y_-(x_i) + y_+(x_i)], & y_-(x_i) > y_+(x_i) \end{cases}$$

Tanımlanan fonksiyonlar sayesinde $z_-(x_i) \leq z_+(x_i)$ durumu bağımsız değişkene ilişkin tüm gözlem değerleri (x_i) için geçerli olur. $[z_-(x_i), z_+(x_i)]$ doğrusal olmayan aralığı her zaman anlamlıdır. Burada $[z_-(x_i), z_+(x_i)]$ aralığından doğrusal olmayan bulanık regresyon modeli türetilmektedir. Bağımlı değişkenin gözlem değerlerine ilişkin aralık

tahmini gerçekleşmektedir. Bu aralıkta yer alan sayıların pozitif olması gerektiğinden $z_-(x_i)$ 'ler sifıra kadar kesilir.

$\hat{Y}(x_i), y_i$ bağımlı değişkenin tahmini olan bir bulanık sayı olarak tanımlanmaktadır. Simetrik üçgensel üyelik fonksiyonları doğrusal olmayan bulanık regresyona uygulandığında Eşitlik 3.195'deki ifadeler elde edilir.

$$\hat{Y}(x_i) = (f^c(x_i), f^w(x_i)) \quad (3.195)$$

$\hat{Y}(x_i)$ 'ne ilişkin h- seviye kümesi Eşitlik 3.196'da yer alan ifade yardımıyla hesaplanmaktadır.

$$[\hat{Y}(x_i)]_h = [f^c(x_i) - (1-h)f^w(x_i), f^c(x_i) + (1-h)f^w(x_i)] \quad (3.196)$$

Burada $f^c(x_i)$, $\hat{Y}(x_i)$ 'nin merkezini; $f^w(x_i)$ ise yayılımını ifade etmektedir. $h \in (0, 1]$ olmak üzere $\hat{Y}(x_i)$ 'nin h seviye kümesi Eşitlik 3.197'deki koşulu sağlayacak şekilde bağımsız değişkenlerin tüm gözlem değerleri için bulanık model elde edilir.

$$[\hat{Y}(x_i)]_h = [z_-(x_i), z_+(x_i)] \quad (3.197)$$

$[\hat{Y}(x_i)]_h$ 'nin üst sınırı $[\hat{Y}(x_i)]_h^+$; alt sınırı ise $[\hat{Y}(x_i)]_h^-$; merkezi $[\hat{Y}(x_i)]_h^c = f^c(x_i)$ ile ifade edilmektedir. Buna göre merkez ve yayılım değerleri Eşitlik 3.195 ve Eşitlik 3.196 yardımıyla Eşitlik 3.198'de bulunan eşitlikler kullanılarak hesaplanabilmektedir. Böylece tüm bağımsız değişkenler için $\hat{Y}(x_i)$ bulanık sayısı tahmin edilmiş olunur (Xu ve diğ. 2000).

$$f^c(x_i) = \frac{1}{2}(z_-(x_i) + z_+(x_i))$$

$$f^w(x_i) = \frac{1}{2h}(z_+(x_i) - z_-(x_i)) \quad (3.198)$$

Doğrusal olmayan bulanık regresyon analizinde tahmin aralığını hesaplamak amacıyla yapay sinir ağları kapsamında çok katmanlı algılayıcı modeli kullanılmıştır. Bulanık regresyon analizinde girdi değişkeni kesin sayı, çıktı değişkeni ise bulanık sayı olacak şekilde sistemde yer almıştır. Alt ve üst sınırlara ilişkin tahmin değerlerinin elde edilmesi işlemine başlamadan önce, her bir gözlem değeri için Xu ve Khoshgoftaar (2001) tarafından önerilen yöntem çerçevesinde bulanık sayıların elde edilmesi amacıyla yayılım

değerleri hesaplanmıştır. Simetrik üçgensel bulanık sayıların kullanıldığı analizlerde, yayılım değerlerinin hesaplanma sürecinde ϕ değeri 0.65 olarak alınmıştır. Gözlem değerleri için elde edilen yayılımlar kullanılarak, sinir ağlarının eğitim sürecinde yer alacak alt ve üst sınır değerleri hesaplanmıştır. Birbirinden bağımsız şekilde eğitilen sinir ağlarının çıktıları analizlerde yer alan bağımlı değişkenin alt ve üst tahmin değerleri olmaktadır. Tahmin aralığına ilişkin alt ve üst sınır eğrileri ile gerçek gözlem değerleri kullanılarak osilasyon alanının olup olmadığı incelenmiş ve buna göre kompanse fonksiyonunun kullanılmaması gerektiğine karar verilmiştir. Bu noktada, veriler zamana bağımlı olarak değiştiği ve eğrisel bir yapı sergilediğinden dolayı sinir ağlarının eğitim işleminin çok dikkatli yapılması gerekmektedir. Analizler, çıktı değişkeni bir ve iki tane olacak şekilde tamamlanmıştır. Tek değişkenli analizlerde sinir ağı mimarileri bir girdi değişkeni ve bir çıktı değişkeni; çok değişkenli analizlerde bir girdi değişkeni ve iki çıktı değişkeni olmak üzere, katman sayısı bir ve iki olacak şekilde tasarlanmıştır. Ara katmanlarda yer alacak nöron sayıları üç nörondan başlamak üzere 20 nörona kadar ele alınmış, sonuçlar her nöron için hesaplanmıştır. Böylece sinir ağı mimarilerinin optimum yapısına ulaşılmaya çalışılmıştır. Sinir ağlarına dayalı bulanık regresyon analizine ilişkin bulguların sunumunda en başarılı tahmin değerinin elde edildiği nöron sayısı kullanılmıştır. Analizler günlük ve haftalık kaydı alınmış veri setleri kullanılarak yapılmıştır.

Yapay sinir ağları ile gerçekleştirilen analizlerde eğitim aşamasında aktivasyon fonksiyonu hiperbolik tanjant-sigmoid ve log-sigmoid olarak belirlenmiştir. Çok katmanlı geri yayılım algoritmaları ileri beslemeli sinir ağı modelinin kullanıldığı analizlerde eğitim sürecini gerçekleştirmek üzere, 10 farklı geri yayılım algoritması kullanılmıştır. Bunlar Bayesian Regularization (BR), Levenberg- Marquardt (LM), Scaled Conjugate Gradient (SCG), Gradient Descent (GD), Gradient Descent with Momentum (GDM), Gradient Descent with Momentum and Adaptive Learning Rate (GDX), Conjugate Gradient Backpropagation with Fletcher-Reeves Updates (CGF), Conjugate Gradient Backpropagation with Powell-Beale Restarts (CGB), Brayde Fletcher Gold Farlo Shanno Quasi Newton Backpropagation (BFG) ve One Step Secant Algorithm (OSS) olacak şekilde belirlenmiştir. Öğrenme oranı 0.01, momentum katsayısı 0.95, en yüksek iterasyon sayısı ise 100000 olarak analizlerde yer almıştır. Bulanık regresyon analizinin alt ve üst tahmin değerlerini belirlemek üzere kullanılan sinir ağlarının eğitiminde başlangıç değerleri şansa bağlı olarak belirlenmiştir.

Ayrıca bağlantı ağırlıklarının öğrenme süreci hata kareler ortalaması en düşük seviyeye ulaştığında tamamlanmıştır.

Tahmin aralığına ilişkin alt ve üst sınır değerleri elde edildikten sonra bulanık model türetilmek üzere h seviyeleri 0.1, 0.3, 0.5, 0.7 ve 0.9 olmak üzere beş farklı değer olarak belirlenmiştir. Buna göre bağımlı değişkenin tahmin değerlerine ilişkin h -seviye kümeleri oluşturulmuştur. Böylece bağımlı değişkenin tahmin değeri bulanık sayı olarak elde edilmiştir. Bağımlı değişkene ait veriler yapay sinir ağının eğitim performansını iyileştirmek amacıyla normalizasyona tabi tutulmuştur. Verilerin eğitim işlemi gerçekleştirildikten sonra normalize edilmeden önceki hallerine geri dönüştürülmüştür.

Doğrusal olmayan bulanık regresyon analizinde tahmin aralığının oluşturulmasında kullanılan sinir ağlarının test ve geçerlilik setleri için elde edilen merkez değerleri, Tablo 3.2'de yer alan istatistiksel hata kriterleri kullanılarak, gerçek gözlem değerleri ile karşılaştırmalı olarak incelenmiştir. Bu kapsamda hata kareler ortalaması (HKO), ortalama mutlak yüzde hata (OMYH) ve ortalama mutlak hata (OMH) kriterleri kullanılmıştır. Hata değerleri test ve geçerlilik seti için geri yayılım algoritmalarının her nöronunda ayrı ayrı hesaplanmıştır.

Tablo 3.2: İstatistiksel Hata Kriterleri.

İstatistiksel Hata Kriterleri	Eşitlikler
Hata Kareler Ortalaması (HKO)	$HKO = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
Ortalama Mutlak Yüzde Hata (OMYH)	$OMYH = \left(\frac{100}{n}\right) \sum_{i=1}^n \left \frac{(y_i - \hat{y}_i)}{y_i} \right $
Ortalama Mutlak Hata (OMH)	$OMH^* = \frac{1}{n} \sum_{i=1}^n y_i - [\hat{y}(x_i)]_h^* $
	$OMH^w = \frac{2}{n} \sum_{i=1}^n f^w(x_i) $

*Üst sınır (+), alt sınır(-) ve merkez (c) için tanımlanabilmektedir.

3.5.2.3. En Küçük Kareler Destek Vektör Makineleri

Sistem tanımlaması yapmak amacıyla girdi-çıkı ilişkileri açısından ölçümlenen değerler ışığında modellenme ve tahmin çalışmaları çeşitli yöntemler aracılığıyla sürdürülmektedir. Doğrusal olmayan sistemlerin tanımlanmasında, doğrusal yapıda sistemlere göre, çok daha kapsamlı ve karmaşık hesaplamalar gerekmektedir. Bu amaçla doğrusal olmayan regresyon analiz teknikleri, yapay sinir ağları ve destek vektör makineleri yöntemleri araştırmacılar tarafından tercih edilmektedir.

Destek vektör makineleri ile ilgili çalışmaların temelleri 1960'lı yıllarda Vladimir Vapnik ve Alexie Chervonenkis isimli arařtırmacıların istatistiksel öğrenme teorisi üzerine yaptıkları arařtırmalara dayanmaktadır. Konu ile ilgili ilk makale ise 1992 yılında Bernhard Boser, Isabelle Guyon ve Vladimir Vapnik, tarafından yayınlanmıştır (Boser ve diğ. 1992; Vapnik 1995; Vapnik 1998). Destek vektör makinelerinin eğitim zamanları diğeri yöntemlere göre uzun sürebilmektedir ancak karmaşık doğrusal olmayan karar sınırlarını oldukça başarılı bir şekilde modelleyebilmekte ve doğruluk değeri oldukça yüksek olmaktadır. Aynı zamanda aşırı uyum problemine yatkınlık, diğeri yöntemlere göre daha az olmaktadır (Han ve Kamber, 2006).

Yapay zeka temelli yöntemlerden birisi olan destek vektör makineleri, doğrusal ve doğrusal olmayan veri yapılarında sınıflandırma amacıyla kullanılmaktadır ayrıca çok katmanlı algılayıcılara benzer şekilde örüntü tanıma ve doğrusal olmayan regresyon problemleri için de kullanılabilir (Haykin, 1999). Destek vektör makineleri sınıflandırma ve tahmin çalışmalarının yanı sıra el yazısı tanıma, nesne tanıma, konuşmacı tanımlama ve zaman serisi tahmin testlerinin değerlendirilmesi olmak üzere bir çok farklı alanda uygulanmaktadır (Han ve Kamber, 2006).

Destek vektör makineleri Kernel tabanlı yöntemleri kullanmaktadır. Kernel tabanlı yöntemlerin doğrusal olmayan regresyon analizi problemlerinde modelleme gücü oldukça başarılıdır. Arařtırmacılar tarafından tercih edilmelerinde etkili olan sebeplerden bazıları şu şekildedir: Öncelikle dışbükey optimizasyon dayanağı sayısal çözümler için oldukça etkilidir. İkinci olarak Kernel tabanlı tahmin tekniklerine bağılı olarak destek vektör teknikleri, diğeri doğrusal olmayan tahmin tekniklerinin olduğu gibi boyutluluk olumsuzluğuna maruz kalmamaktadırlar. Üçüncüsü ise optimizasyon problemine ilişkin formülasyon model üzerinde doğru biçimde ek yapı sunmaktadır ve böylece önceki bilgiyi de içermektedir. Destek vektör makineleri (DVM) istatistiksel öğrenme teorisine dayanan ve danışmanlı öğrenme gerçekleştiren oldukça popüler bir yaklaşımdır. DVM yöntemi doğrusal olmayan sınıflandırma, çok değişkenli fonksiyon tahmini ve doğrusal olmayan regresyon problemlerinin çözümüne olanak sağlamaktadır (Vapnik ve diğ. 1998, Suyken 2001; Smola ve Schölkopf, 2004). Doğrusal olmayan Kernelleri kullanan bu yöntem yüksek genelleme yeteneğine sahiptir. En küçük kareler destek vektör makineleri (EKK-DVM) ise makine öğrenmesi gerçekleştiren yapay zeka temelli bir yöntemdir ve yapay sinir ağlarına benzer bir çalışma yapısına sahiptir. EKK-DVM Kernel tabanlı modellerin özel bir türü olarak da tanımlanmaktadır ve kuadratik programlama problemlerinde

optimizasyon işlemlerinin karmaşıklığını azaltmak amacıyla DVM'nin özel bir türü olarak önerilmiştir. Burada amaç, dual uzaydaki bir kuadratik programlama problemi yerine doğrusal bir denklem seti elde etmek için eşitsizlik kısıtı yerine eşitlik önermektir (Suyken ve Vandewalle, 1999). EKK-DVM, belirlenen optimizasyon problemini çözümlmek amacıyla en küçük kareler maliyet fonksiyonunu kullanmaktadır. Bu yönüyle destek vektör makinelerinden farklılaşmıştır. EKK-DVM regresyonuna ilişkin fonksiyon tanımını Eşitlik 3.199'da; tahmin yapılacak optimizasyon problemi Eşitlik 3.200'de; probleme ilişkin kısıt ise Eşitlik 3.201'de tanımlanmaktadır (Suyken ve diğ. 2002, Li ve diğ. 2012).

$$y(x) = w^T \varphi(x) + b \quad (3.199)$$

$$\min_{w,b,e} J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=R}^N e_i^2 \quad (3.200)$$

$$y_i = w^T \varphi(x_i) + b + e_i \quad i = R, \dots, N \quad (3.201)$$

Burada eğitim seti $\{x_i, y_i\}$, $w \in \mathbb{R}$ ve $b \in \mathbb{R}$ olmak üzere model parametreleridir. Eşitlik 3.199'da w ; ağırlık vektörü, b ise sapma terimidir. φ doğrusal olmayan eşleme (mapping) fonksiyonu $\varphi: \mathbb{R} \rightarrow \mathbb{R}$ olarak tanımlanmaktadır. Eşitlik 3.199'da yer alan regresyon modeli doğrusal olmayan eşleme (mapping) fonksiyonu kullanılarak yapılandırılmaktadır. DVM teorisinde olduğu gibi EKK-DVM'da da cezalı regresyon hatası içeren maliyet fonksiyonunu (J) minimize etmektir.. Maliyet fonksiyonunun ilk kısmında ağırlıklar düzenlenmektedir. İkinci kısmı ise, tüm eğitim verileri için regresyon hatasıdır. J parametresi kullanıcı tarafından belirlenmektedir (Borin ve diğ. 2006; Bessedik ve Hadi, 2013).

Özellik uzayı genellikle yüksek boyutludur. Kernel tabanlı tekniklerde φ açık bir şekilde tanımlanamamaktadır, K olarak adlandırılan belirli bir pozitif Kernel fonksiyonu aracılığı ile belirtilir. Mercer koşullarına (Mercer, 1909) dayanarak her pozitif belirli $K(x_i, x_j)$ fonksiyonu, $K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$ iç çarpımı olarak ifade edilir. Özellik uzayının çok boyutlu olması durumunda daha pratik çözümler tasarlamak adına Lagrange dual formülasyon kullanılmaktadır. Kernel tabanlı model üretebilmek amacıyla aşağıda belirtilen beş adımı gerçekleştirmek gerekmektedir. Matematiksel ifadeler Eşitlik 3.202 ve Eşitlik 3.203'de verilmiştir.

Adım 1: Optimizasyon problemini çözmek amacıyla Lagrange fonksiyonu yapılandırılır:

$$L(w, b, e; \alpha) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=R}^N e_i^2 - \sum_{i=R}^N \alpha_i (w^T \varphi(x_i) + b + e_i - y_i) \quad (3.202)$$

Burada α_i Lagrange çarpanlarıdır.

Adım 2: Öncül ve dual değişkenlere göre lagrange türevleri alınır.

Adım 3: Optimallik için Karush-Kuhn-Tucker (KKT) şartlarına ilişkin formülasyon oluşturulur. Sonuçlar w, b, e ve α 'ya göre kısmi türevlerin alınması ile elde edilir.

$$\frac{\partial L}{\partial w} = 0: \quad w = \sum_{i=R}^N \alpha_i \varphi(x_i), \quad (3.203)$$

$$\frac{\partial L}{\partial b} = 0: \quad \sum_{i=R}^N \alpha_i = 0,$$

$$\frac{\partial L}{\partial e_i} = 0: \quad e_i = \gamma^{-1} \alpha_i, \quad i = R, \dots, N,$$

$$\frac{\partial L}{\partial \alpha_i} = 0: \quad y_i = w^T \varphi(x_i) + b + e_i, \quad i = R, \dots, N.$$

Adım 4: Dual optimizasyon problemi yazılır.

Adım 5: Dual modeli elde etmek için primal model içerisinde dual çözümün ikamesi kullanılır.

$$\begin{bmatrix} 0 & 1_v^T \\ 1_v & \Omega + I/\gamma \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (3.204)$$

Eşitlik 3.203'de yer alan w ve b 'nin eliminasyonu ile Eşitlik 3.204'de yer alan matematiksel ifade elde edilir. $\alpha = [\alpha_R, \dots, \alpha_N]^T \in \mathbb{R}$ ve b dual değişkenleri sistemin çözümü olarak tanımlanmaktadır. Eşitlik 3.204'de y vektörü $1_v = [1, 1, \dots, 1]$ ve $y = [y_R, \dots, y_N]^T$ olarak tanımlıdır. Kernel matrisi $\Omega_{ij} = \varphi(x_i)^T \varphi(x_j) = K(x_i, x_j)$, $(i, j = 1, \dots, N)$ şeklinde tanımlanmaktadır. Mercer koşullarının Ω matrisine uygulanması ile birlikte EKK-DVM regresyon için Eşitlik 3.205'de yer alan ifade ile elde edilir (Suyken ve Vandewalle, 2000; Suyken ve diğ. 2002; Zhu ve Wei 2013).

$$y(x) = \sum_{i=R}^N \alpha_i K(x, x_i) + b \quad (3.205)$$

Analizler, EKK-DVM teorisinde verilerin eğitim sürecinde yer alan üç farklı Kernel fonksiyonu kullanılarak gerçekleştirilmiştir. Bunlar Radial Basis Function (RBF), Polinomiyal Kernel Fonksiyonu ve doğrusal Kernel fonksiyonu şeklindedir. Model parametrelerinin optimal değerlerini belirlemek üzere farklı parametre kombinasyonlarında analizler gerçekleştirilmiştir. Kernel fonksiyonları Tablo 3.3’de verilmiştir.

Tablo 3.3: Kernel Fonksiyonları.

Kernel Fonksiyonları	Eşitlikler	Açıklamalar
Radial Basis Function (RBF)	$K(x_i, x_j) = e^{-\frac{\ x_i - x_j\ ^2}{\sigma^2}}$	σ^2 : Varyans.
Polinomiyal Kernel Fonksiyonu	$K(x_i, x_j) = (x_i^T x_j + t)^d$, $t \geq 0$	t : Intercept. d : Polinomiyal derecesi.
Doğrusal Kernel Fonksiyonu	$K(x_i, x_j) = x_i^T x_j$	-

3.5.2.4. En Küçük Kareler Destek Vektör Makinelere Dayalı Doğrusal Olmayan Bulanık Regresyon Analizi

Bulanık girdi ve bulanık çıktı ile tasarlanan bulanık çok değişkenli regresyon modelleri için konveks optimizasyon problemi türetilmek amacıyla en küçük kareler destek vektör makineleri kullanılmaktadır (Hong ve Hwang, 2003; Hong ve Hwang, 2006). Hong ve Hwang (2006) tarafından önerilen yöntemde bulanık regresyon çalışmalarında en fazla kullanılan sayı tipi olan üçgensel bulanık sayılar kullanılmıştır.

Bulanık doğrusal EKK-DVM regresyonu için eğitim verisi $\{X_i, Y_i\}_{i=1}^l \subset T(R)^d \times T(R)$ şeklinde tanımlanmaktadır. Burada $X_i = ((m_{X_{i1}}, \alpha_{X_{i1}}, \beta_{X_{i1}}), \dots, (m_{X_{id}}, \alpha_{X_{id}}, \beta_{X_{id}}))$ ve $Y_i = (m_{Y_i}, \alpha_{Y_i}, \beta_{Y_i})$ şeklinde ifade edilmektedir. $T(R)^d$ üçgensel bulanık sayıların d vektörlerinin kümesi ve $T(R)$ ise üçgensel bulanık sayılar kümesini temsil etmektedir. Bu ifadelerin yanı sıra $m_{X_i} = (m_{X_{i1}}, \dots, m_{X_{id}})$, $\alpha_{X_i} = (\alpha_{X_{i1}}, \dots, \alpha_{X_{id}})$, $\beta_{X_i} = (\beta_{X_{i1}}, \dots, \beta_{X_{id}})$, $B = (m_B, \alpha_B, \beta_B)$ ve $w = (w_1, \dots, w_d)$ olarak belirtilmiştir.

Bulanık girdi ve bulanık çıktının yer aldığı sistemler için Eşitlik 3.206’da yer alan model $B \in T(R)$, $w \in R^d$ olmak üzere önerilmiştir.

$$Y(X) = \langle w, X \rangle + B = (\langle w, m_X \rangle + m_B, \langle |w|, \alpha_X \rangle + \alpha_B, \langle |w|, \beta_X \rangle + \beta_B) \quad (3.206)$$

Burada $|w| = (|w_1|, |w_2|, \dots, |w_d|)$ şeklinde ifade edilmektedir. Bu noktada klasik çoklu doğrusal regresyon analizinden hareketle konveks optimizasyon problemine ulaşılır. Bahsi geçen problem yapısına ilişkin matematiksel gösterim Eşitlik 3.207’de yer almaktadır.

$$\min \frac{1}{2} \|\omega\|^2 + \frac{C}{2} \sum_{k=1}^3 \sum_{i=1}^l e_{ki}^2 \quad (3.207)$$

Model kısıtları Eşitlik 3.208’de tanımlanmıştır.

$$\begin{aligned} m_{Y_i} - \langle \omega, m_{X_i} \rangle - m_B &= e_{1i}, \\ (m_{Y_i} - \alpha_{Y_i}) - (\langle \omega, m_{X_i} \rangle + m_B - (|\omega|, \alpha_{X_i}) - \alpha_B) &= e_{2i} \\ (m_{Y_i} + \beta_{Y_i}) - (\langle \omega, m_{X_i} \rangle + m_B + (|\omega|, \beta_{X_i}) + \beta_B) &= e_{3i} \end{aligned} \quad (3.208)$$

Eşitlik 3.207’de yer alan C parametresi pozitif reel sabit bir sayı olup algoritma içinde düzenleyici niteliktedir. $B = (m_B, \alpha_B, \beta_B)$ ’nin optimal değeri ile α_{1i} , α_{2i} ve α_{3i} Lagrange çarpanları ve ω ’nin değeri optimallik koşulları aracılığı ile elde edilebilmektedir. Bu amaçla Eşitlik 3.209’da yer alan Lagrange fonksiyonu oluşturulmuştur.

$$\begin{aligned} L &= \frac{1}{2} \|\omega\|^2 + \frac{C}{2} \sum_{k=1}^3 \sum_{i=1}^l e_{ki}^2 + \sum_{i=1}^l \alpha_{1i} (e_{1i} - m_{Y_i}) + \langle \omega, m_{X_i} \rangle + m_B \\ &\quad - \sum_{i=1}^l \alpha_{2i} (e_{2i} - (m_{Y_i} - \alpha_{Y_i}) + \langle \omega, m_{X_i} \rangle + m_B - (|\omega|, \alpha_{X_i}) - \alpha_B) \\ &\quad - \sum_{i=1}^l \alpha_{3i} (e_{3i} - (m_{Y_i} + \beta_{Y_i}) + \langle \omega, m_{X_i} \rangle + m_B + (|\omega|, \beta_{X_i}) + \beta_B) \end{aligned} \quad (3.209)$$

Optimallik koşulları Eşitlik 3.210-3.217’de belirtilmiştir:

$$\frac{\partial L}{\partial \omega} = 0 \quad \omega = \sum_{i=1}^l \alpha_{1i} m_{X_i} + \sum_{i=1}^l \alpha_{2i} (m_{X_i} - \text{sgn}(\omega) \alpha_{X_i}) + \sum_{i=1}^l \alpha_{3i} (m_{X_i} + \text{sgn}(\omega) \beta_{X_i}) \quad (3.210)$$

$$\frac{\partial L}{\partial m_B} = 0 \quad \sum_{k=1}^3 \sum_{i=1}^l \alpha_{ki} = 0 \quad (3.211)$$

$$\frac{\partial L}{\partial \alpha_B} = 0 \quad \sum_{i=1}^l \alpha_{2i} = 0 \quad (3.212)$$

$$\frac{\partial L}{\partial \beta_B} = 0 \quad \sum_{i=1}^l \alpha_{3i} = 0 \quad (3.213)$$

$$\frac{\partial L}{\partial e_{ki}} = 0 \quad e_{ki} = \frac{\alpha_{ki}}{C}, \quad k = 1, 2, 3 \quad (3.214)$$

$$\frac{\partial L}{\partial \alpha_{1i}} = 0 \quad m_{Y_i} - \langle \omega, m_{X_i} \rangle - m_B - e_{1i} = 0 \quad (3.215)$$

$$\frac{\partial L}{\partial \alpha_{2i}} = 0 \quad m_{Y_l} - \alpha Y_1 - \langle w, m_{X_l} \rangle - m_B + \langle |w|, \alpha X_1 \rangle + \alpha_B - e_{2i} = 0 \quad (3.216)$$

$$\frac{\partial L}{\partial \alpha_{3i}} = 0 \quad m_{Y_l} + \beta_{Y_l} - \langle w, m_{X_l} \rangle - m_B - \langle |w|, \beta X_1 \rangle - \beta_B - e_{3i} = 0 \quad (3.217)$$

Optimallik koşulları içinde $sgn(w) = (sgn(w_1), \dots, sgn(w_d))$ olarak tanımlanmaktadır. $B = (m_B, \alpha_B, \beta_B)$ 'nin optimal değeri ile α_{1i} , α_{2i} ve α_{3i} Lagrange çarpanları Eşitlik 3.218'de verilen doğrusal eşitlik yardımı ile elde edilebilir.

$$\begin{pmatrix} 0 & 0 & 0 & 1' & 1' & 1' \\ 0 & 0 & 0 & 0' & 1' & 0' \\ 0 & 0 & 0 & 0' & 0' & 1' \\ 1 & 0 & 0 & s_{11} & s_{12} & s_{13} \\ 1 & -1 & 0 & s'_{12} & s_{22} & s_{23} \\ 1 & 0 & 1 & s'_{13} & s'_{23} & s_{33} \end{pmatrix} \begin{pmatrix} m_B \\ \alpha_B \\ \beta_B \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ m_Y \\ m_Y - \alpha_Y \\ m_Y + \beta_Y \end{pmatrix} \quad (3.218)$$

$$s_{11} = [\langle m_{X_l}, m_{X_j} \rangle] + I/C \quad (3.219)$$

$$s_{12} = [\langle m_{X_l}, m_{X_j} - sgn(w)\alpha_{X_j} \rangle] \quad (3.220)$$

$$s_{13} = [\langle m_{X_l}, m_{X_j} + sgn(w)\beta_{X_j} \rangle] \quad (3.221)$$

$$s_{22} = [\langle m_{X_l} - sgn(w)\alpha_{X_l}, m_{X_j} - sgn(w)\alpha_{X_j} \rangle + I/C] \quad (3.222)$$

$$s_{23} = [\langle m_{X_l} - sgn(w)\alpha_{X_l}, m_{X_j} + sgn(w)\beta_{X_j} \rangle] \quad (3.223)$$

$$s_{33} = [\langle m_{X_l} + sgn(w)\beta_{X_l}, m_{X_j} + sgn(w)\beta_{X_j} \rangle] + I/C \quad (3.224)$$

Eşitlik 3.219-3.224'de $\alpha_1, \alpha_2, \alpha_3, m_Y, \alpha_Y$ ve β_Y ; $\alpha_{1i}, \alpha_{2i}, \alpha_{3i}, m_{Y_i}, \alpha_{Y_i}$ ve β_{Y_i} 'lerin sırası ile $l \times 1$ boyutlu vektörlerini ifade etmektedir. $[\alpha_{ij}]$ ise $n \times 1$ boyutlu matrisin α_{ij} elemanlarını temsil etmektedir. İşlemler tamamlandığında EKK-DVM tarafından verilen X_q verisi üzerinde $Y(X_q)$ 'ye ilişkin tahmin değeri elde edilmiş olunur. Bahsi geçen durumun matematiksel gösterimi Eşitlik 3.225'de yer almaktadır (Hong ve Hwang, 2006).

$$\hat{Y}(X_q) = (\langle w, m_{X_q} \rangle + m_B, \langle |w|, \alpha_{X_q} \rangle + \alpha_B, \langle |w|, \beta_{X_q} \rangle + \beta_B) \quad (3.225)$$

Bulanık doğrusal olmayan EKK-DVM regresyonu için Hong ve Hwang (2006) tarafından önerilen yöntem kapsamında, öncelikle bulanık girdilerin çok boyutlu özellik uzayında

EKK-DVM'na dayanan doğrusal regresyon analizi için anlatım yapılmıştır. Bu süreçte klasik doğrusal olmayan regresyon analizine ilişkin temel fikirler kullanılmıştır. $\Phi: R^d \rightarrow \mathcal{F}$ 'den özellik uzayı \mathcal{F} 'ye eşleştirilen x_i girdi deseninin ön işleme sürecinin gerçekleşmesinin ardından EKK-DVM yöntemine ait algoritmanın veriler üzerinde uygulaması yapılır. Burada dikkat edilmesi gereken husus, verilerin (x_i, x_j) nokta biçiminde verilecek olmasıdır. Burada $\langle \Phi(x_i), \Phi(x_j) \rangle$ formunda ifade edilen fonksiyon algoritmanın \mathcal{F} 'de tanımlanan noktalar yardımıyla veriye bağlandığını ifade etmektedir. Böylelikle $\Phi(\cdot)$ ifadesinin yerine $K(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle$ ifadesinin bilinmesi ve kullanımı algoritmanın işleyişi açısından yeterli olmaktadır (Hong ve Hwang, 2006).

İkinci dereceden Polinomiyal Kernel ve iki girdinin yer aldığı bir özellik uzayına ilişkin örnek üzerinde yapılan işlemler Eşitlik 3.226-3.228'de verilmektedir.

$$K(x, y) = (1 + \langle x, y \rangle)^2 \quad (3.226)$$

$$K(x, y) = (1 + x_1y_1 + x_2y_2)^2 \quad (3.227)$$

$$K(x, y) = 1 + 2x_1y_1 + 2x_2y_2 + (x_1y_1)^2 + (x_2y_2)^2 + 2x_1y_1x_2y_2 \quad (3.228)$$

Burada $\Phi(x) = (1, \sqrt{2}x_1, \sqrt{2}x_2, x_1^2, x_2^2, \sqrt{2}x_1x_2)$ olarak seçildiğinde $K(x, y) = (\Phi(x), \Phi(y))$ ifadesine ulaşılmaktadır. Üçgensel bulanık sayıların şeklinin korunması gerekliliğinden Φ fonksiyonu bulanık girdiler için artan olmalıdır. Üçgensel bulanık sayının şeklinin korunması; $m_{x_{ij}} - \alpha_{x_{ij}} \geq 0$ durumu söz konusu olduğunda, Polinomiyal Kernel ile ilişkili özellik eşleştirme fonksiyonu Φ artan nitelikte olması ile de ifade edilmektedir. Hong ve Hwang (2006) tarafından önerilen yöntemde Gaussian Kernel ile ilişkilendirilmiş özellik eşleştirme fonksiyonu bahsi geçen durum için yeterli bulunmadığından $m_{x_{ij}} - \alpha_{x_{ij}} \geq 0$ varsayımına bağlı olarak verilere basit bir transformasyon uygulanmıştır. Böylece analizlerde sadece Polinomiyal Kernel ile ilişkilendirilmiş özellik eşleştirme fonksiyonu var olmuştur. Araştırmacılar Kernel fonksiyonuna tercihen özellik eşleştirme fonksiyonu kullanmışlardır. $\Phi^*: T(R)^d \rightarrow T(\mathcal{F})$ şeklinde bir fonksiyon tanımlandığında Eşitlik 3.229'da yer alan ifadeye ulaşılır.

$$\Phi^*((m_X, \alpha_X, \beta_X)) = (\Phi(m_X), \Phi(m_X) - \Phi(m_X - \alpha_X), \Phi(m_X + \beta_X) - \Phi(m_X)) \quad (3.229)$$

$\alpha_{X_l}^\Phi$ ve $\beta_{X_l}^\Phi$ ifadeleri şu şekilde tanımlanmaktadır:

$$\alpha_{X_l}^\Phi = \Phi(m_{X_l}) - \Phi(m_{X_l} - \alpha_{X_l})$$

$$\beta_{X_l}^\Phi = \Phi(m_{X_l} + \beta_{X_l}) - \Phi(m_{X_l})$$

Doğrusal bulanık EKK-DVM'ındaki çözüm sürecine benzer şekilde Eşitlik 3.230'da yer alan ifade elde edilir.

$$w^\Phi = \sum_{i=1}^l \alpha_{1i} \Phi(m_{X_i}) + \sum_{i=1}^l \alpha_{2i} \Phi(m_{X_i}) - \text{sgn}(w^\Phi)(\alpha_{X_l}^\Phi) + \sum_{i=1}^l \alpha_{3i} \Phi(m_{X_i}) + \text{sgn}(w^\Phi)\beta_{X_l}^\Phi \quad (3.230)$$

Burada Eşitlik 3.230'da $w, m_X, \alpha_X, \beta_X$ ifadelerinin yerine $w^\Phi, \Phi(m_{X_l}), \alpha_{X_l}^\Phi, \beta_{X_l}^\Phi$ ifadeleri yazıldığında ve çözümlendiğinde $Y(X_q)$ 'ne ilişkin doğrusal olmayan tahmin değeri X_q verisi üzerinde elde edilmiş olunur. Bu durumun matematiksel gösterimi Eşitlik 3.231'de verilmektedir.

$$\hat{Y}(X_q) = (\langle w^\Phi, (m_{X_q}) \rangle + m_B, \langle |w^\Phi|, \alpha_{X_q}^\Phi \rangle + \alpha_B, \langle |w^\Phi|, \beta_{X_q}^\Phi \rangle + \beta_B) \quad (3.231)$$

Tez çalışması kapsamında en küçük kareler destek vektör makinelerine dayalı doğrusal olmayan bulanık regresyon analizini gerçekleştirmek üzere Hong ve Hwang (2006) tarafından önerilen yöntem kullanılmıştır. Verilerin eğitim, test ve geçerlilik süreçleri yapay sinir ağları ile gerçekleştirilen analizlere benzer şekilde yürütülmüştür. En küçük kareler destek vektör makinelerinin yer aldığı analizlerde üç farklı Kernel fonksiyonu kullanılmıştır. Tek değişkenli analizlerde Radial Basis Function (RBF), Polinomial Kernel fonksiyonu ve doğrusal Kernel fonksiyonu; çok değişkenli analizlerde ise sadece RBF Kernel fonksiyonu kullanılmıştır. RBF Kernel fonksiyonu içinde yer alan σ parametresi “10, 30, 50, 70 ve 90”; γ parametresi ise “0.1, 0.4, 0.7 ve 1” olacak şekilde analizlerde yer almıştır. Polinomial Kernel fonksiyonu dereceleri 1-5 arasında analiz edilmiştir.

4. ARAŞTIRMA BULGULARI

Tez çalışması kapsamında çok değişkenli doğrusal olmayan bulanık regresyon analizi yönteminin tarımsal verilerin modellenmesinde kullanım olanaklarını belirlemek amacıyla yumurta performans ve yumurta ağırlık verileri ile uygulamalar gerçekleştirilmiştir. Uygulamaların tamamında, verilerin zaman periyotları günlük ve haftalık olarak alınmış ve analizler ayrı ayrı gerçekleştirilmiştir. Araştırma bulguları, altı farklı kısımda incelenmiştir. Bu kısımların başlıkları; tek ve çok değişkenli klasik regresyon analizi, tek ve çok değişkenli yapay sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizi ile tek ve çok değişkenli en küçük kareler destek vektör makinelerine dayalı doğrusal olmayan bulanık regresyon analizi şeklinde oluşturulmuştur. Tek değişkenli analizlerde çıktı değişkeni sadece yumurta performansı olarak alınmıştır. Çok değişkenli analizlerde ise yumurta performansı ve yumurta ağırlığı olmak üzere iki çıktı değişkeni ile çalışılmıştır.

4.1 Tek Değişkenli Klasik Doğrusal Olmayan Regresyon Analizi Uygulama Sonuçları

Tek değişkenli klasik doğrusal olmayan regresyon analizi kapsamında yumurta performansını modellemek üzere dört farklı model yapısı ele alınmıştır. Lojistik, Compartmental, McNally ve Gamma modelleri ile gerçekleştirilen analizlerde gerçek ve tahmin değerlerine ilişkin grafiksel gösterimlere yer verilmiştir. Ayrıca, parametre tahmin değerleri ve standart hataları ile uyum iyiliği kriterlerinin sayısal sonuçları sunulmuştur. Günlük ölçülmüş veri seti 70 hafta; haftalık ölçülmüş veri seti ise 72 hafta boyunca kaydı alınmış verilerden oluşmaktadır. Günlük ölçülmüş verilerde en yüksek üretim noktasına 32. haftada, haftalık ölçülmüş verilerde ise 35. haftada ulaşıldığı gözlenmiştir.


Tablo 4.1'de günlük ölçülmüş veriler için tek değişkenli doğrusal olmayan klasik regresyon analizi sonuçları, parametre tahminleri ve standart hata değerleri ile elde edilen tahmin değerlerinin gerçek gözlem değerlerine karşılık hesaplanan HKO ve OMYH değerleri görülmektedir. Buna göre, istatistiksel hata kriterleri bakımından en iyi uyuma McNally modelinin sahip olduğu ve hata değerlerinin en yüksek olduğu modelin ise Compartmental model olduğu tespit edilmiştir. McNally modelinde HKO değeri 1.7433 ve OMYH değeri 3.1152; Compartmental modelde ise HKO değeri 11.7029 ve OMYH değeri

3.1152 olarak hesaplanmıştır. Logistic ve Gamma model ile elde edilen tahmin sonuçlarına ilişkin istatistiksel hata kriterlerinin birbirlerine yakın değerli olduğu görülmektedir. Tez çalışmasında elde edilen bulguların, literatürde yumurta performans (%) modellenmesini konu alan yayınlar ile uyum içinde olduğu belirlenmiştir.


Tablo 4.1: Günlük Ölçülmüş Veriler için Tek Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları.

Model	Parametre	Parametre Tahmin Değeri	Standart Hata	İstatistiksel Performans Kriterleri	
				HKO	OMYH
Logistic Model	<i>a</i>	102.348	0.28005	3.8583	2.1467
	<i>b</i>	0.282	0.02611		
	<i>c</i>	0.063	0.00151		
	<i>x</i>	0.001	0.00009		
Compartmental Model	<i>a</i>	99.979	0.4128	11.7029	3.1152
	<i>b</i>	0.085	0.0019		
	<i>c</i>	0.001	0.0001		
McNally Model	<i>a</i>	33.3759	0.4366	1.7433	1.3496
	<i>b</i>	0.3789	0.0081		
	<i>c</i>	0.0001	0.0007		
	<i>d</i>	-0.0693	0.0032		
Gamma	<i>a</i>	41.045	0.4327	3.4052	1.5315
	<i>b</i>	0.215	0.0026		
	<i>c</i>	0.02	0.0007		


Günlük ölçülmüş veriler için Şekil 4.1’de doğrusal olmayan regresyon analizi kapsamında ele alınan model yapılarından Logistic model; Şekil 4.2’de Compartmental model; Şekil 4.3’de McNally modeli; Şekil 4.4’de Gamma modeli ile elde edilen tahmin sonuçları ve gerçek değerlere ait grafiksel gösterimler yer almaktadır. Analizlerde yer alan tüm modellerin veri setlerine kabul edilebilir bir uyum sağladığı görülmektedir. Grafiksel analizler incelendiğinde yumurta performansına ilişkin en yüksek değeri en başarılı şekilde yakalayan modellerin McNally ve Gamma modelleri olduğu belirlenmiştir. Bunun yanı sıra Logistic ve Compartmental modellerin, üretimin en yüksek olduğu seviyede eğrinin bükülme noktasında yeterli esnekliği sunamadığı görülmektedir. Ayrıca “*a*” parametresi; Logistic ve Compartmental modellerin birlikte, McNally ve Gamma modellerin de kendi içinde birlikte birbirine daha yakın değerlerde tahmin edilmiştir. “*a*” parametresi yumurta üretim performansının biyolojik açıdan yorumlanmasında ve özellikle aynı hatların farklı nesilleri veya farklı tavuk ırklarının performans karşılaştırmasında kullanılabilir.




Şekil 4.1: Günlük Ölçülmüş Gerçek Değerler ve Lojistik Model Tahmin Sonuçları.



Şekil 4.2: Günlük Ölçülmüş Gerçek Değerler ve Compartmental Model Tahmin Sonuçları.



Şekil 4.3: Günlük Ölçülmüş Gerçek Değerler ve McNally Model Tahmin Sonuçları.



Şekil 4.4: Günlük Ölçülmüş Gerçek Değerler ve Gamma Model Tahmin Sonuçları.


Tablo 4.2: Haftalık Ölçülmüş Veriler için Tek Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları.

Model	Parametre	Parametre Tahmin Değeri	Standart Hata	İstatistiksel Performans Kriterleri	
				HKO	OMYH
Logistic Model	a	105.194	0.990	7.305	3.029
	b	0.931	0.111		
	c	0.505	0.038		
	x	0.004	0.000		
Compartmental Model	a	105.796	1.007	7.477	2.787
	b	0.365	0.015		
	c	0.04	0.000		
McNally Model	a	62.659	2.032	5.930	2.327
	b	0.650	0.057		
	c	-0.007	0.003		
	d	-0.356	0.056		
Gamma	a	53.517	1.641	10.120	2.598
	b	0.288	0.014		
	c	0.013	0.010		


Tablo 4.2’de haftalık ölçülmüş veriler için tek değişkenli doğrusal olmayan klasik regresyon analizi sonuçları, parametre tahminleri ve standart hata değerleri ile elde edilen tahmin değerlerinin gerçek gözlem değerlerine karşılık hesaplanan HKO ve OMYH görülmektedir. Günlük ölçülmüş verilere benzer şekilde, istatistiksel hata kriterleri bakımından en iyi uyuma McNally modelinin sahip olduğu ve hata değerlerinin en yüksek olduğu modelin ise Gamma model olduğu tespit edilmiştir. McNally modelinde HKO değeri 5.930 ve OMYH değeri 2.327; Gamma modelinde ise HKO değeri 10.120 ve OMYH değeri 2.598 olarak hesaplanmıştır. Haftalık verilere ilişkin tahmin sonuçlarında, günlük verilerden farklı olarak, Logistic ve Compartmental model ile elde edilen hata kriteri değerlerinin birbirlerine yakın olduğu görülmektedir. Analiz bulgularına göre, veri

setinde yer alan gözlem sayılarının değişimine karşılık incelenen model yapıları arasında McNally modelinin daha tutarlı sonuçlara sahip olduğu görülmektedir.


Haftalık ölçülmüş veriler için Şekil 4.5’de Logistic model; Şekil 4.6’da Compartmental model; Şekil 4.7’de McNally modeli; Şekil 4.8’de Gamma modeli ile elde edilen tahmin sonuçları ve gerçek değerlere ait grafiksel gösterimler yer almaktadır. Analizlerde yer alan tüm modeller veri setlerine iyi uyum sağlamıştır. Grafiksel gösterimler ve istatistiksel performans kriterleri incelendiğinde günlük ölçülmüş verilerle gerçekleştirilen analizlerde, Compartmental model dışındaki modellerin daha iyi tahminler yaptığı görülmektedir. Bu durum incelenen modellerin veri seti büyüklüğünden etkilendiğini göstermektedir.




Şekil 4.5: Haftalık Ölçülmüş Gerçek Değerler ve Logistic Model Tahmin Sonuçları.



Şekil 4.6: Haftalık Ölçülmüş Gerçek Değerler ve Compartmental Model Tahmin Sonuçları.



Şekil 4.7: Haftalık Ölçülmüş Gerçek Değerler ve McNally Model Tahmin Sonuçları.



Şekil 4.8: Haftalık Ölçülmüş Gerçek Değerler ve Gamma Model Tahmin Sonuçları.

4.2. Çok Değişkenli Klasik Doğrusal Olmayan Regresyon Analizi Uygulama Sonuçları

Tez çalışması kapsamında çok değişkenli doğrusal olmayan klasik regresyon analizini gerçekleştirmek üzere yumurta performansı ve yumurta ağırlığı değişkenleri ile çalışılmıştır. Analizler, günlük ve haftalık olarak ölçülmüş veri setleri için ayrı ayrı gerçekleştirilmiştir. Tablo 4.3’de günlük ölçülmüş verilere çok değişkenli klasik regresyon analizi uygulanması sonucunda elde edilen parametre tahmin değerleri ile bunlara karşılık gelen standart hata değerleri yer almaktadır. Buna göre, günlük verilerde HKO ve OMYH değerleri; yumurta performansı için sırasıyla 1.8482 ve 1.3365 iken yumurta ağırlığı için 0.2712 ve 0.6255 olarak hesaplanmıştır.

Tablo 4.4’de haftalık ölçülmüş veriler için yumurta performansı ve yumurta ağırlığı değişkenlerine ilişkin gerçek gözlem değerlerine göre hesaplanmış HKO ve OMYH değerleri ile çok değişkenli klasik regresyon analizi uygulaması sonucunda elde edilen

parametre tahmin değerleri ile bunlara karşılık gelen standart hata değerleri yer almaktadır. Buna göre, haftalık verilerde HKO ve OMYH değerleri; yumurta performansı için sırasıyla 6.2872 ve 2.3776 iken yumurta ağırlığı için 0.2236 ve 0.5664 olarak hesaplanmıştır. Analiz sonuçları yumurta ağırlığı değişkenine ilişkin istatistiksel performans kriterlerinin daha başarılı olduğunu göstermektedir.


Tablo 4.3: Günlük Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları.

Değişken	Parametre	Parametre Tahmin Değeri	Standart Hata	İstatistiksel Performans Kriterleri	
				HKO	OMYH
Yumurta Performansı	a	3.5363	0.0096	1.8482	1.3365
	b	0.3466	0.0069		
	c	-0.0005	0.000074		
	d	-0.0538	0.0031		
Yumurta Ağırlığı	a	3.6526	0.0047	0.2712	0.6255
	b	0.1117	0.0034		
	c	-0.0001	3.6839		
	d	-0.0042	0.0015		


Tablo 4.4: Haftalık Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi HKO ve OMYH Sonuçları.

Değişken	Parametre	Parametre Tahmin Değeri	Standart Hata	İstatistiksel Performans Kriterleri	
				HKO	OMYH
Yumurta Performansı	a	4.120	0.0326	6.2872	2.3776
	b	0.711	0.0435		
	c	0.008	0.0026		
	d	-0.409	0.0459		
Yumurta Ağırlığı	a	3.765	0.0096	0.2236	0.5664
	b	0.234	0.0128		
	c	0.003	0.0008		
	d	-0.096	0.0135		

Yumurta performansı ve yumurta ağırlığı değişkenlerinin zamana bağlı değişimi günlük veriler için Şekil 4.9'da; haftalık verilerde ise Şekil 4.10'da ortaya konmuştur. Şekil 4.9'da günlük ölçülmüş veriler için yumurta performansı ve yumurta ağırlığı değişkenlerinin gerçek gözlem değerleri ve tahmin değerlerine ilişkin aynı düzlem üzerinde grafiksel gösterimler yer almaktadır. Şekil 4.10'da haftalık ölçülmüş veriler için yumurta performansı ve yumurta ağırlığı değişkenlerinin tahmin ve Gerçek değerlere ilişkin grafiksel gösterimleri bulunmaktadır. Günlük ve haftalık veriler için gerçekleştirilen analiz sonuçları incelendiğinde gerçek değerler ve tahmin değerlerine ait eğrilerin birbirlerine yakın seyir ettiği görülmektedir. Günlük verilerle gerçekleştirilen analizlerde, yumurta performans eğrisinin tepe noktasının haftalık verilere göre daha başarılı şekilde tahmin edildiği görülmektedir.



Şekil 4.9: Günlük Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi Sonuçları.



Şekil 4.10: Haftalık Ölçülmüş Veriler için Çok Değişkenli Doğrusal Olmayan Klasik Regresyon Analizi Sonuçları.


4.3. Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları

Yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi sürecinde yumurta performansını modellemek üzere çok sayıda farklı yapay sinir ağı mimarileri tasarlanmıştır. Yapay sinir ağları doğrusal olmayan bulanık regresyon analizinin alt ve üst tahmin sınırlarını belirlemek amacıyla kullanılmıştır. Analizlerde eğitim süreci iki aşamalı olarak tamamlanmıştır. Öncelikle eğitim seti ağa sunulmuş ve sonrasında sinir ağlarının genelleştirme yeteneğini kazanıp kazanmadığını belirlemek için test ve geçerlilik setleri ile performans kriterleri hesaplanmıştır.


Tablo 4.5: Günlük Ölçülmüş Veriler için Sinir Ağlarına Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

Geri Yayılım Algoritmaları	Aktivasyon Fonksiyonları	HKO		OMYH	
		Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
Bayesian Regularization (BR)	TanSig	0.005	0.068	0.004	0.060
	LogSig	0.006	0.074	0.006	0.075
Levenberg-Marquardt (LM)	TanSig	0.020	0.138	0.022	0.141
	LogSig	0.019	0.132	0.024	0.142
Scaled Conjugate Gradient (SCG)	TanSig	0.418	0.568	0.398	0.545
	LogSig	0.739	0.860	0.743	0.849
Gradient Descent (GD)	TanSig	0.919	0.901	0.776	0.839
	LogSig	1.816	1.278	1.773	1.238
Gradient Descent with Momentum (GDM)	TanSig	54.26	3.922	37.91	3.145
	LogSig	7.466	2.556	5.396	2.320
Gradient Descent with Momentum and Adaptive Learning Rate (GDX)	TanSig	58.67	6.148	45.69	5.501
	LogSig	77.33	7.488	61.50	6.793
Conjugate Gradient	TanSig	52.10	4.620	37.98	3.932
Backpropagation with Fletcher-Reeves Updates (CGF)	LogSig	56.07	5.459	39.84	4.723
Conjugate Gradient	TanSig	0.401	0.567	0.400	0.564
Backpropagation with Powell-Beale Restarts (CGB)	LogSig	0.054	0.207	0.058	0.206
Brayde Fletcher Gold Farlo Shanno	TanSig	0.068	0.255	0.067	0.251
Quasi Newton Backpropagation (BFG)	LogSig	0.255	0.455	0.279	0.477
One Step Secant Algorithm (OSS)	TanSig	0.679	0.695	0.506	0.633
	LogSig	1.992	1.274	1.310	1.108


Tablo 4.5’de günlük veriler için yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Analizlerde merkez değerler, test seti için elde edilen alt ve üst sınır değerleri ile geçerlilik seti için elde edilen alt ve üst sınır değerler kullanılarak, her veri seti için ayrı elde edilmiştir. Merkez değerler ve gözlem değerleri kullanılarak hesaplanan HKO ve OMYH kriterleri, test ve geçerlilik setleri için her algoritmada iki farklı aktivasyon fonksiyonunda sunulmuştur. BR algoritması ve Tan-Sig aktivasyon fonksiyonu ile yapılandırılmış sinir ağı mimarilerinin kullanıldığı tek değişkenli bulanık regresyon analiz sonuçları diğer algoritmalara göre daha başarılı bulunmuştur. Sonuçlar test ve geçerlilik setlerinde uyum göstermektedir. BR algoritmasını takiben LM algoritması analizlerde başarı göstermiştir. LM algoritması, BR algoritmasına göre çok daha hızlı çalışmaktadır ve daha az iterasyon ile başarılı tahminler üretmiştir.





(a)




(b)







(c)



Şekil 4.11: Günlük Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.







Şekil 4.12: Günlük Ölçülmüş Geçerlilik Verileri İçin Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.


Doğrusal olmayan bulanık regresyon analizi sürecinde farklı h -seviye kümeleri oluşturulmuştur. Bu bağlamda analizlerde h değeri “0.1, 0.3, 0.5, 0.7 ve 0.9” olacak şekilde yer almıştır. Şekil 4.11’de günlük ölçülmüş test verileri için, Şekil 4.12’de geçerlilik verileri için yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Grafikselleştirimler sadece BR algoritması için verilmiştir. Günlük ölçülmüş veriler için test ve geçerlilik setlerinde sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin 0.5, 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisinin tipik görünümünü sergilediğini göstermektedir. Bulanık regresyon analizinde h seviyesinin belirlenmesi araştırmacıların tercihine bırakılmıştır.




Tablo 4.6’da haftalık ölçülmüş veriler için yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Analiz sonuçları günlük ölçülmüş veriler için elde edilen tahmin sonuçlarına benzer şekilde, BR algoritması ve Tan-Sig aktivasyon fonksiyonu ile yapılandırılmış sinir ağı mimarilerinin kullanıldığı tek değişkenli bulanık regresyon analizlerinin diğer algoritmalara göre daha başarılı olduğunu göstermektedir. Doğrusal olmayan bulanık regresyon analizinde grafikselleştirimler test seti için Şekil 4.13, geçerlilik seti için Şekil 4.14’de yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Grafikselleştirimler BR


algoritması için verilmiştir. Doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisinin tipik görünümünü sergilediğini göstermektedir.

Tablo 4.6: Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.



Geri Yayılım Algoritmaları	Aktivasyon Fonksiyonları	HKO		OMYH	
		Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
Bayesian Regularization (BR)	TanSig	0.255	0.272	0.465	0.538
	LogSig	0.496	1.924	0.748	1.261
Levenberg-Marquardt (LM)	TanSig	0.491	0.339	0.739	0.617
	LogSig	110.9	130.5	10.31	11.16
Scaled Conjugate Gradient (SCG)	TanSig	1.859	1.475	1.476	1.221
	LogSig	6.581	83.44	1.979	5.683
Gradient Descent (GD)	TanSig	39.34	52.36	6.118	7.624
	LogSig	22.10	95.39	4.244	7.508
Gradient Descent with Momentum (GDM)	TanSig	60.67	107.9	8.037	11.07
	LogSig	90.65	90.49	9.641	10.12
Gradient Descent with Momentum and Adaptive Learning Rate (GDX)	TanSig	171.8	108.9	12.97	9.053
	LogSig	29.22	109.2	5.500	9.003
Conjugate Gradient Backpropagation with Fletcher-Reeves Updates (CGF)	TanSig	5.858	3.257	2.003	1.855
	LogSig	16.59	54.66	4.681	7.179
Conjugate Gradient Backpropagation with Powell-Beale Restarts (CGB)	TanSig	3.346	3.847	1.886	2.225
	LogSig	91.47	78.59	8.834	8.304
Brayde Fletcher Gold Farlo Shanno Quasi Newton Backpropagation (BFG)	TanSig	3.189	8.452	1.666	2.616
	LogSig	38.53	102.8	5.796	8.829
One Step Secant Algorithm (OSS)	TanSig	109.5	94.31	9.503	8.709
	LogSig	96.72	156.7	9.639	12.47










Şekil 4.13: Haftalık Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.





Şekil 4.14: Haftalık Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.7’de günlük ölçülmüş veriler için ve Tablo 4.8’de haftalık ölçülmüş veriler için elde edilen OMH değerleri bulunmaktadır. Analiz sonuçlarında test ve geçerlilik setlerine ilişkin, beş farklı h seviyesinde üç farklı tür ortalama mutlak hata sonuçları yer almaktadır. OMH^+ , OMH^- ve OMH^c ifadeleri doğrusal olmayan bulanık regresyon analizinde tahmin edilen bulanık çıktının sırasıyla üst sınır, alt sınır ve merkez değerinin gerçek gözlem

değerlerine ne kadar yakın olduğunu belirtmektedir. OMG^w ise verilen h seviyesi için tahminlenen aralığın genişliğini açıklamaktadır. OMH değerleri, grafiksel gösterimlerde h seviyesindeki artış ve azalışlara bağlı olarak meydana gelen daralma ve genişlemenin sayısal bulguları olarak verilmiştir. Buna göre günlük ölçülmüş veriler için test setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 17.219; alt sınırı arasındaki ortalama uzaklık 17.230; aralığın merkezi arasındaki ortalama uzaklık ise 0.0538 olarak hesaplanmıştır. Haftalık ölçülmüş veriler için test setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 17.831; alt sınırı arasındaki ortalama uzaklık 17.648; aralığın merkezi arasındaki ortalama uzaklık ise 0.3964 olarak hesaplanmıştır. Günlük ölçülmüş veriler için geçerlilik setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 17.286; alt sınırı arasındaki ortalama uzaklık 17.287; aralığın merkezi arasındaki ortalama uzaklık ise 0.0507 olarak hesaplanmıştır. Haftalık ölçülmüş veriler için geçerlilik setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 17.475; alt sınırı arasındaki ortalama uzaklık 16.824; aralığın merkezi arasındaki ortalama uzaklık ise 0.4373 olarak hesaplanmıştır. Tablo 4.7 ve Tablo 4.8’de üst ve alt tahmin sınırlarının, analizlerde simetrik üçgensel bulanık sayı kullanıldığından dolayı birbirlerine oldukça yakın değerler aldıkları görülmektedir. Gözlenen veri noktalarının her biri bütün h seviyelerinde tahmini regresyon eğrileri etrafında aralık içerisinde yer almaktadır. Analiz sonuçları h değerinde meydana gelen artış ile birlikte bulanık tahmin aralığında bir daralmanın meydana geldiğini göstermektedir.

Tablo 4.7: Günlük Ölçülmüş Veriler için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.

Veri Seti	h -seviye	OMH^+	OMH^-	OMH^c	OMG^w
Test Seti	0.1	361.71	361.72	0.0538	803.83
	0.3	93.775	93.785	0.0538	267.94
	0.5	40.186	40.196	0.0538	160.76
	0.7	17.219	17.230	0.0538	114.83
	0.9	4.4605	4.4708	0.0538	89.314
Geçerlilik Seti	0.1	363.03	363.03	0.0507	806.73
	0.3	94.118	94.119	0.0507	268.91
	0.5	40.336	40.337	0.0507	161.34
	0.7	17.286	17.287	0.0507	115.24
	0.9	4.4813	4.4824	0.0507	89.637

Tablo 4.8: Haftalık Ölçülmüş Veriler için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.

Veri Seti	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMG ^w
Test Seti	0.1	372.63	372.45	0.3964	827.86
	0.3	96.676	96.493	0.3964	275.95
	0.5	41.484	41.302	0.3964	165.57
	0.7	17.831	17.648	0.3964	118.26
	0.9	4.6905	4.5079	0.3964	91.985
Geçerlilik Seti	0.1	360.47	359.82	0.4373	800.34
	0.3	93.698	93.047	0.4373	266.78
	0.5	40.342	39.691	0.4373	160.06
	0.7	17.475	16.824	0.4373	114.33
	0.9	4.7719	4.1207	0.4373	88.926

Bulanık tahmin aralığında oluşan daralma modelde yer alan bulanıklığın azalmasına sebebiyet vermektedir. Bulanık regresyon analizinde amaç sistemde yer alan bulanıklığı sayısallaştırarak klasik regresyona göre daha esnek sınırlar çerçevesinde tahminler sağlamaktır. Bu bilgiler ışığında, yumurta performans eğrisinin bulanık regresyon ile modellenmesinde h seviyesinin 0.7 olduğu değerin analize konu olan veri seti için uygun olduğu gözlenmiştir.

Yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi tahmin sonuçlarının, tek değişkenli klasik doğrusal olmayan bulanık regresyon analizi sonuçlarına göre çok daha başarılı olduğu görülmektedir. Klasik regresyon analizinde verilerin uyumu verilerin miktarı ve parametrelerin başlangıç değerleri ile yakın ilişkilidir. Ayrıca veri girişi seriler halinde gerçekleşir. Sinir ağlarında ise uyum süreci klasik regresyona göre oldukça hızlıdır. Bunun nedeni, sinir ağları yapısında bulunan sinaptik ağırlıklar öğrenme işlemi sırasında otomatik olarak ayarlanır ve veriler katmanlar boyunca paralel olarak yerleştirilir. Çalışmada yer alan diğer geri yayılım algoritmaları ile karşılaştırıldığında BR algoritmasının eğitim süresi ve iterasyon sayısının daha fazla olduğu; en hızlı çalışan algoritmanın ise LM algoritmasının olduğu gözlemlenmiştir. Literatürde, özellikle çok büyük veri setleri ile çalışıldığı takdirde hızlı çalışan algoritmalar tercih sebebi olabilmektedir. Ancak bu çalışmada yer alan veri setleri için en doğru tahmin değerlerini ve doğrusal olmayan yapıyı yakalayan algoritma BR algoritması olmuştur.

Tablo 4.9-12’de sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin yapay sinir ağlarına dayalı tek değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Buna göre tablolarda; gerçek gözlem değerleri, bulanık regresyon uygulaması sonucu elde edilen alt tahmin, üst tahmin ve

merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır. Tablolarda, gerçek değerler ve bulanık tahmin aralığının merkez değerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir. Burada yumurta performansı değişkenine ilişkin gerçekleşmesi beklenen olası muhtemel bir aralık oluşturulmuştur. Bağımlı değişken gözlem değerleri üçgensel bulanık sayı olmak üzere bulanık tahmin aralığı elde edilmiştir. Tahmin aralığı olası minimum ve maksimum yumurta performans değerleri ile sınırlandırılmıştır.

Tablo 4.9: Günlük Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
52.47	58.85	45.97	52.41	21.47
92.7	112.7	72.68	92.73	66.81
89.77	108.8	70.73	89.77	63.46
80.52	96.39	64.57	80.48	53.02
71.67	84.41	58.64	71.53	42.95

Tablo 4.10: Günlük Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
60.05	69.16	51.07	60.12	30.14
92.67	112.6	72.64	92.67	66.75
89.65	108.5	70.62	89.61	63.27
80.25	96.08	64.42	80.25	52.77
71.24	84.04	58.45	71.25	42.64

Tablo 4.11: Haftalık Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
91.5	109.6	71.05	90.35	64.35
91.5	111.9	72.07	92.03	66.52
85.9	104.2	68.3	86.27	59.89
83.9	100.9	66.7	83.83	57.09
73.8	88.69	60.62	74.66	46.77

Tablo 4.12: Haftalık Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
89.2	107.6	70.17	88.9	62.42
91.9	112.8	72.47	92.64	67.22
86.8	105.4	68.92	87.19	60.87
84.7	102.3	67.4	84.86	58.2
75.2	90.56	61.57	76.07	48.32

Şekil 4.13 ve Şekil 4.14’de görüleceği üzere Tablo 4.9-12’de bağımlı değişken değerindeki artışın yayılım miktarını arttırdığı, daha küçük değerlerde yayılım miktarının azaldığı

görülmektedir. Bu durum bağımlı değişkenin bulanıklığının gözlem değerlerinin küçük ve büyük olmasına göre değişebileceğini bildirmektedir.

4.4. Yapay Sinir Ağları Yardımıyla Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Tahmin Sonuçları

Yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi sürecinde yumurta performansı ve yumurta ağırlığını modellemek üzere çok sayıda farklı yapay sinir ağı mimarileri tasarlanmıştır. Çok değişkenli doğrusal olmayan bulanık regresyon analizinde eğitilen sinir ağı mimarileri, girdi değişkeni zaman ve çıktı değişkenleri yumurta performansı ile yumurta ağırlığı olacak şekilde oluşturulmuştur. Yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizine benzer şekilde, çok değişkenli analizlerde de çok katmanlı geri yayılım algoritmaları ileri beslemeli sinir ağı modeli kullanılmıştır.

Sinir ağlarının eğitim sürecinde 10 farklı geri yayılım algoritması kullanılmıştır. Bunlar; Bayesian Regularization (BR), Levenberg- Marquardt (LM), Scaled Conjugate Gradient (SCG), Gradient Descent (GD), Gradient Descent with Momentum (GDM), Gradient Descent with Momentum and Adaptive Learning Rate (GDX), Conjugate Gradient Backpropagation with Fletcher-Reeves Updates (CGF), Conjugate Gradient Backpropagation with Powell-Beale Restarts (CGB), Brayde Fletcher Gold Farlo Shanno Quasi Newton Backpropagation (BFG) ve One Step Secant Algorithm (OSS) şeklindedir. Analizler günlük ve haftalık kaydı alınmış veri setleri kullanılarak yapılmıştır. Yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi süreci tek değişkenli analizlere benzer şekilde yürütülmüştür.

Tablo 4.13'de günlük veriler için yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Analizlerde merkez değerler, test seti ve geçerlilik seti için elde edilen alt ve üst sınır değerleri kullanılarak, her veri seti için ayrı elde edilmiştir. Tabloda yer alan HKO ve OMYH değerleri incelendiğinde, YP ve YA çıktı değişkenlerine ilişkin en başarılı tahmin değerlerinin BR algoritması ve TanSig aktivasyon fonksiyonu ile yapılandırılmış sinir ağı mimarilerinin kullanıldığı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edildiği görülmektedir. Merkez değerler ve

gözlem değerleri kullanılarak hesaplanan HKO ve OMYH kriterleri, test ve geçerlilik setleri için her algoritmada iki farklı aktivasyon fonksiyonunda sunulmuştur.


Tablo 4.13: Günlük Ölçülmüş Veriler için Sınır Ağlarına Dayanan Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.




Geri Yayılım Algoritmaları	Değişken	Aktivasyon Fonksiyonları	HKO		OMYH	
			Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
BR	YP	TanSig	0.0109	0.0109	0.0991	0.0946
	YA	TanSig	0.0038	0.0041	0.0754	0.0710
	YP	LogSig	0.0138	0.0138	0.1119	0.1119
	YA	LogSig	0.0111	0.0107	0.1235	0.1162
LM	YP	TanSig	0.0226	0.0290	0.1475	0.1619
	YA	TanSig	0.0224	0.0217	0.1925	0.1862
	YP	LogSig	0.0172	0.0141	0.1242	0.1156
	YA	LogSig	0.0159	0.0158	0.1590	0.1554
SCG	YP	TanSig	135.56	124.29	11.353	10.809
	YA	TanSig	0.2121	0.1147	0.4889	0.4324
	YP	LogSig	1.7940	1.4456	1.2455	1.1326
	YA	LogSig	0.2762	0.2730	0.7215	0.7129
GD	YP	TanSig	1.8449	1.5817	1.3640	1.2929
	YA	TanSig	0.3810	0.3048	0.6908	0.6398
	YP	LogSig	118.31	118.52	11.584	11.444
	YA	LogSig	22.664	22.007	5.6295	5.5113
GDM	YP	TanSig	106.95	110.12	9.6136	9.6920
	YA	TanSig	2.9569	2.9357	2.3376	2.3141
	YP	LogSig	5.0592	3.9970	2.1303	1.9378
	YA	LogSig	6.8206	6.2654	3.7353	3.6173
GDX	YP	TanSig	111.48	115.09	10.027	10.175
	YA	TanSig	0.8936	335.41	1.1451	28.219
	YP	LogSig	71.928	58.946	7.4994	6.8860
	YA	LogSig	1.1573	335.06	1.2728	28.190
CGF	YP	TanSig	1.0148	0.7074	0.7100	0.6063
	YA	TanSig	0.1119	0.1078	0.4513	0.4379
	YP	LogSig	0.5778	0.4055	0.6180	0.5447
	YA	LogSig	25.401	22.613	5.5942	5.2949
CGB	YP	TanSig	0.1201	0.1142	0.3152	0.2998
	YA	TanSig	0.0403	0.0398	0.2614	0.2557
	YP	LogSig	0.4902	0.3473	0.5033	0.4546
	YA	LogSig	24.538	21.707	5.4978	5.1881
BFG	YP	TanSig	0.0531	0.0534	0.2138	0.2080
	YA	TanSig	0.0264	0.0246	0.2135	0.2039
	YP	LogSig	89.148	89.907	8.9225	8.8195
	YA	LogSig	0.0735	0.0739	0.3464	0.3459
OSS	YP	TanSig	0.1730	0.1717	0.3718	0.3719
	YA	TanSig	0.4531	0.3937	0.7969	0.7515
	YP	LogSig	135.61	124.24	11.338	10.791
	YA	LogSig	0.3206	0.2535	0.6890	0.6398


Tablo 4.13’de yer alan bulgulara göre günlük verilerde test seti için elde edilen en düşük HKO: YP için 0.0109, YA için 0.0038; elde edilen en düşük OMYH: YP için 0.0991, YA için 0.0754 şeklindedir. Geçerlilik seti için elde edilen en düşük HKO: YP için 0.0109, YA için 0.0041; elde edilen en düşük OMYH: YP için 0.0946, YA için 0.0710 şeklindedir. Gözlem değerleri ve merkez değerler kullanılarak elde edilen bu hesaplamalar, doğrusal

olmayan klasik regresyon analizi sonuçları (Tablo 4.3) ile karşılaştırıldığında sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizinin HKO ve OMYH değerlerine göre oldukça başarılı olduğu görülmektedir. Bunun yanı sıra, analizlerde kullanılan LogSig aktivasyon fonksiyonunun algoritmaların büyük bir bölümünde yüksek değerli hata kriterlerine sahip olduğu gözlenmiştir. İncelenen algoritmalar içinde özellikle GD, GDM ve GDX algoritmalarının tahmin başarılarının oldukça düşük olduğu gözlenmiştir. Bahsi geçen algoritmaların verilerin sahip olduğu doğrusal olmayan yapıyı yakalayamadığı, elde edilen tahmin değerlerinde pik seviyesinden sonra tekrar eden değerlerin olduğu ve oldukça yüksek iterasyon sayılarına sahip oldukları belirlenmiştir. Tabloda yer alan algoritmaların büyük bir bölümünde YP değişkeninin YA değişkenine göre çok daha yüksek hata kriteri değerlerine sahip olduğu görülmektedir. Bu durumun YP değişkenine ilişkin varyasyonun YA değişkenine göre daha yüksek olması ile ilişkili olduğu düşünülmektedir. Sonuçlar test ve geçerlilik setlerinde uyum göstermektedir. BR algoritmasını takiben LM algoritması analizlerde başarı göstermiştir.



Şekil 4.15 ve Şekil 4.16'da sırasıyla test ve geçerlilik seti için yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Analizlerde en başarılı tahmin değerleri BR algoritması ile elde edildiğinden dolayı, grafiksel gösterimler sadece BR algoritması için verilmiştir. Doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisi ile yumurta ağırlığı eğrisinin tipik görünümünü sergilediğini göstermektedir (Şekil 4.15, Şekil 4.16).









Şekil 4.15: Günlük Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.






(c)



(d)



(e)

Şekil 4.16: Günlük Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.14'de haftalık veriler için yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Analiz sonuçları tek değişkenli analizlere benzer şekilde, BR algoritması ve Tan-Sig aktivasyon fonksiyonu ile yapılandırılmış sinir

ağı mimarilerinin kullanıldığı çok değişkenli bulanık regresyon analizlerinin diğer algoritmalara göre daha başarılı olduğunu göstermektedir.




Tablo 4.14’de haftalık veriler için elde edilen bulgular, test seti için elde edilen en düşük HKO: YP için 0.0898, YA için 0.0047; elde edilen en düşük OMYH: YP için 0.2622, YA için 0.0932 olduğunu göstermektedir. Geçerlilik seti için elde edilen en düşük HKO: YP için 0.0660, YA için 0.0044; elde edilen en düşük OMYH: YP için 0.1970, YA için 0.0833 şeklindedir. Günlük ölçülmüş verilerin araştırma bulgularına benzer şekilde, sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizinin doğrusal olmayan klasik regresyon analizi ile karşılaştırıldığında, HKO ve OMYH değerlerine göre çok daha başarılı olduğu görülmektedir. İncelenen algoritmalar içinde özellikle GD, GDM, GDX, CGF ve OSS algoritmalarının tahmin başarılarının oldukça düşük olduğu gözlenmiştir. Bahsi geçen algoritmalar günlük ölçülmüş verilerde olduğu gibi, verilerin sahip olduğu doğrusal olmayan yapıyı yakalayamamıştır.


Tablo 4.14’de yer alan algoritmaların büyük bir bölümünde, ele alınan her iki aktivasyon fonksiyonunda da YP değişkeninin YA değişkenine göre çok daha yüksek hata kriteri değerlerine sahip olduğu görülmektedir. Grafikselleştirilmelerde haftalık ölçülmüş verilerin yapısı günlük ölçülmüş verilerin yapısı ile benzerlik göstermektedir. HKO değerlerinde iki değişken arasında oluşan farklılığın, YP değişkenine ilişkin varyasyonun YA değişkenine göre daha yüksek olması ile ilişkili olduğu düşünülmektedir. Sonuçlar test ve geçerlilik setlerinde uyum göstermektedir. BR algoritmasını takiben LM algoritması analizlerde başarı göstermiştir.

Şekil 4.17 ve Şekil 4.18’de sırasıyla test ve geçerlilik seti için yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Analizlerde en başarılı tahmin değerleri BR algoritması ile elde edildiğinden dolayı, grafikselleştirilmeler sadece BR algoritması için verilmiştir. Doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisi ile yumurta ağırlığı eğrisinin tipik görünümünü sergilediğini göstermektedir. Haftalık ölçülmüş test ve geçerlilik veri setleri, günlük ölçülmüş veri setlerine göre daha az gözlem sayısı içermektedir. Bu duruma rağmen, sinir ağlarının yumurta performans eğrilerine ilişkin yapıyı doğru bir şekilde öğrendiği, bulanık tahmin aralığının üst sınırını, alt sınırını ve merkez değerlerini temsil eden eğrilerin grafikselleştirilmelerinde görülebilmektedir.


Tablo 4.14: Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

Geri Yayılm Algoritmaları	Değişken	Aktivasyon Fonksiyonları	HKO		OMYH	
			Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
BR	YP	TanSig	0.0898	0.0660	0.2622	0.1970
	YA	TanSig	0.0047	0.0044	0.0932	0.0833
	YP	LogSig	0.3369	0.0853	0.4186	0.2377
LM	YA	LogSig	0.0089	0.0098	0.1104	0.1054
	YP	TanSig	0.1513	0.1827	0.3301	0.3416
	YA	TanSig	0.0136	0.0045	0.1530	0.0846
SCG	YP	LogSig	0.3677	8.9919	0.3933	2.2071
	YA	LogSig	0.0051	0.0070	0.0936	0.1087
	YP	TanSig	1.4896	0.2791	0.8281	0.4633
GD	YA	TanSig	0.2174	0.1621	0.5620	0.5636
	YP	LogSig	0.5992	0.7572	0.7225	0.7125
	YA	LogSig	0.1394	0.0906	0.5041	0.4140
GDM	YP	TanSig	43.412	14.958	5.3930	3.6663
	YA	TanSig	0.5835	0.4290	1.0967	0.8946
	YP	LogSig	51.546	17.611	6.1728	3.9086
GDX	YA	LogSig	19.425	6.8098	4.8285	3.3497
	YP	TanSig	54.559	15.321	4.8501	3.1114
	YA	TanSig	1.0070	0.5019	1.3429	0.9890
CGF	YP	LogSig	64.824	20.693	5.4668	3.5696
	YA	LogSig	4.4889	4.8849	2.7430	2.8943
	YP	TanSig	7.9023	9.7601	2.3070	2.4325
CGB	YA	TanSig	1.8542	1.0525	1.9251	1.4005
	YP	LogSig	49.359	12.403	5.0332	3.0665
	YA	LogSig	27.538	13.965	5.8586	4.2812
BFG	YP	TanSig	115.19	82.794	8.9643	7.6053
	YA	TanSig	0.2763	0.7395	0.6091	0.8953
	YP	LogSig	72.605	93.017	6.6228	7.6141
OSS	YA	LogSig	22.607	15.343	5.6726	4.7691
	YP	TanSig	3.9010	5.2744	1.7693	1.8436
	YA	TanSig	0.2558	0.3337	0.7557	0.7392
CGB	YP	LogSig	2.3722	3.3942	1.4939	1.6966
	YA	LogSig	0.6715	0.3570	1.0372	0.8160
	YP	TanSig	4.2766	2.7479	1.7781	1.4277
BFG	YA	TanSig	0.6199	0.1448	0.8568	0.5476
	YP	LogSig	4.3271	1.9239	1.7354	1.3066
	YA	LogSig	0.0659	0.0670	0.3115	0.3232
OSS	YP	TanSig	94.407	93.783	8.3609	7.8015
	YA	TanSig	7.4759	7.4410	3.5858	3.5937
	YP	LogSig	117.92	96.264	9.0620	7.9433
	YA	LogSig	8.6271	8.4103	4.0403	3.8472






(d)




(e)


Şekil 4.17: Haftalık Ölçülmüş Test Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.




(a)



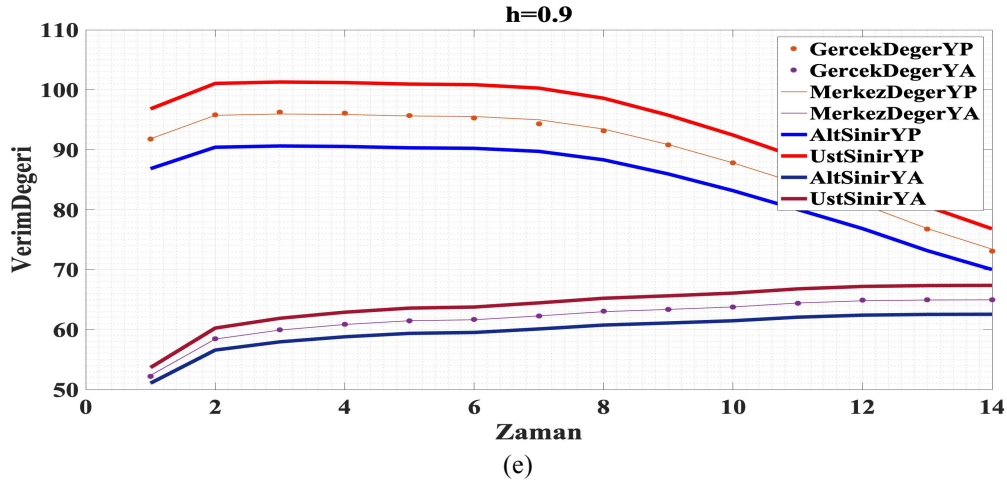
(b)



(c)



(d)



Şekil 4.18: Haftalık Ölçülmüş Geçerlilik Verileri için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.15’ de günlük ölçülmüş veriler için ve Tablo 4.16’da haftalık ölçülmüş veriler için elde edilen OMH değerleri bulunmaktadır. Tablolarda yer alan değerler incelendiğinde hem günlük hem de haftalık veriler için gerçekleştirilen analizlerde h seviyesindeki artışların, merkez değer için verilen ölçü dışında diğer OMH değerlerinde bir azalış meydana getirdiği görülmektedir. Şekil 4.17 ve Şekil 4.18’de görüleceği üzere bu durum grafiksel gösterimler ile uyum içindedir.

Tablo 4.15’de, YP değişkeninde günlük ölçülmüş veriler için test setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 17.222; alt sınırı arasındaki ortalama uzaklık 17.227; aralığın merkezi arasındaki ortalama uzaklık ise 0.0813 olarak hesaplanmıştır. YA değişkeninde günlük ölçülmüş veriler için test setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı arasındaki ortalama uzaklık 7.6218; alt sınırı arasındaki ortalama uzaklık 7.6310; aralığın merkezi arasındaki ortalama uzaklık ise 0.0459 olarak hesaplanmıştır. Günlük ölçülmüş veriler için geçerlilik setinde h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı, alt sınırı ve aralığın merkezi arasındaki ortalama uzaklık değerleri sırası ile YP değişkeninde 17.285, 17.286, 0.0791; YA değişkeninde 8.2273, 8.2618, 0.0495 olarak hesaplanmıştır. Tablo 4.16’da görüleceği üzere haftalık ölçülmüş veriler için h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı, alt sınırı ve aralığın merkezi arasındaki ortalama uzaklık değerleri sırası ile test seti için YP değişkeninde 18.256, 18.076, 0.2326 ve YA değişkeninde 17.831, 17.648, 0.3964; geçerlilik setinde YP değişkeninde 18.539, 18.375, 0.17776 ve YA değişkeninde 8.2273, 8.2618, 0.0495 olarak hesaplanmıştır.

Tablo 4.15: Günlük Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.

Değişken	Veri Seti	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMG ^w
YP	Test Seti	0.1	361.72	361.72	0.0811	803.83
		0.3	93.778	93.782	0.0811	267.94
		0.5	40.189	40.193	0.0811	160.76
		0.7	17.222	17.227	0.0811	114.83
		0.9	4.4634	4.4680	0.0811	89.314
	Geçerlilik Seti	0.1	362.71	362.87	0.1546	806.21
		0.3	93.979	94.137	0.1546	268.73
		0.5	40.232	40.389	0.1546	161.24
		0.7	17.197	17.354	0.1546	115.17
		0.9	4.5114	4.5577	0.1546	89.579
YA	Test Seti	0.1	160.15	160.15	0.0459	355.90
		0.3	41.517	41.526	0.0459	118.63
		0.5	17.790	17.799	0.0459	71.180
		0.7	7.6218	7.6310	0.0459	50.842
		0.9	1.9725	1.9818	0.0459	39.544
	Geçerlilik Seti	0.1	161.16	161.16	0.0437	358.13
		0.3	41.782	41.783	0.0437	119.37
		0.5	17.906	17.907	0.0437	71.627
		0.7	7.6739	7.6747	0.0437	51.162
		0.9	1.9892	1.9900	0.0437	39.792

Tablo 4.16: Haftalık Ölçülmüş Veriler için Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Değerleri.

Değişken	Veri Seti	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMG ^w
YP	Test Seti	0.1	381.58	381.40	0.2326	847.75
		0.3	98.995	98.815	0.2326	282.58
		0.5	42.477	42.298	0.2326	169.55
		0.7	18.256	18.076	0.2326	121.10
		0.9	4.7997	4.6198	0.2326	94.195
	Geçerlilik Seti	0.1	387.69	387.52	0.1776	861.35
		0.3	100.57	100.40	0.1776	287.11
		0.5	43.149	42.985	0.1776	172.27
		0.7	18.539	18.375	0.1776	123.05
		0.9	4.8671	4.7034	0.1776	95.706
YA	Test Seti	0.1	167.38	167.36	0.0612	371.93
		0.3	43.405	43.380	0.0612	123.97
		0.5	18.609	18.584	0.0612	74.387
		0.7	7.9825	7.9577	0.0612	53.134
		0.9	2.0787	2.0539	0.0612	41.326
	Geçerlilik Seti	0.1	173.11	173.15	0.0495	384.74
		0.3	44.870	44.904	0.0495	128.24
		0.5	19.220	19.254	0.0495	76.949
		0.7	8.2273	8.2618	0.0495	54.964
		0.9	2.1202	2.1547	0.0495	42.749

Yapay sinir ağlarına dayalı doğrusal olmayan tek değişkenli bulanık regresyon analizi sonuçlarına benzer şekilde, çok değişkenli analizlerde de, Tablo 4.15 ve Tablo 4.16'da görüleceği üzere, alt ve üst bulanık tahmin sınırlarının birbirlerine oldukça yakın değerler aldıkları görülmektedir. Ayrıca, hem günlük hem de haftalık ölçülmüş verilerle

gerçekleştirilen analizlerde bulanık tahmin aralıklarının genişliklerinin bütün h seviyelerinde birbirleri ile uyum içinde oldukları görülmektedir. Bu durum farklı veri seti büyüklüklerine rağmen ele alınan yöntemin tutarlı sonuçlar ortaya koyduğunu göstermektedir. Tek değişkenli analizlere benzer şekilde, yumurta performans ve yumurta ağırlığı eğrilerinin doğrusal olmayan bulanık regresyon ile modellenmesinde h seviyesinin 0.7 olduğu değer diğer değerlere göre daha uygun olduğu görülmektedir.

Tablo 4.17-20’de sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin yapay sinir ağlarına dayalı çok değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Tablolarda gerçek gözlem değerleri, yapay sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi uygulaması sonucu elde edilen alt tahmin, üst tahmin ve merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır.

Tablo 4.17: Günlük Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	52.47	59.05	46.06	52.55	21.65
	92.7	112.7	72.65	92.68	66.74
	89.77	108.8	70.76	89.82	63.53
	80.52	96.46	64.61	80.54	53.08
	71.67	84.4	58.62	71.51	42.97
Yumurta Ağırlığı	46	47.98	43.9	45.94	6.807
	63	70.71	55.34	63.03	25.62
	64	71.98	56.01	64	26.62
	65.51	74.04	57.03	65.54	28.35
	66.37	74.99	57.52	66.26	29.12

Tablo 4.18: Günlük Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	60.05	60.59	44.4	52.5	26.99
	92.67	112.6	72.61	92.62	66.68
	89.65	108.7	70.68	89.71	63.41
	80.25	96.09	64.42	80.26	52.77
	71.24	84.03	58.43	71.23	42.66
Yumurta Ağırlığı	47.3	48.38	43.37	45.88	8.35
	62.99	70.54	55.19	62.87	25.59
	63.99	71.98	56.02	64	26.60
	65.55	74.06	57.03	65.55	28.38
	66.1	74.99	57.5	66.25	29.14

Tablo 4.19: Haftalık Ölçülmüş Test Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	94.7	115.3	74.72	95.06	67.77
	95.1	115.8	74.97	95.41	68.12
	89.4	107.6	70.94	89.32	61.25
	86.2	103.4	68.82	86.16	57.77
	75.1	88.78	61.46	75.12	45.53
Yumurta Ağırlığı	56.5	62.91	50.09	56.5	21.37
	61.8	70.05	53.58	61.81	27.45
	63.5	72.35	54.74	63.55	29.35
	64.1	73.11	55.11	64.11	30.00
	65.0	74.25	55.68	64.96	30.95

Tablo 4.20: Haftalık Ölçülmüş Geçerlilik Seti için Yapay Sinir Ağlarına Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	95.8	116.2	75.22	95.74	68.37
	94.3	115.3	74.65	94.98	67.74
	87.8	105.6	69.92	87.79	59.57
	84.3	101.0	67.62	84.35	55.77
	73.1	86.46	60.3	73.38	43.6
Yumurta Ağırlığı	58.5	65.5	51.36	58.43	23.56
	62.3	70.68	53.91	62.29	27.95
	63.8	72.67	54.9	63.79	29.62
	64.4	73.55	55.33	64.44	30.36
	65.0	74.26	55.68	64.97	30.96

Tablolarda, gerçek değerler ve bulanık tahmin aralığının merkez değerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir. Tablo 4.17-20’de yumurta performansı ve yumurta ağırlığı değişkenlerine ilişkin gerçekleşmesi beklenen olası muhtemel aralıklar oluşturulmuştur. Her iki bağımlı değişkenin gözlem değerleri üçgenel bulanık sayı olmak üzere bulanık tahmin aralıkları elde edilmiştir. Tahmin aralığı olası minimum ve maksimum yumurta performans ve yumurta ağırlığı değerleri ile sınırlandırılmıştır. Şekil 4.17 ve Şekil 4.18’de görüleceği üzere Tablo 4.17-20’de bağımlı değişken değerindeki artışın yayılım miktarını arttırdığı, daha küçük değerlerde yayılım miktarının azaldığı görülmektedir.

Yumurta performansı değişkenine ilişkin elde edilen bulgular, tek ve çok değişkenli yapay sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizinde karşılaştırmalı olarak incelendiğinde, hem günlük hem de haftalık ölçümler için, hata kriteri değerlerinde oldukça düşük miktarlarda değişim olduğu görülmektedir. Elde edilen bu bulgular yapay sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizinin farklı şartlar altında

oldukça başarılı ve tutarlı sonuçlar sergilediğini göstermektedir. Buna karşılık, klasik regresyon analizinde gözlem sayılarındaki değişimin hata kriteri değerlerini bulanık regresyon analizine göre oldukça etkilediği görülmektedir.

4.5. En Küçük Kareler Destek Vektör Makinelerine Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Uygulama Sonuçları



Tez çalışması kapsamında yumurta performansını modellemek üzere en küçük kareler destek vektör makinelerine (EKK-DVM) dayalı doğrusal olmayan bulanık regresyon analizinde, sinir ağları yardımıyla gerçekleştirilen analizlere benzer şekilde veri seti eğitim, test ve geçerlilik setleri için hazırlanmıştır. Eğitim seti tahmin modeline ilişkin optimum yapının elde edilmesinde, test ve geçerlilik setleri ise model performansına ilişkin değerlendirmenin sağlanmasında kullanılmaktadır. Burada EKK-DVM yöntemi, doğrusal olmayan bulanık regresyon analizinin tahmin aralıklarına ait alt ve üst eğrileri elde etmek amacıyla kullanılmaktadır. Analizler EKK-DVM teorisinde verilerin eğitim sürecinde yer alan üç farklı Kernel fonksiyonu kullanılarak gerçekleştirilmiştir. Bunlar; Radial Basis Function (RBF) Kernel Fonksiyonu, Polinomial Kernel fonksiyonu ve Doğrusal Kernel fonksiyonu şeklindedir. RBF Kernel fonksiyonu yapısında bulunan σ parametresi “10, 30, 50, 70 ve 90”, γ parametresi “0.1, 0.3, 0.5, 0.7 ve 0.9” olacak şekilde belirlenmiştir. Polinomial Kernel fonksiyonun uygulama sürecinde fonksiyon derecesi birinci dereceden beşinci dereceye kadar ele alınmıştır.




Tablo 4.21: Günlük Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM’na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

Veri Seti	RBF Kernel σ/γ	HKO				OMYH			
		0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Test Seti	10	4.196	0.048	0.023	0.030	0.596	0.168	0.147	0.157
	30	3.670	0.017	0.021	3.670	0.532	0.121	0.141	0.532
	50	3.544	0.016	0.022	0.022	0.521	0.117	0.142	0.148
	70	3.484	0.016	0.023	0.022	0.516	0.119	0.141	0.145
	90	3.448	0.017	0.024	0.021	0.513	0.121	0.141	0.143
Geçerlilik Seti	10	0.058	0.028	0.030	0.035	0.140	0.140	0.152	0.169
	30	0.026	0.022	0.025	0.026	0.102	0.124	0.136	0.102
	50	0.019	0.017	0.024	0.026	0.120	0.085	0.132	0.143
	70	0.020	0.018	0.023	0.026	0.121	0.088	0.130	0.142
	90	0.020	0.021	0.023	0.025	0.122	0.093	0.129	0.141




Tablo 4.21’de günlük ölçülmüş veriler için RBF Kernel fonksiyonu ile çalışan EKK-DVM’na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Analiz sonuçları σ parametresinin 50; γ parametresinin ise 0.4 olduğu tahmin değerlerinin diğer parametrelere göre daha başarılı olduğunu göstermektedir. Buna göre, HKO ve OMYH kriterleri test setinde sırasıyla 0.016 ve 0.117; geçerlilik setinde ise 0.017 ve 0.085 olarak hesaplanmıştır.


Şekil 4.19’da günlük ölçülmüş test verileri için, Şekil 4.20’de geçerlilik verileri için EKK-DVM’na dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Grafikselleştirilmiş gösterimler en başarılı bulunan parametre kombinasyonu için verilmiştir. Doğrusal olmayan bulanık regresyon analizi sonuçları, h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisinin tipik görünümünün sergilendiğini ve tahmin değerlerinin gerçek değerlere oldukça yakın çıktığını göstermektedir.





Şekil 4.19: Günlük Ölçülmüş Test Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.






Şekil 4.20: Günlük Ölçülmüş Geçerlilik Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.22'de haftalık ölçülmüş veriler için RBF Kernel fonksiyonu ile çalışan EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Test ve geçerlilik seti için gerçekleştirilen analizlerde σ parametresinin 90; γ parametresinin ise 1.0 olduğu tahmin sonuçları diğerlerine göre daha başarılı bulunmuştur. Buna göre, HKO ve OMYH kriterleri test setinde sırasıyla 0.026 ve 0.132; geçerlilik setinde ise 0.036 ve 0.197 olarak hesaplanmıştır. HKO ve OMYH değerleri bakımından test ve geçerlilik setlerinin uyum içinde olduğu görülmektedir.


Tablo 4.22: Haftalık Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

Veri Seti	RBF	HKO				OMYH			
	Kernel	0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Test Seti	σ/γ								
	10	0.194	0.134	0.106	0.105	0.284	0.268	0.261	0.272
	30	0.194	0.134	0.106	0.105	0.284	0.268	0.261	0.272
	50	0.067	0.035	0.032	0.030	0.164	0.144	0.145	0.140
	70	0.062	0.030	0.029	0.027	0.161	0.137	0.137	0.134
	90	0.060	0.028	0.027	0.026	0.160	0.133	0.133	0.132
Geçerlilik Seti	10	17.22	0.337	0.075	0.073	2.227	0.398	0.233	0.239
	30	17.22	0.337	0.075	0.073	2.227	0.398	0.233	0.239
	50	15.07	0.081	0.037	0.057	1.996	0.250	0.198	0.228
	70	14.89	0.060	0.037	0.059	1.985	0.231	0.198	0.234
	90	14.78	0.047	0.061	0.036	1.981	0.216	0.238	0.197


Şekil 4.21'de haftalık ölçülmüş test verileri için, Şekil 4.22'de geçerlilik verileri için RBF Kernel fonksiyonu ile çalıştırılan EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Doğrusal olmayan bulanık regresyon analizi sonuçları, h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisi eğrisinin tipik görünümünün sergilendiğini ve tahmin değerlerinin gerçek değerlere oldukça yakın olduğunu göstermektedir.




(a)




(b)





(c)




(d)




Şekil 4.21: Haftalık Ölçülmüş Test Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.






(c)



(d)



(e)

Şekil 4.22: Haftalık Ölçülmüş Geçerlilik Verileri için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Yumurta performansı değişkenine ilişkin farklı tahmin aralıkları ve bulanıklık seviyeleri elde edilen bulgular ışığında RBF Kernel ile çalışan EKK-DVM'na dayalı doğrusal olmayan bulanık regresyon analizi ile geliştirilen modeller karşılaştırılmalı olarak değerlendirilmiştir. Buna göre, Tablo 4.23'de günlük ölçülmüş veriler için ve Tablo 4.24'de haftalık ölçülmüş veriler için elde edilen OMH değerleri bulunmaktadır. Sınır

ağları ile gerçekleştirilen analize benzer şekilde h seviyesindeki artışların, merkez değer için verilen ölçü dışında diğer OMH değerlerinde azalış eğiliminin olduğu bir başka ifade ile bulanık tahmin aralığında bir daralmanın meydana geldiği görülmektedir. Bu durum grafiksel gösterimler ile uyum içindedir. RBF Kernel ile çalışan EKK-DVM'na dayalı doğrusal olmayan bulanık regresyon analizinde h seviyesinin 0.7 olduğu değerlerin ele alınan veri seti için uygun olduğu görülmektedir. Tablo 4.23'de görüleceği üzere günlük ölçülmüş veriler için h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı, alt sınırı ve aralığın merkezi arasındaki ortalama uzaklık değerleri sırası ile test seti için 17.218, 17.230, 0.0940; geçerlilik seti için 17.287, 17.286, 0.0982 olarak hesaplanmıştır. Haftalık ölçülmüş veriler için h değerinin 0.7 olduğu durumda gerçek gözlem değerleri ile aralığın üst sınırı, alt sınırı ve aralığın merkezi arasındaki ortalama uzaklık değerleri sırası ile test seti için 17.742, 17.777, 0.1140; geçerlilik seti için 17.362, 17.137, 0.1770 olarak hesaplanmıştır ve ilgili sayısal bulgular Tablo 4.24'de yer almaktadır. Tablo 4.23 ve Tablo 4.24'de yer alan OMH bulgularında belirtildiği üzere üst ve alt tahmin sınırlarına ilişkin uzaklık değerlerinin, günlük ölçülmüş verilerde olduğu gibi, birbirlerine oldukça yakın olduğu buna karşılık haftalık ölçülmüş verilerde istenen simetrik yapının yakalanamadığı görülmektedir. Bu durum sinir ağları ile gerçekleştirilen analizlere göre EKK-DVM'na dayalı doğrusal olmayan bulanık regresyon analizinin OMH değerleri açısından daha az tutarlı bir yapıya sahip olduğunu ve veri seti büyüklüğünde oluşan değişimden etkilenebildiğini göstermektedir.

Tablo 4.23. Günlük Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.

RBF Kernel	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Test Seti	0.1	361.70	361.71	0.0940	803.80
	0.3	93.771	93.783	0.0940	267.93
	0.5	40.184	40.196	0.0940	160.76
	0.7	17.218	17.230	0.0940	114.82
	0.9	4.4596	4.4715	0.0940	89.311
Geçerlilik Seti	0.1	363.02	363.02	0.0982	806.72
	0.3	94.119	94.117	0.0982	268.90
	0.5	40.337	40.335	0.0982	161.34
	0.7	17.287	17.286	0.0982	115.24
	0.9	4.4826	4.4810	0.0982	89.636

Tablo 4.24: Haftalık Ölçülmüş Veriler için RBF Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.

RBF Kernel	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Test Seti	0.1	372.94	372.97	0.1140	828.79
	0.3	96.676	96.710	0.1140	276.26
	0.5	41.422	41.457	0.1140	165.75
	0.7	17.742	17.777	0.1140	118.39
	0.9	4.5872	4.6215	0.1140	92.088
Geçerlilik Seti	0.1	362.36	362.13	0.1770	805.00
	0.3	94.029	93.804	0.1770	268.33
	0.5	40.362	40.137	0.1770	161.00
	0.7	17.362	17.137	0.1770	115.00
	0.9	4.5848	4.3596	0.1770	89.444

Tablo 4.25-28'de sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin RBF Kernel ile çalışan EKK-DVM'na dayalı tek değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Tablolarda gerçek gözlem değerleri, EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi uygulaması sonucu elde edilen alt tahmin, üst tahmin ve merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır. Tablolarda, gerçek değerler ve bulanık tahmin aralığının merkez değerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir.

Tablo 4.25: Günlük Ölçülmüş Test Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
52.47	58.99	46.02	52.51	21.6
92.7	112.7	72.68	92.71	66.74
89.77	108.8	70.77	89.82	63.47
80.52	96.47	64.62	80.55	53.09
71.67	84.08	58.49	71.29	42.65

Tablo 4.26: Günlük Ölçülmüş Geçerlilik Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
60.05	69.31	51.14	60.23	30.27
92.67	112.6	72.62	92.63	66.67
89.65	108.6	70.68	89.69	63.34
80.25	96.11	64.44	80.28	52.77
71.24	83.77	58.33	71.05	42.4

Tablo 4.27: Haftalık Ölçülmüş Test Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
91.5	110.8	71.49	91.16	65.53
91.5	111.3	71.76	91.56	65.97
85.9	104.1	68.19	86.17	59.91
83.9	101.1	66.73	83.95	57.38
73.8	87.78	60.13	73.96	46.07

Tablo 4.28: Haftalık Ölçülmüş Geçerlilik Seti için RBF Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
89.2	108.7	70.43	89.57	63.77
91.9	112	72.09	92.06	66.55
86.8	105.1	68.71	86.95	60.8
84.7	102.4	67.35	84.89	58.46
75.2	89.52	61.01	75.27	47.52

Tablo 4.29: Günlük Ölçülmüş Veriler için Polinomial Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

Polinomial Kernel		HKO		OMYH	
Derece	Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti	
1	1.812	1.844	1.044	1.036	
2	0.416	0.336	0.579	0.521	
3	0.186	0.065	0.317	0.223	
4	0.044	0.036	0.197	0.181	
5	0.069	0.044	0.213	0.202	



Tablo 4.30: Haftalık Ölçülmüş Veriler için Polinomial Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.




Polinomial Kernel		HKO		OMYH	
Derece	Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti	
1	8.505	6.482	2.314	2.270	
2	0.774	3.342	0.732	1.441	
3	0.271	1.167	0.434	0.754	
4	0.053	0.143	0.220	0.318	
5	0.027	0.029	0.141	0.176	

Tablo 4.29'da günlük ölçülmüş Tablo 4.30'da haftalık ölçülmüş veriler için Polinomial Kernel fonksiyonu ile çalışan EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Test ve geçerlilik seti için gerçekleştirilen analizlerde fonksiyon derecesinin günlük ölçülmüş verilerde dört; haftalık ölçülmüş verilerde ise beş olduğu durumda tahmin sonuçları diğerlerine göre daha başarılı bulunmuştur. Buna göre, günlük ölçülmüş verilerde test ve geçerlilik setinde sırasıyla




HKO değeri 0.044 ve 0.036; haftalık ölçülmüş verilerde test ve geçerlilik setinde sırasıyla HKO değeri 0.027 ve 0.029 olarak hesaplanmıştır.


Şekil 4.23’de günlük ölçülmüş test verileri için, Şekil 4.24’de geçerlilik verileri için Polinomial Kernel ile çalışan EKK-DVM’na dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. RBF Kernel fonksiyonuna benzer şekilde Polinomial Kernel fonksiyonu sonuçları, h seviyesinin 0.7 ve 0.9 olduğu durumlarda yumurta performans eğrisinin doğrusal olmayan yapısının doğru bir şekilde öğrenildiğini ve elde edilen tahmin değerlerinin gerçek değerlere oldukça yakın çıktığını göstermektedir.



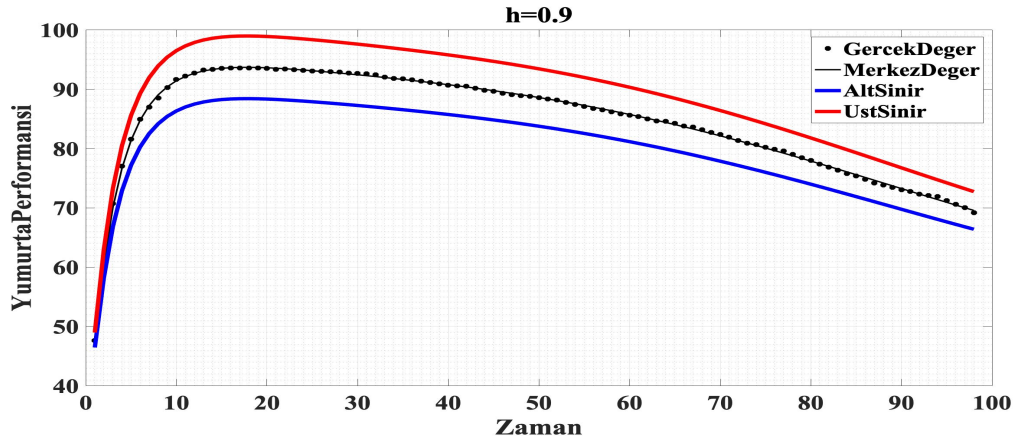


Şekil 4.23: Günlük Ölçülmüş Test Verileri için Polinomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.






(d)




(e)

Şekil 4.24: Günlük Ölçülmüş Geçerlilik Verileri için Polinomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.


Şekil 4.25'de haftalık ölçülmüş test verileri için, Şekil 4.26'da geçerlilik verileri için Polinomial Kernel ile çalışan EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır.




(a)




(b)



(c)




(d)




(e)


Şekil 4.25: Haftalık Ölçülmüş Test Verileri için Polinomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.




(a)




(b)



(c)



(d)



(e)

Şekil 4.26: Haftalık Ölçülmüş Geçerlilik Verileri için Polinomial Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.31'de günlük ölçülmüş veriler için ve Tablo 4.32'de haftalık ölçülmüş veriler için elde edilen OMH değerleri bulunmaktadır. Bu değerlere göre h seviyesindeki artışların, merkez değer için verilen ölçü dışında diğer OMH değerlerinde bir azalış meydana gelmektedir. Elde edilen bu bulgular sinir ağırları ve RBF Kernel fonksiyonu kullanılarak

gerçekleştirilen analizler ile benzerlik göstermekle birlikte, OMH^w değerlerinin bahsi geçen diğer yöntemlere göre daha yüksek değerlerde tahmin edildiği gözlenmektedir.

Tablo 4.33-36'da sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin Polinomiyal Kernel ile çalışan EKK-DVM'na dayalı tek değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Tablolarda gerçek gözlem değerleri, bulanık regresyon analizi uygulaması sonucu elde edilen alt tahmin, üst tahmin ve merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır. Tablolarda, gerçek değerler ve bulanık tahmin aralığının merkez değerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir.

Tablo 4.31: Günlük Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.

Polinomiyal Kernel	h-seviye	OMH^+	OMH^-	OMH^c	OMH^w
Test Seti	0.1	361.77	361.77	0.1579	803.94
	0.3	120.59	120.58	0.1579	267.98
	0.5	72.358	72.352	0.1579	160.78
	0.7	51.685	51.679	0.1579	114.84
	0.9	40.200	40.194	0.1579	89.327
Geçerlilik Seti	0.1	363.04	363.04	0.1630	806.76
	0.3	121.01	121.01	0.1630	268.92
	0.5	72.612	72.605	0.1630	161.35
	0.7	51.867	51.860	0.1630	115.25
	0.9	40.341	40.335	0.1630	89.640

Tablo 4.32: Haftalık Ölçülmüş Veriler için Polinomiyal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.

Polinomiyal Kernel	h-seviye	OMH^+	OMH^-	OMH^c	OMH^w
Test Seti	0.1	373.03	373.04	0.1198	828.97
	0.3	124.33	124.35	0.1198	276.32
	0.5	74.601	74.613	0.1198	165.79
	0.7	53.284	53.297	0.1198	118.42
	0.9	41.442	41.454	0.1198	92.108
Geçerlilik Seti	0.1	361.91	361.79	0.1473	804.12
	0.3	120.67	120.56	0.1473	268.04
	0.5	72.428	72.313	0.1473	160.82
	0.7	51.750	51.636	0.1473	114.87
	0.9	40.263	40.149	0.1473	89.346

Tablo 4.37’de günlük ölçülmüş veriler için; Tablo 4.38’de haftalık ölçülmüş veriler için doğrusal Kernel fonksiyonu ile çalışan EKK-DVM’na dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin istatistiksel hata kriterleri yer almaktadır. Tablo 4.37 ve Tablo 4.38’de bulgular, klasik regresyon analizi sonuçlarının doğrusal Kernel fonksiyonu sonuçlarından daha başarılı olduğunu göstermektedir. Ayrıca doğrusal Kernel fonksiyonu sonuçları tez çalışması kapsamında değerlendirilen diğer Kernel fonksiyonları ile karşılaştırıldığında başarı seviyesinin oldukça düşük olduğu da görülmektedir.

Tablo 4.33: Günlük Ölçülmüş Test Seti için Polinomiyal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
52.47	59.97	46.52	53.25	22.42
92.7	112.5	72.57	92.54	66.55
89.77	108.9	70.83	89.91	63.6
80.52	96.21	64.5	80.36	52.83
71.67	83.99	58.44	71.22	42.58

Tablo 4.34: Günlük Ölçülmüş Geçerlilik Seti için Polinomiyal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
60.05	69.9	51.43	60.67	30.77
92.67	112.3	72.5	92.45	66.49
89.65	108.8	70.73	89.78	63.47
80.25	95.87	64.32	80.1	52.59
71.24	83.63	58.26	70.95	42.27

Tablo 4.35: Haftalık Ölçülmüş Test Seti için Polinomiyal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
91.5	110.7	71.46	91.13	65.54
91.5	111.1	71.67	91.43	65.85
85.9	104.2	68.23	86.23	59.97
83.9	101	66.65	83.83	57.26
73.8	87.99	60.24	74.12	46.26

Tablo 4.36: Haftalık Ölçülmüş Geçerlilik Seti için Polinomiyal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.



Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılm
89.2	108.5	70.36	89.46	63.65
91.9	111.7	71.98	91.89	66.35
86.8	105.3	68.8	87.08	60.92
84.7	102.3	67.32	84.84	58.4
75.2	89.74	61.11	75.43	47.71


Tablo 4.37: Günlük Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

	HKO		OMYH	
	Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
Doğrusal Kernel Fonksiyonu	1.812	1.844	1.044	1.036


Tablo 4.38: Haftalık Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi HKO ve OMYH Sonuçları.

	HKO		OMYH	
	Test Seti	Geçerlilik Seti	Test Seti	Geçerlilik Seti
Doğrusal Kernel Fonksiyonu	8.505	6.482	2.314	2.270






(c)


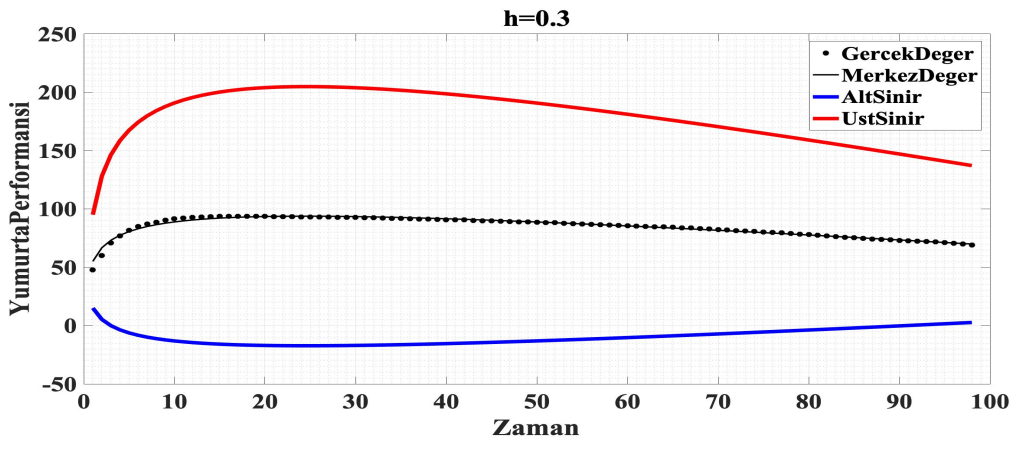




(d)



(e)

Şekil 4.27: Günlük Ölçülmüş Test Verileri için Doğrusal Kernel İle Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.





Şekil 4.28: Günlük Ölçülmüş Geçerlilik Verileri için Doğrusal Kernel İle Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.39'da günlük ölçülmüş veriler için ve Tablo 4.40'da haftalık ölçülmüş veriler için doğrusal Kernel fonksiyonu ile çalışan EKK-DVM'na dayanan tek değişkenli doğrusal olmayan bulanık regresyon analizi OMH sonuçları bulunmaktadır. Şekil 4.27'de günlük ölçülmüş test verileri için, Şekil 4.28'de günlük ölçülmüş geçerlilik verileri için, Şekil 4.29'da haftalık ölçülmüş test verileri için, Şekil 4.30'da haftalık ölçülmüş geçerlilik verileri için doğrusal Kernel ile çalışan EKK-DVM'na dayalı tek değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. OMH bulgularında, doğrusal Kernel fonksiyonu ile diğer Kernel fonksiyonları ile gerçekleştirilen analizlere benzer bulgular elde edildiği belirlenmiştir. Ancak grafiksel gösterimler gerçek gözlem değerleri ve tahmin değerleri arasında diğer yöntemlere göre daha fazla sapmalar meydana geldiğini göstermektedir. Bunun yanı sıra bulanık regresyon analizinde, gerçek gözlem değerlerinin belirlenen h seviyesine göre elde edilen sınır değerleri içerisinde kapsanması gerekmektedir. Oysa bu


koşul doğrusal Kernel fonksiyonunun kullanıldığı analizlerde özellikle h seviyesinin 0.9 olduğu durumlarda sağlanamamıştır. Bu nedenle tez çalışmasına konu olan veri setleri için doğrusal Kernel fonksiyonu önerilmemektedir.

Tablo 4.39: Günlük Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.


Doğrusal Kernel Fonksiyonu	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Test Seti	0.1	361.76	361.76	0.8065	803.92
	0.3	120.59	120.58	0.8065	267.97
	0.5	72.355	72.351	0.8065	160.78
	0.7	51.682	51.679	0.8065	114.84
	0.9	40.198	40.194	0.8065	89.325
Geçerlilik Seti	0.1	363.49	363.38	0.8064	807.64
	0.3	121.20	121.08	0.8064	269.21
	0.5	72.746	72.628	0.8064	161.52
	0.7	51.978	51.860	0.8064	115.37
	0.9	40.441	40.323	0.8064	89.738

Tablo 4.40: Haftalık Ölçülmüş Veriler için Doğrusal Kernel Fonksiyonu ile Çalışan EKK-DVM'na Dayanan Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi OMH Sonuçları.


Doğrusal Kernel Fonksiyonu	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Test Seti	0.1	366.54	368.14	2.0124	816.32
	0.3	121.64	123.25	2.0124	272.10
	0.5	72.665	74.272	2.0124	163.26
	0.7	51.674	53.281	2.0124	116.61
	0.9	40.012	41.619	2.0124	90.702
Geçerlilik Seti	0.1	359.72	360.14	1.8929	799.85
	0.3	119.76	120.18	1.8929	266.61
	0.5	71.774	72.198	1.8929	159.97
	0.7	51.206	51.631	1.8929	114.26
	0.9	39.780	40.204	1.8929	88.872




(a)




(b)



(c)




(d)




(e)




Şekil 4.29: Haftalık Ölçülmüş Test Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.



(a)



(b)



Şekil 4.30: Haftalık Ölçülmüş Geçerlilik Verileri için Doğrusal Kernel ile Çalışan EKK-DVM'na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.41: Günlük Ölçülmüş Test Seti için Doğrusal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
52.47	70.14	51.55	60.85	30.97
92.7	113.8	73.22	93.53	67.68
89.77	109.7	71.2	90.47	64.22
80.52	95.66	64.22	79.94	52.4
71.67	84.38	58.64	71.51	42.9

Tablo 4.42: Günlük Ölçülmüş Geçerlilik Seti için Doğrusal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
60.05	78.07	55.48	66.78	37.64
92.67	113.7	73.17	93.46	67.62
89.65	109.5	71.09	90.31	64.03
80.25	95.34	64.05	79.7	52.15
71.24	84.04	58.45	71.25	42.65

Tablo 4.43: Haftalık Ölçülmüş Test Seti için Doğrusal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
91.5	102.5	67.41	84.97	58.52
91.5	114	73.06	93.54	68.25
85.9	105.2	68.76	87.02	60.86
83.9	101.3	66.83	84.11	57.57
73.8	86.76	59.65	73.21	45.18

Tablo 4.44: Haftalık Ölçülmüş Geçerlilik Seti için Doğrusal Kernel ile Çalışan EKK-DVM’na Dayalı Tek Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
89.2	99.65	65.98	82.82	56.12
91.9	114.4	73.29	93.89	68.63
86.8	106.7	69.47	88.09	62.06
84.7	102.9	67.64	85.31	58.9
75.2	88.75	60.61	74.68	46.9

Tablo 4.41-44’de sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin doğrusal Kernel ile çalışan EKK-DVM’na dayalı tek değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Tablolarda gerçek gözlem değerleri, bulanık regresyon analizi uygulaması sonucu elde edilen alt tahmin, üst tahmin ve merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir.

Tez çalışması kapsamında yumurta performans eğrisinin modellenmesi amacıyla kullanılan tek değişkenli analiz yöntemleri karşılaştırmalı olarak değerlendirildiğinde, hata kriterleri bakımından en başarılı tahminlerin sinir ağlarına dayalı doğrusal olmayan tek değişkenli bulanık regresyon analizi ile üretildiği görülmektedir. Bunu takiben EKK-

DVM'na dayalı doğrusal olmayan tek değişkenli bulanık regresyon analizi başarılı bulunmuştur. Yöntemlerin değerlendirilmesinde bir diğer önemli ölçüt OMH değerleridir. Bu ölçüt farklı h seviyelerine göre oluşturulan bulanık tahmin aralığının genişliğine ilişkin bilgiler sunmaktadır. Bu bağlamda, incelenen yöntemler arasında en tutarlı bulgular yine sinir ağlarına dayalı doğrusal olmayan tek değişkenli bulanık regresyon analizi ile elde edilmiştir.

4.6. En Küçük Kareler Destek Vektör Makinelere Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Analizi Tahmin Sonuçları

Yumurta performansı ve yumurta ağırlığı değişkenlerini birlikte modellemek üzere EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi farklı parametre kombinasyonlarında ele alınmıştır. Analizlerde eğitim, test ve geçerlilik setleri tek değişkenli analizlere benzer şekilde hazırlanmıştır. Burada sadece Radial Basis Function (RBF) Kernel Fonksiyonu kullanılmıştır. RBF Kernel fonksiyonu yapısında bulunan σ parametresi “10, 30, 50, 70 ve 90”, γ parametresi “0.1, 0.3, 0.5, 0.7 ve 0.9” olacak şekilde belirlenmiştir. EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi süreci tek değişkenli analizlere benzer şekilde yürütülmüştür.

Tablo 4.45 ve Tablo 4.46'da, günlük ölçülmüş veriler için RBF Kernel fonksiyonu ile çalışan EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin HKO ve OMYH değerleri yer almaktadır. Test ve geçerlilik seti için gerçekleştirilen analizlerde σ parametresinin 50; γ parametresinin ise 0.4 olduğu tahmin sonuçları diğerlerine göre daha başarılı bulunmuştur. Buna bağlamda, Tablo 4.45 ve Tablo 4.46'da yer alan en başarılı bulgular test seti için elde edilen HKO: YP için 0.016, YA için 0.013; OMYH: YP için 0.117, YA için 0.139 şeklindedir. Geçerlilik seti için elde edilen HKO: YP için 0.017, YA için 0.004; OMYH: YP için 0.085, YA için 0.067 şeklindedir. Tablolarda yer alan sayısal bulguların tamamında yöntemin kendi içerisinde tutarlı bir yapıya sahip olduğu görülmektedir. Bir başka ifade ile HKO ve OMYH değerleri tüm parametre kombinasyonlarında ve her iki bağımlı değişkende hemen hemen benzer bir yapı sergilemektedir. Elde edilen hata kriteri değerleri diğer doğrusal olmayan regresyon analizi sonuçları ile karşılaştırıldığında, en başarılı tahmin değerlerinin sinir ağlarına dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edildiği görülebilmektedir.

Tablo 4.45: Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin HKO Değerleri.

Değişken	σ/γ	HKO							
		Test Seti				Geçerlilik Seti			
		0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Yumurta Performansı	10	4.196	0.048	0.023	0.030	0.028	0.058	0.030	0.035
	30	3.670	0.017	0.021	0.024	0.022	0.026	0.025	0.028
	50	3.544	0.016	0.022	0.022	0.019	0.017	0.024	0.026
	70	3.484	0.016	0.023	0.022	0.020	0.018	0.023	0.026
	90	3.448	0.017	0.024	0.021	0.021	0.021	0.023	0.025
Yumurta Ağırlığı	10	0.710	0.021	0.017	0.017	0.017	0.014	0.018	0.018
	30	0.624	0.014	0.017	0.017	0.014	0.006	0.016	0.016
	50	0.605	0.013	0.017	0.017	0.013	0.004	0.015	0.016
	70	0.596	0.013	0.017	0.017	0.013	0.005	0.015	0.016
	90	0.591	0.013	0.016	0.017	0.013	0.005	0.015	0.015

Tablo 4.46: Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMYH Değerleri.


Değişken	σ/γ	OMYH							
		Test Seti				Geçerlilik Seti			
		0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Yumurta Performansı	10	0.596	0.168	0.147	0.157	0.140	0.140	0.152	0.169
	30	0.532	0.121	0.141	0.154	0.124	0.102	0.136	0.149
	50	0.521	0.117	0.142	0.148	0.120	0.085	0.132	0.143
	70	0.516	0.119	0.141	0.145	0.121	0.088	0.130	0.142
	90	0.513	0.121	0.141	0.143	0.122	0.093	0.129	0.141
Yumurta Ağırlığı	10	0.279	0.179	0.173	0.172	0.165	0.102	0.176	0.175
	30	0.246	0.147	0.167	0.172	0.145	0.077	0.161	0.166
	50	0.241	0.139	0.164	0.170	0.140	0.067	0.156	0.163
	70	0.239	0.140	0.162	0.168	0.139	0.069	0.153	0.160
	90	0.237	0.141	0.161	0.166	0.138	0.071	0.151	0.158

Şekil 4.31'de günlük ölçülmüş test verileri için, Şekil 4.32'de geçerlilik verileri için, RBF Kernel ile çalışan EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin sadece 0.7 ve 0.9 olduğu durumlarda, yumurta performansı ve yumurta ağırlığı bağımlı değişkenlerinin sahip olduğu doğrusal olmayan yapının öğrenilebildiğini göstermektedir. EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları, tek değişkenli analizlere benzer şekilde yöntemin oldukça başarılı tahminler gerçekleştirdiğini göstermektedir. Tablo 4.47'de günlük ölçülmüş veriler için EKK-DVM'na dayanan çok değişkenli doğrusal olmayan bulanık regresyon analizi OMH sonuçları bulunmaktadır. Tez çalışması kapsamında incelenen diğer doğrusal olmayan bulanık regresyon analizi bulgularında olduğu gibi, bu analizde de h seviyesindeki artışların, merkez değer için verilen ölçü dışında diğer OMH değerlerinde bir azalış meydana getirdiği görülmektedir. Tablo 4.47'de her iki bulanık çıktının da




tahmin değerlerine ilişkin üst ve alt sınırlarının ortalama uzaklık değerleri birbirlerine oldukça yakındır. Bu durum, ele alınan yöntemin istenilen simetrik yapıyı doğru bir şekilde elde ettiğini göstermektedir.


Tablo 4.47: Günlük Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMH Değerleri.

Değişken	Veri Seti	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Yumurta Performansı	Test Seti	0.1	361.70	361.71	0.0940	803.80
		0.3	93.771	93.783	0.0940	267.93
		0.5	40.184	40.196	0.0940	160.76
		0.7	17.218	17.230	0.0940	114.82
		0.9	4.4596	4.4715	0.0940	89.311
	Geçerlilik Seti	0.1	363.02	363.02	0.0982	806.72
		0.3	94.119	94.117	0.0982	268.90
		0.5	40.337	40.335	0.0982	161.34
		0.7	17.287	17.286	0.0982	115.24
		0.9	4.4826	4.4810	0.0982	89.636
Yumurta Ağırlığı	Test Seti	0.1	160.15	160.16	0.0886	355.90
		0.3	41.517	41.526	0.0886	118.63
		0.5	17.790	17.799	0.0886	71.180
		0.7	7.6220	7.6308	0.0886	50.843
		0.9	1.9728	1.9816	0.0886	39.544
	Geçerlilik Seti	0.1	161.15	161.15	0.0881	358.12
		0.3	41.779	41.781	0.0881	119.37
		0.5	17.904	17.907	0.0881	71.624
		0.7	7.6727	7.6752	0.0881	51.160
		0.9	1.9883	1.9907	0.0881	39.791




(a)






(e)




Şekil 4.31: Günlük Ölçülmüş Test Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.



(a)



(b)



Şekil 4.32: Günlük Ölçülmüş Geçerlilik Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.48: Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin HKO Değerleri.

Değişken	σ/γ	HKO							
		Test Seti				Geçerlilik Seti			
		0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Yumurta Performansı	10	0.195	0.114	0.134	0.162	0.614	0.462	0.424	0.532
	30	0.221	0.072	0.079	0.108	0.324	0.231	0.207	0.266
	50	0.270	0.076	0.067	0.095	0.266	0.172	0.153	0.203
	70	0.299	0.085	0.061	0.086	0.237	0.143	0.128	0.169
	90	0.318	0.093	0.058	0.079	0.218	0.125	0.113	0.147
Yumurta Ağırlığı	10	0.386	0.076	0.027	0.040	0.389	0.109	0.061	0.065
	30	0.030	0.014	0.027	0.009	0.052	0.027	0.061	0.020
	50	0.133	0.022	0.007	0.009	0.183	0.038	32.55	0.020
	70	0.114	0.019	0.006	0.008	0.158	0.032	0.011	0.018
	90	0.103	0.017	0.005	0.007	0.141	0.028	0.010	0.017

Tablo 4.48 ve Tablo 4.49'da, haftalık ölçülmüş veriler için RBF Kernel fonksiyonu ile çalışan EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon analizi ile elde edilen tahmin sonuçları ve gerçek değerlere ilişkin HKO ve OMYH değerleri yer almaktadır. Test ve geçerlilik seti için gerçekleştirilen analizlerde σ parametresinin 90; γ parametresinin ise 0.7 olduğu tahmin sonuçları diğerlerine göre daha başarılı bulunmuştur. Bu bağlamda, Tablo 4.48 ve Tablo 4.49'da yer alan en başarılı bulgular test seti için elde edilen HKO: YP için 0.058, YA için 0.055; OMYH: YP için 0.192, YA için 0.103 şeklindedir. Geçerlilik seti için elde edilen HKO: YP için 0.113, YA için 0.010; OMYH: YP için 0.203, YA için 0.108 şeklindedir.




Tablo 4.49: Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMYH Değerleri.


Değişken	σ/γ	OMYH							
		Test Seti				Geçerlilik Seti			
		0.1	0.4	0.7	1.0	0.1	0.4	0.7	1.0
Yumurta Performansı	10	0.416	0.260	0.288	0.334	0.551	0.494	0.479	0.540
	30	0.321	0.208	0.225	0.256	0.298	0.337	0.305	0.364
	50	0.308	0.196	0.209	0.241	0.268	0.293	0.251	0.323
	70	0.306	0.192	0.201	0.232	0.255	0.274	0.222	0.296
	90	0.304	0.192	0.192	0.224	0.246	0.262	0.203	0.276
Yumurta Ağırlığı	10	0.563	0.265	0.200	0.241	0.478	0.268	0.271	0.240
	30	0.176	0.146	0.200	0.140	0.179	0.145	0.271	0.150
	50	0.333	0.160	0.122	0.122	0.280	0.155	7.888	0.123
	70	0.310	0.153	0.111	0.110	0.262	0.143	0.116	0.114
	90	0.296	0.148	0.103	0.104	0.250	0.135	0.108	0.109

Tablo 4.50: Haftalık Ölçülmüş Veriler için EKK-DVM'na Dayanan Doğrusal Olmayan Çok Değişkenli Bulanık Regresyon Analizi Sonuçlarına İlişkin OMH Değerleri.


Değişken	Veri Seti	h-seviye	OMH ⁺	OMH ⁻	OMH ^c	OMH ^w
Yumurta Performansı	Test Seti	0.1	381.33	381.38	0.1567	847.46
		0.3	98.843	98.899	0.1567	282.48
		0.5	42.345	42.401	0.1567	169.49
		0.7	18.131	18.188	0.1567	121.06
		0.9	4.6800	4.7362	0.1567	94.163
	Geçerlilik Seti	0.1	387.30	387.21	0.2166	860.57
		0.3	100.44	100.35	0.2166	286.85
		0.5	43.072	42.984	0.2166	172.11
		0.7	18.484	18.396	0.2166	122.93
		0.9	4.8249	4.7369	0.2166	95.619
Yumurta Ağırlığı	Test Seti	0.1	167.34	167.32	0.0598	371.86
		0.3	43.392	43.375	0.0598	123.95
		0.5	18.601	18.584	0.0598	74.372
		0.7	7.9766	7.9603	0.0598	53.123
		0.9	2.0740	2.0577	0.0598	41.318
	Geçerlilik Seti	0.1	172.98	173.04	0.0659	384.47
		0.3	44.825	44.884	0.0659	128.15
		0.5	19.194	19.253	0.0659	76.894
		0.7	8.2092	8.2682	0.0659	54.924
		0.9	2.1064	2.1654	0.0659	42.719

Şekil 4.33'de günlük ölçülmüş test verileri için, Şekil 4.34'de geçerlilik verileri için, RBF Kernel ile çalışan EKK-DVM'na dayalı çok değişkenli doğrusal olmayan bulanık regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) seviye kümesi tahmin sonuçları yer almaktadır. Doğrusal olmayan bulanık regresyon analizi sonuçları h seviyesinin 0.7 ve 0.9 olduğu durumlarda YP ve YA değişkenlerinin tipik görünümünün sergilendiğini göstermektedir. Haftalık ölçülmüş verilerle gerçekleştirilen analizde, günlük verilere benzer şekilde, yöntemin oldukça başarılı tahminler gerçekleştirdiği görülmektedir. Tablo 4.50'de haftalık ölçülmüş veriler için EKK-DVM'na dayanan çok değişkenli doğrusal olmayan bulanık regresyon analizi OMH sonuçları bulunmaktadır. Burada h seviyesindeki artışların, merkez değer için verilen ölçü dışında diğer OMH değerlerinde bir azalış meydana getirdiği görülmektedir. Tablo 4.50'de YP ve YA bulanık çıktılarının tahmin değerlerine ilişkin üst ve alt sınırlarının ortalama uzaklık değerlerinin kendi içlerinde birbirlerine oldukça yakın değerler aldıkları belirlenmiştir.






(d)







(e)

Şekil 4.33: Haftalık Ölçülmüş Test Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h = 0.1$ (a), $h = 0.3$ (b), $h = 0.5$ (c), $h = 0.7$ (d), $h = 0.9$ (e) Seviye Kümesi Tahmin Sonuçları.



(a)





(e)

Şekil 4.34: Haftalık Ölçülmüş Geçerlilik Verileri için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon $h=0.1$ (a), $h=0.3$ (b), $h=0.5$ (c), $h=0.7$ (d), $h=0.9$ (e) Seviye Kümesi Tahmin Sonuçları.

Tablo 4.51: Günlük Ölçülmüş Test Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
Yumurta Performansı	52.47	58.99	46.02	52.51	21.6
	92.7	112.7	72.68	92.71	66.74
	89.77	108.8	70.77	89.82	63.47
	80.52	96.47	64.62	80.55	53.09
	71.67	84.08	58.49	71.29	42.65
Yumurta Ağırlığı	46	48.09	43.94	46.02	6.914
	63	70.5	55.25	62.88	25.42
	64	72.01	56.02	64.02	26.66
	65.51	73.98	57.01	65.5	28.28
	66.37	74.98	57.51	66.25	29.11

Tablo 4.52: Günlük Ölçülmüş Geçerlilik Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılim
Yumurta Performansı	60.05	69.31	51.14	60.23	30.27
	92.67	112.6	72.62	92.63	66.67
	89.65	108.6	70.68	89.69	63.34
	80.25	96.11	64.44	80.28	52.77
	71.24	83.77	58.33	71.05	42.4
Yumurta Ağırlığı	47.3	49.8	44.81	47.31	8.328
	62.99	70.57	55.28	62.93	25.47
	63.99	72.08	56.05	64.07	26.72
	65.55	74.02	57.03	65.53	28.32
	66.1	74.99	57.52	66.26	29.12

Tablo 4.53: Haftalık Ölçülmüş Test Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	94.7	115.1	74.68	94.94	67.52
	95.1	115.3	74.78	95.08	67.64
	89.4	107.8	71.02	89.42	61.32
	86.2	103.5	68.86	86.22	57.84
	75.1	89.4	61.77	75.59	46.03
Yumurta Ağırlığı	56.5	62.9	50.07	56.49	21.38
	61.8	70.06	53.61	61.84	27.42
	63.5	72.37	54.74	63.56	29.37
	64.1	73.05	55.08	64.07	29.94
	65	74.07	55.59	64.83	30.8

Tablo 4.54: Haftalık Ölçülmüş Geçerlilik Seti için EKK-DVM'na Dayalı Çok Değişkenli Doğrusal Olmayan Bulanık Regresyon Sonuçları.

Değişken	Gerçek Değer	Üst Tahmin Sınırı	Alt Tahmin Sınır	Merkez Değer	Yayılım
Yumurta Performansı	95.8	116	75.13	95.59	68.2
	94.3	114.6	74.4	94.51	67.01
	87.8	105.8	69.99	87.91	59.71
	84.3	101	67.61	84.33	55.71
	73.1	87.66	60.9	74.28	44.6
Yumurta Ağırlığı	58.5	65.54	51.37	58.46	23.62
	62.3	70.68	53.91	62.3	27.93
	63.8	72.66	54.89	63.78	29.62
	64.4	73.49	55.3	64.4	30.32
	65	73.73	55.42	64.58	30.51

Tablo 4.51-54'de sırasıyla, günlük ölçülmüş veriler için test seti, günlük ölçülmüş veriler için geçerlilik seti, haftalık ölçülmüş veriler için test seti ve haftalık ölçülmüş veriler için geçerlilik setlerine ilişkin EKK-DVM'na dayalı çok değişkenli bulanık regresyon analizi sonuçlarının bir bölümü yer almaktadır. Tablolarda gerçek gözlem değerleri, alt tahmin, üst tahmin ve merkez değerleri ile tahmin edilen yayılım miktarları yer almaktadır. Tablolarda, gerçek değerler ve bulanık tahmin aralığının merkez değerinin birbirlerine oldukça yakın değerler aldığı görülmektedir. Tablolarda yer alan değerler h seviye kümesinin 0.7 değerli olduğu durumlar için verilmiştir.

Yumurta performansı değişkeni hem tek hem de çok değişkenli analizde yer almaktadır. Bağımlı değişken sayısının tahmin performansını etkileyip etkilemediği incelendiğinde hem günlük hem de haftalık ölçümler için, hata kriteri değerlerinde oldukça düşük miktarlarda değişim olduğu görülmektedir. Elde edilen bu bulgu, sinir ağları ile gerçekleştirilen analizlere benzer şekilde, EKK-DVM'na dayalı çok değişkenli bulanık regresyon analizi yönteminin farklı şartlar altında oldukça başarılı ve tutarlı sonuçlara sahip olduğunu belirtmektedir. Buna karşılık, klasik regresyon analizinde gözlem

sayılarındaki deęişimin hata kriteri deęerlerini bulanık regresyon analizine göre oldukça etkilediđi görölmektedir. Tez alıřması kapsamında ele alınan doęrusal olmayan bulanık regresyon analizi bulguları karřılařtırmalı olarak incelendiđinde sinir aęlarına dayalı doęrusal olmayan bulanık regresyon analizinin daha başarılı sonuçlara sahip olduđu görölmektedir.



5. SONUÇ VE ÖNERİLER

Bilim ve teknoloji alanında sağlanan gelişmeler, özellikle son 50 yılda bulanık mantık çalışmalarına hız kazandırmıştır. Gerçek dünya ve içinde karşılaşılan problemler karmaşık ve belirsizliklerle doludur. Bu nedenle klasik mantığa dayalı yöntemler çözüm üretme sürecinde yetersiz kalabilmektedir. Bulanık mantık ve ilişkili yöntemler, bu noktada araştırmacılara farklı ve doğaya uygun bakış açıları sunmakta ve belirsizliği sayısallaştırabilmek adına geliştirilmiş dinamik yöntemler arasında yer almaktadır. Bulanık regresyon, bulanık mantığın regresyon analizine uygulanması ile ortaya çıkmış başarılı bir yöntemdir. Doğrusal ve doğrusal olmayan veri yapılarında modelleme gücü oldukça yüksektir.

Bu çalışmada tarımsal verilerin doğrusal olmayan çok değişkenli bulanık regresyon analizinde kullanım olanaklarının belirlenmesi ve klasik regresyon analizi ile karşılaştırmalı olarak incelenmesi amaçlanmıştır. Çalışmada tarımsal alanda yeni bir model geliştirilmiştir. Tez çalışmasına konu olan yumurta performansı ve yumurta ağırlığı değişkenlerinin modellenme sürecinde, sistem yapısında doğada belirgin olmayan olguların var olduğu kabul edilmiştir. Bu noktada bulanık karakterlere sahip bir zeki sistemin, geleneksel yöntemlere göre daha iyi performans göstereceği düşünülmüştür. Tarımsal alanda oldukça yeni kullanılmaya başlanan bulanık regresyon analizi ile literatüre yeni bir bakış açısı kazandırılarak, klasik yöntemlere göre gerçeğe daha yakın tahminler yapabilecek model oluşturulması hedeflenmiştir.

Tez çalışmasında doğrusal olmayan bulanık regresyon analizine ilişkin bulgular, klasik regresyon analizi ile bir karşılaştırmaya tabi tutulmuştur. Çalışmada yer alan veri setleri günlük ve haftalık periyotlar ile ele alınmıştır. Bunun amacı modellerin parametre tahminlerinin ve uyum iyiliği kriterlerinin farklı zaman aralıkları ile ölçümlenmiş veri setlerine verecekleri tepkiyi değerlendirmektir. Sonuçlar incelenen modellerin yapmış olduğu tahmin değerlerinin gerçek değerlere uyumunun oldukça başarılı olduğunu göstermektedir.

Tez çalışmasında tek değişkenli klasik doğrusal olmayan regresyon analizi başlığı altında dört farklı model incelenmiştir. Ele alınan modeller arasında en başarılı tahminler McNally modeli ile elde edilmiştir. Günlük ve haftalık olarak ölçülmüş veri setlerine ilişkin HKO ve OMYH değerleri incelendiğinde, haftalık olarak ölçülmüş veri setinde tüm modeller için hata miktarının arttığı görülmektedir. Bu durum yumurta performans eğrilerinde parametre tahminlerinin veri sayısından oldukça yüksek düzeyde etkilendiğini göstermektedir. Literatürde, tez çalışmasında ele alınan model yapılarının konu olduğu çeşitli yayınlar bulunmaktadır. Bunlardan bazıları şu şekildedir: Narinç ve diğ. (2014) çalışmalarında yumurta üretim eğrisini modellemek amacıyla farklı model yapılarını ele almışlardır. 20 - 70 haftalık yaştaki yumurtacı tavukların haftalık verilerinin kullanıldığı araştırmada eğri uyumunu sağlamak üzere Gamma, McNally, Modified Compartmental ve Adams-Bell modelleri incelenmiştir. Araştırmacılar Modified Compartmental modelin diğer modellere göre daha başarılı olduğunu tespit etmişlerdir. Savegnago ve diğ. (2012) hayvanların seçim süreçlerinden kaynaklı yumurta üretim eğrisinde meydana gelebilecek değişimleri incelemek amacıyla seleksiyon yapılmış ve seleksiyon yapılmamış tavuk hatları üzerinde, haftalık yumurta üretim oranlarını kullanarak doğrusal olmayan ve Segmented Polinomial modeller ile analizlerini gerçekleştirmişlerdir. Bu amaçla Logistic, Compartmental I, McNally, Compartmental II, Yang, Segmented Polinomial ve Persistency modelleri ele alınmıştır. Veriler 17 -70 haftalık yaştaki tavukların verim kayıtlarından oluşmuştur. Logistic, Yang, Segmented Polinomial modelleri en iyi uyuma sahip modeller olarak belirtilmiştir. Çalışmamızda, bahsi geçen her iki çalışmadan farklı olarak veriler hem günlük hem de haftalık olarak ele alınmıştır. Çalışmamızda kullanılan modellerin hata kriterleri ve grafiksel gösterimleri incelendiğinde literatürde yer alan çalışmalar ile uyum gösterdiği belirlenmiştir.

Tez çalışmasında çok değişkenli klasik doğrusal olmayan regresyon analizi McNally modeli kullanılarak incelenmiştir. Günlük ve haftalık ölçümlenmiş veri setleri için, yumurta performansı ve yumurta ağırlığı zamana bağlı olarak birlikte modellenmiştir. Çok değişkenli analiz sonuçları incelendiğinde; günlük veriler için gerçekleştirilen analizlerin haftalık veriler için gerçekleştirilen analizlere göre çok daha başarılı olduğu görülmektedir. Bu durum klasik regresyon analizinin veri seti miktarından oldukça yüksek derecede etkilendiğini göstermektedir. Hayvancılık alanında çok değişkenli doğrusal olmayan regresyon analizini konu alan yayın sayısı, tek değişkenli analizlere göre kısıtlı sayıdadır. Strathe ve diğ. (2010) çalışmalarında domuzlarda büyüme sürecinde metabolize enerji

alımına bağlı yağ ve protein depozitlerinin modellenmesini incelemişlerdir. Çok değişkenli doğrusal olmayan regresyon analizini “mixed effect” kapsamında ele alan araştırmacılar, metabolik parametrelerdeki varyansı bireysel açıdan yorumlamışlardır. Sonuçları fixed effect ve random effect model yapısına sahip analizler ile karşılaştırmışlardır. Büyüme döneminde olan hayvan popülasyonu için ideal beslenme simülasyon modelinin tasarlanması yönünde önerdikleri yöntemin oldukça başarılı olduğunu vurgulamışlardır. Tez çalışmasında, çok değişkenli doğrusal olmayan regresyon analizi için Strathe ve diğ. (2010) tarafından gerçekleştirilen çalışmada kullanılan değişkenlerden farklı olmak üzere eğri modellemesi amacı güdülmüştür. Ancak hem tez çalışmasında hem de bahsi geçen çalışmada çok değişkenli veri analiz modellerinin gelişimine olumlu anlamda katkı sağlandığı düşünülmektedir. Çalışmamızın sonuçları yumurta performansı ve yumurta ağırlığı değişkenlerinin eğri uyumunun başarılı olduğunu göstermektedir.

Tez çalışması kapsamında doğrusal olmayan bulanık regresyon analizi, yapay sinir ağları ve en küçük kareler destek vektör makineleri ile entegreli olarak yapılandırılmıştır. Yapay sinir ağlarına dayalı tek değişkenli doğrusal olmayan bulanık regresyon analizi sürecinde dikkat edilmesi gereken en önemli noktalardan birisi her gözlem değeri için yayılımların hesaplanmasıdır. Tez çalışmasında yayılım değerleri Xu ve Khoshgoftaar (2001) tarafından önerilen yöntem çerçevesinde hesaplanmıştır. Alt ve üst tahmin sınırlarını elde etmek amacıyla birbirinden bağımsız iki sinir ağı eğitilmiştir. Bu noktada sinir ağlarının eğitimi doğrusal modeller gibi düşünülmemelidir. Veriler zamana bağlı ve eğrisel bir yapı sergilediğinden dolayı, eğitimin çok dikkatli yapılması gerekmektedir.

Literatürde hayvancılık alanında doğrusal olmayan regresyon analizine alternatif ve eğri uyumunu konu olan yapay sinir ağı çalışmaları mevcuttur. Roush ve diğ. (2006) çalışmalarında etlik piliçlerde günlük canlı ağırlık verileri ile büyümenin modellenmesi amacıyla yapay sinir ağlarını ve Gompertz büyüme eğrisini karşılaştırmalı olarak ele almışlardır. Veri seti sınırlı sayıda gözlemden oluştuğu için eğitim ve test verileri eşit oranlarda alınmıştır. Çalışmamızda haftalık veriler ile gerçekleştirilen analizlerde eğitim seti tüm veri setinin %60 oranında belirlenmiştir. Ahmad (2009) çalışmasında Roush ve diğ. (2006) tarafından yayınlanan veri setini simülasyon ile veri üretmek amacıyla kullanmıştır. Veri deseninin oluşturulmasının ardından, büyüme eğrisini modellemek amacıyla üç farklı sinir ağı kullanmıştır. Literatürde yer alan diğer yöntemlere göre farklı bir bakış açısı ortaya koyan Ahmad (2009), çalışmamızda olduğu gibi, geri yayılım algoritmaları sinir ağının diğerlerine göre daha başarılı olduğunu bildirmiştir. Büyüme

eğrilerinin modellenmesi ile ilgili çalışmalarda yöntemin işleyişi ve elde edilen sonuçlar çalışmamızda elde edilen sonuçlar ile uyum göstermektedir (Roush ve diğ. 2006; Yu ve diğ. 2006; Ahmad, 2009; Behzadi ve Aslaminejad, 2010; Kaewtapee ve diğ. 2011). Yumurta verim eğrisi ile ilgili gerçekleştirilen çalışmaların büyük bir bölümünde sinir ağlarının eğitim süreci, büyüme eğrilerine benzer şekilde gerçekleşmiştir. Savegnago ve diğ. (2011) çalışmalarında yumurtacı tavukların iki nesil boyunca haftalık periyotlar ile ölçümlenmiş verilerini kullanmışlardır. Tek numaralı haftalar sinir ağının eğitimi ve çift numaralı haftalar ise test edilmesi amacıyla kullanılmıştır. İkinci nesil veri seti ise modellerin geçerliliğini incelemek üzere analizlerde yer almıştır. Çalışmamızda hem günlük hem de haftalık verilerin analizlerinde, sinir ağlarının eğitim seti, Savegnago ve diğ. (2011) tarafından gerçekleştirilen çalışmadan farklı olarak, tüm veri setinin %60'ı oranında belirlenmiştir. Ahmadi ve Golian (2008) çalışmalarında yumurta üretim eğrilerinin sinir ağları ile modellenmesinde iki nesil boyunca elde edilmiş verileri kullanmışlardır. Çalışmamızdan farklı olarak her nesil için verileri 80% eğitim ve 20% geçerlilik seti olmak üzere iki bölüme ayırmışlardır ve analiz sonuçları iki nesil için ayrı ayrı sunulmuştur. Yumurta üretiminin sinir ağları kullanılarak modellendiği bir başka çalışma Ahmad (2011) tarafından gerçekleştirilmiştir. Ahmad (2009) tarafından yapılan çalışmaya benzer şekilde gerçek verilerden oluşan bir veri setini Monte Carlo yöntemi ile simülasyon yapmak amacıyla kullanılmıştır. Araştırmacının önermiş olduğu yöntem, sinir ağlarının hiç görmediği veriler üzerinde tahmin yapmasını sağlamak ve performansını değerlendirmek üzere kullanılmıştır. Sinir ağları kullanılarak yumurta üretiminin modellenmesini konu alan bilimsel çalışmalar incelendiğinde, çalışmamızda elde edilen sonuçlar ile uyum içinde olduğu, sinir ağları yönteminin doğrusal olmayan regresyon analizine alternatif bir yöntem olabileceği ve oldukça başarılı tahmin değerlerinin elde edildiği görülebilmektedir (Ahmad, 2011; Ahmadi ve Golian, 2008; Ghazanfari ve diğ. 2011; Savegnago ve diğ. 2011). Tez çalışmasında literatürde yer alan çalışmalardan farklı olarak analizler hem günlük hem de haftalık periyotlar için gerçekleştirilmiştir. Aynı zamanda verilerin eğitim sürecinde 10 farklı geri yayılım algoritması ile çalışılmıştır. Tez çalışmasında analizler kapsamlı bir şekilde ele alınmıştır. Böylece hem eğitim, test ve geçerlik setlerinin büyüklüğünün hem de algoritma farklılığının analiz başarısına etkisi vurgulanmıştır. Literatürde tez çalışmasında benzer şekilde, yapay sinir ağlarında farklı geri yayılım algoritmalarını konu alan ve sonuçları karşılaştırmalı olarak sunan bilimsel çalışmalar mevcuttur. Bu çalışmaların sonuçları tez çalışmasında elde edilen bulgular ile uyum halindedir (Ghaffari ve diğ. 2006; Kayri, 2016).

Yapay sinir ađlarına dayalı tek deđişkenli doğrusal olmayan bulanık regresyon uygulama sonuçları incelendiđinde, en başarılı tahminlerin BR algoritması ve tan-sig transfer fonksiyonu ile elde edildiđi görölmektedir. Bahsi geçen yönteme ilişkin hata deđerleri günlük ve haftalık veri setleri ile birlikte deđerlendirildiđinde, haftalık ölçümlenmiş verilerin test ve geçerlilik veri setlerinde oldukça küçük bir artışın meydana geldiđini ayrıca klasik doğrusal olmayan regresyon analizinde meydana gelen farklılıktan çok daha küçük olduđu gözlenmiştir. Bu durum veri seti miktarındaki deđişimin sinir ađı analizlerini önemli derecede etkilemediđini göstermektedir. Bahsi geçen yöntemde, bir diđer başarılı geri yayılım algoritması LM algoritmasıdır. Bulanık regresyon analizi teorisinde yer alan h seviye kümeleri beş farklı deđer için hesaplanmıştır. Bu noktada, analizlerde h deđerinin 0.7 ve 0.9 olduđu durumlarda yumurta performans eđrisinin sahip olduđu doğrusal yapının sağlandıđı görölmektedir.

Yapay sinir ađlarına dayalı çok deđişkenli doğrusal olmayan bulanık regresyon uygulama sonuçları incelendiđinde ise bulguların tek deđişkenli analizler ile uyumlu olduđu görölmektedir. Burada BR algoritması ile tan-sig transfer fonksiyonun yer aldıđı bulanık regresyon analizinin diđer analizlere göre daha başarılı olduđu görölmüştür. h deđerinin 0.7 ve 0.9 olduđu seviyelerde tahmin edilen bulanık aralıkların yumurta performans eđrilerinin yorumlanmasına daha uygun olduđu belirlenmiştir.

Yapay sinir ađları yöntemi, doğrusal olmayan regresyon analizinde oldukça büyük bir öneme sahiptir. Literatürde bu konuda yapılmış ilk çalışmalardan birisi Ishibuchi ve Tanaka (1992) tarafından sunulmuştur. Günümüzde gerçekleştirilen çalışmalara temel niteliđinde olan bu araştırmada aralık deđerli bulanık sayıların alt ve üst sınırlarının uyumu, bağlantı ađırlıkları ve sapmaları kesin sayı olan, birbirinden bađımsız geri yayılım algoritması ile çalışan iki sinir ađı ile sağlanmıştır. Araştırmacılar doğrusal olmayan bulanık regresyon analizinde girdi ve çıktıları bulanık sayı olarak sisteme dahil etmişlerdir. Araştırmacıların 1993 yılında yaptıkları bir başka çalışmada, bulanık regresyon analizini gerçekleştirmek üzere tek bir geri yayımlı sinir ađı kullanmışlar ve bağlantı ađırlıkları ile sapmaları aralık deđerli bulanık sayı olarak ele almışlardır. Çalışmamıza benzer şekilde girdiler kesin, çıktılar ise bulanık sayı olmaktadır (Ishibuchi ve diđer., 1993). Ishibuchi ve diđer., (1995), çalışmalarında bulanık regresyon analizinde, bağlantı ađırlıkları ve sapmaların üçgensel bulanık sayı olduđu, girdi ve çıktıların aralık deđerli bulanık sayı olduđu ve çalışmamıza benzer şekilde geri yayılım algoritmalı sinir ađını kullanmışlardır. Bahsi geçen araştırmaların bulguları çalışmamızda elde edilen bulgular ile uyum göstermektedir.

Tez çalışmasında tek ve çok değişkenli doğrusal olmayan bulanık regresyon analizi Xu ve Khoshgoftaar (2001) tarafından önerilen yöntem çerçevesinde uygulanmıştır. Xu ve Khoshgoftaar (2001) çalışmalarında Ishibuchi ve Tanaka (1992) tarafından önerilen yöntemden farklı olarak, doğrusal olmayan bulanık regresyon analizi sürecinde maliyet fonksiyonu yerine bağımlı değişkenin ortalaması ve standart sapmasını kullanmışlardır. Araştırmacılar telekomünikasyon sistemlerinde yazılım hatalarının olası muhtemel tahmin aralığını üretebilen bulanık doğrusal olmayan regresyon modeli geliştirmişlerdir ve oldukça büyük boyutlu bir veri seti ile çalışmışlardır. Çoklu doğrusal regresyon analizi ile gerçekleştirdikleri karşılaştırmada yazılım kalite modelinin bulanık doğrusal olmayan regresyon analizinde çok daha başarılı bir şekilde elde edildiği belirtilmiştir. Bahsi geçen araştırma bulguları tez çalışmasında elde edilen bulgular ile uyum göstermektedir. Tez çalışmasında hem tek hem de çok değişkenli analizlerde, bu çalışmadan farklı olarak 10 farklı geri yayılım algoritması 3-20 nöron arasında her nöron için kullanılmıştır. Araştırmacılar 0.10 ve 0.05 olmak üzere iki farklı h seviyesi ile çalışmışlardır. Tez çalışmasında ise beş farklı h seviyesi ile analizler gerçekleştirilmiştir. Sinir ağları tabanlı doğrusal olmayan bulanık regresyon analizinin oldukça ayrıntılı bir şekilde ele alındığı çalışmamızda elde edilen sonuçlar hem gerçek gözlem değerleri ile hem de klasik regresyon ile elde edilen tahmin sonuçları ile karşılaştırılmıştır. Yöntemin, yumurta verimini temsil eden eğrisel yapıdaki verilerin tek ve çok değişkenli analizlerinde başarılı bir şekilde kullanılabilceği sonucuna varılmıştır.

Tekşen (2008) ve Tekşen ve Evren (2012) tarafından yapılan çalışmalarda, çalışmamıza benzer şekilde Xu ve diğ. (2000) tarafından önerilen yöntem kullanılmıştır. Tekşen (2008) çalışmasında yapay sinir ağları, en küçük kareler destek vektör makinaları ve bulanık en küçük mutlak sapma regresyonu olmak üzere üç farklı yöntemi doğrusal olmayan bulanık regresyon analizi için kullanmış ve karşılaştırmalı olarak incelemeye tabi tutmuştur. Çalışmamızda olduğu gibi analiz sonuçları yapay sinir ağı yönteminin tahmin başarısının diğer yöntemlere göre daha yüksek olduğu belirtilmiştir. Bahsi geçen çalışmada simülasyon yöntemi ile üretilmiş 25 veri kullanılmış ve doğrusal olmayan bulanık regresyon analizi iki farklı h seviye kümesinde incelenmiştir. Çalışmamızda ise gerçek dünyaya ait farklı boyutlarda veri setleri beş farklı h seviye kümesi ile ele alınmıştır. He ve diğ. (2016) tarafından yapılan çalışmada ise üçgensel bulanık sayıların yer aldığı sinir ağı tabanlı bulanık regresyon analizini gerçekleştirmek üzere geri yayılım algoritmaları sinir ağı ile radyal tabanlı fonksiyon sinir ağı kullanılmıştır. Çalışmamızdan farklı olarak, geri

yayımlı algoritmaları ile çalışan çok katmanlı algılayıcı ve radyal tabanlı sinir ağlarının yanı sıra ağ ağırlıklarının iteratif düzenlenmesine ihtiyaç duyulmadığı bunun yerine rassal ağırlıkların kullanıldığı sinir ağlarını kullanmışlar ve farklı veri setleri üzerinde sayısal uygulamalar gerçekleştirmişlerdir. Araştırmacılar rassal ağırlıkların kullanıldığı sinir ağlarının diğer yöntemlere göre daha başarılı olduğunu bildirmişlerdir. He ve diğ. (2018) ise girdi ve çıktıların yamuk bulanık sayı olduğu rassal ağırlık ağlarını doğrusal olmayan bulanık regresyon analizi için geri yayılım algoritmaları ile çalışan çok katmanlı algılayıcı ile karşılaştırmışlardır. Araştırmacılar rassal ağırlıkların kullanıldığı sinir ağlarının çok katmanlı algılayıcıya göre daha başarılı olduğunu bildirmişlerdir. He ve diğ. (2016) ile He ve diğ. (2018) tarafından gerçekleştirilen çalışmalarda, tez çalışmamıza benzer şekilde, h seviyelerindeki artışların bulanık tahmin aralığını daralttığı ve doğrusal olmayan veri yapılarının oldukça başarılı bir şekilde modellendiği görülmektedir.

Yapay sinir ağlarına dayalı doğrusal olmayan bulanık regresyon analizi ve klasik regresyon analizi, uygulamaların sayısal bulguları ve yöntemlerin teorik yapısı açısından karşılaştırıldığında araştırmacılar açısından oldukça faydalı bilgiler ortaya çıkmıştır. Doğrusal olmayan bulanık regresyon analizi yapay sinir ağları ile yapılandırıldığından dolayı, klasik regresyon analizinde var olan varsayımlar geçerli değildir. Bu durum tahmin değerlerinin elde edilmesinde araştırmacılara büyük kolaylık sağlamaktadır. Sinir ağlarının kullanımı ile ilgili bir diğer avantaj, eğri uyumunun veri setinde yer alan gözlem sayısından, klasik regresyonda olduğu gibi, etkilenmiyor olmasıdır. Klasik regresyon analizlerinde parametrelerin başlangıç değerleri ve gözlem sayısı uyum iyiliği ile oldukça yakından ilişkilidir. Sinir ağları ve ilişkili yöntemlerde uyum süreci, sinaptik ağırlıkların öğrenme işlemi sırasında otomatik olarak ayarlanması ve verilerin katmanlar boyunca paralel olarak yerleştirilmesinden dolayı, klasik regresyona göre oldukça hızlıdır. Bahsi geçen yönteme ilişkin bir diğer önemli avantaj, çıktı değişkenine etki eden çevresel etkilerin sayısal bulgularının modele dahil edilebilir olmasıdır. Bir başka ifade ile, modelde yer alan girdi değişkeni sayısının birden fazla olabilmesidir. Doğrusal olmayan klasik regresyon analizi kapsamında incelenen model yapılarında tek bir girdi değişkenine yer verilmektedir. Sinir ağının teorik yapısı gereğince, doğrusal olmayan bulanık regresyon analizine ilişkin kısıtların başında parametre tahmininin yapılmıyor olması gelmektedir. Ayrıca nöron ve katman sayılarına ilişkin optimal değerlerin elde edilmesinde kesin bir formülasyon bulunmamaktadır.

Literatürde doğrusal ve doğrusal olmayan regresyon analizine alternatif olarak kullanılan bir diğer yapay zeka yöntemi en küçük kareler destek vektör makineleridir. Doğrusal olmayan bulanık regresyon analizlerinde, sinir ağlarına benzer şekilde, tahmin aralığının elde edilmesi amacıyla kullanılabilir. EKK-DVM'na dayalı bulanık regresyon analizi süreci sinir ağları ile gerçekleştirilen analizlere benzer şekilde sürdürülmüştür. Çalışmamızda Hong ve Hwang (2006) tarafından doğrusal olmayan bulanık regresyon analizini modellemek üzere önerilmiş yöntem kullanılmıştır. Hong ve Hwang (2006), çalışmalarında bulanık çok değişkenli doğrusal olmayan regresyon modeli için bulanık girdi ve bulanık çıktı verilerini kullanarak yeni bir yöntem geliştirmişlerdir. Çalışmamızdan farklı olarak bağımlı değişkenin yayılım ve merkez değerleri simülasyon yoluyla türetilmiştir ve sadece Polinomial Kernel fonksiyonu kullanılmıştır. Bahsi geçen çalışmanın analiz sonuçları, tez çalışmamızda elde edilen bulgulara benzer şekilde, oldukça başarılı bulunmuştur. EKK-DVM'nı konu alan bir diğer doğrusal olmayan bulanık regresyon çalışması Hong ve diğ. (2006) tarafından gerçekleştirilmiştir. Önerilen yöntemde, çalışmamızdan farklı olarak lokal ağırlıklandırılmış en küçük kareler destek vektör makinesi regresyonunun uygulanması ile elde edilmiştir. Lokal ağırlıklar eğitim ve test verileri arasındaki pozitif metrik uzaklıktan elde edilmiştir. Ülkemizde bu alanda gerçekleştirilen çalışmalardan Tekşen (2008) ile Tekşen ve Genç (2012) tarafından yapılan çalışmalarda, doğrusal olmayan bulanık regresyon analizine ilişkin uygulamayı çalışmamızda uygulanan yöntem çerçevesinde gerçekleştirmişlerdir. Karadavut ve diğ. (2009) mısır bitkilerinde büyümenin modellenmesi amacıyla EKK-DVM'na dayalı doğrusal olmayan bulanık regresyon analizini kullanmışlardır. Tarımsal alanda gerçekleştirdikleri çalışmalarında, tez çalışmamızın sonuçları ile uyumlu ve başarılı bulgular elde edilmiştir. Literatürde EKK-DVM'nı konu olan doğrusal (Qu ve Ding, 2012; Lu ve diğ.2013; Yang ve diğ. 2014) ve doğrusal olmayan (Yao ve Yu, 2006; Yongqi, 2012) bulanık regresyon çalışmalarının yanı sıra güncel çalışmalarda optimizasyon yöntemleri ile entegreli çalışan sistemler üzerine yoğunlaşıldığı görülmektedir. Zaman serilerinde genetik algoritma (Hung ve Lin, 2013; Lin ve diğ. 2013; Lin ve Pai., 2010) ile termal konfor endekslerini tahmin etmek üzere parçacık sürü optimizasyonunun kullanıldığı çalışmalar mevcuttur (Megri ve diğ., 2016).

En küçük kareler destek vektör makinelerine dayalı doğrusal olmayan bulanık regresyon analizi Radial Basis Function, Polinomial Kernel Fonksiyonu ve Doğrusal Kernel Fonksiyonu olmak üzere üç farklı Kernel fonksiyonu ile yapılandırılmıştır. Model

parametrelerinin optimal deęerlerini belirlemek üzere farklı parametre kombinasyonlarında analizler gerekleřtirilmiřtir. En kk kareler destek vektr makinelerine dayalı tek ve ok deęiřkenli doęrusal olmayan bulanık regresyon analizi sonuları incelendięinde RBF Kernel Fonksiyonu ile tasarlanan sistemlerin dięerlerine gre daha bařarılı olduęu belirlenmiřtir.

ıktı deęiřkeni sayısının birden fazla olduęu durumlarda, yapay sinir aęları ve EKK-DVM yntemlerinin kullanımı mmkndr (Trundle ve dię. 2007; Khoshnevisan ve dię. 2014; Torres-Valencia ve dię. 2014; Falck ve dię. 2015). alıřmamızda ok deęiřkenli bulanık regresyon analizinin inřasında, tek deęiřkenli analizlerde olduęu gibi, yapay sinir aęları ve EKK-DVM yntemlerinden yararlanılmıřtır. Yumurta performansı ve yumurta aęırlıęı zamana baęlı olarak birlikte deęiřebilen karakterlerdir. ok deęiřkenli doęrusal olmayan bulanık regresyon analizi sonuları gerek deęerlere uyum aısından olduka bařarılı bulunmuřtur.

Hayvancılık alanında doz-cevap dzeyi, sıcaklık, metabolik enerji veya zamana baęlı olarak deęiřen eřitli deęiřkenlerin modellenmesinde ve biyolojik anlamda yorumlanmasında doęrusal olmayan regresyon analizi nemli bir yere sahiptir. Doęrusal olmayan regresyon analizi kapsamında incelenen yumurta verim eęrileri, zellikle ticari yumurtacı tavuklarda bireysel veya sr bazında retim deseninin incelenmesinde ve ortalama retim oranının yorumlanmasında kullanılmaktadır. Yumurta verimi, canlı aęırlık ve st verimine benzer řekilde ekonomik deęeri yksek karakterlerden birisidir. Matematiksel modeller aracılıęı ile bilimsel bulgulara dayanarak biyolojik aıdan yorumlanması retici ve karar vericiler aısından byk nem arz etmektedir. Bu baęlamda arařtırmacılar; genetik ve evresel faktrlerin yumurta verim zellikleri zerindeki etkisi, yumurta retim verimlilięini artırmak iin alternatif stratejilerin belirlenmesi, hayvanların genetik avantajının ve verim potansiyelinin deęerlendirilmesi, hayvanların beklenen gnlk verim artıřına dayalı olarak besin gereksinimleri iin beslenme programlarının planlanmasına benzer konularda yumurta verim eęrilerinden kapsamlı řekilde yararlanmaktadırlar. Matematiksel modeller ıřıęında hayvan ıslahı ve sr ynetimine iliřkin geleceęe ynelik doęru ve stratejik kararların alınması ile ekonomi, zaman ve iř gc konularında iřletme sahiplerine ve lke ekonomisine nemli katkılar saęlanmaktadır.

Doğrusal olmayan veya eğrisel veri yapılarının, bulanık karakterlere sahip zeki sistemler ile modellenmesi yeni bir konudur. Ülkemizde bu konu ile ilgili yayın sayısı oldukça kısıtlı sayıdadır. Tez çalışmasında, hem yapay sinir ağları ve EKK-DVM, hem de bu yöntemler ile entegreli çalışan doğrusal olmayan bulanık regresyon analizi yöntemleri teorik açıdan ayrıntılı bir şekilde sunulmuştur. Tarımsal alanda kullanılan veri setleri ile yürütülen uygulamalara ilişkin bulgular, bahsi geçen yöntemlerin geleneksel yöntemlere alternatif olarak kullanılabileceğini göstermektedir. Klasik yöntemlere göre farklı bakış açıları sunan ve daha düşük hata payları ile başarılı tahminler gerçekleştiren yeni yöntemlerin alan literatürüne kazanımı, bu yöntemlerin kullanımı ile yumurta verim eğrilerinin hayvancılık sektörüne ve araştırmacılara sağlayacağı katkıların daha da artması hedeflenmektedir. Çok değişkenli istatistiksel yöntemler ile yapay zeka yöntemleri ve optimizasyon temelli yöntemlerin birlikte tasarlanması, gelecekte hayvancılıkta karar alma ve öngörü süreçlerinde daha farklı bakış açıları sunacaktır. Doğrusal olmayan bulanık regresyon analizi konusunda çalışacak olan araştırmacılara bu tez çalışmasının ışık tutacağı düşünülmektedir.

6. KAYNAKÇA

- Acilar, M.A. and Arslan, A., 2011, Optimization of multiple input–output fuzzy membership functions using clonal selection algorithm, *Expert system with applications*, 38 (3), 1374-1381.
- Acton, S.T., 1998, On fuzzy nonlinear regression for image enhancement, *Journal of mathematical imaging and vision*, 8 (3), 239–253.
- Ahmad, H.A., 2009, Poultry growth modeling using neural networks and simulated data, *Journal of applied poultry research*, 18 (3), 440-446.
- Ahmad, H.A., 2011, Egg production forecasting: Determining efficient modeling approaches, *J. Appl. Poult. Res.*, 20 (4), 463–473.
- Ahmadi, H. and Golian, A., 2008, Neural network model for egg production curve. *Journal of animal and veterinary advances*, 7 (9), 1168-1170.
- Akıllı, A. ve Atıl H., 2014, Süt sığırcılığında yapay zeka teknolojisi: Bulanık mantık ve yapay sinir ağları, *Hayvansal Üretim*, 55 (1), 39-45.
- Akkaptan, A., 2012, *Hayvancılıkta bulanık mantık tabanlı karar destek sistemi*, Yüksek Lisans Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü.
- Ali, T.E. and Schaeffer, L.R., 1987, Accounting for covariances among test day milk yields in dairy cows, *Can. J. Anim. Sci.*, 67 (3), 637-64.
- Alpar, R., 2011, *Çok değişkenli istatistiksel yöntemler*, Detay Yayıncılık.
- Arslan, A. and Kaya, M., 2001, Determination of fuzzy logic membership functions using genetic algorithms, *Fuzzy Sets. Syst.*, 118 (2), 297-306.
- Atıl, H., 1991, *Doğrusal olmayan (nonlinear) cevap yüzeyi modellerinin doğrusallıktan uzaklaşmaları ölçütleri ve bu ölçütlerin parametre tahminleri üzerine etkilerinin incelenmesi*, Doktora Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü.
- Bağış, A., 2003, Determining fuzzy membership functions with tabu search an application to control, *Fuzzy Sets. Syst.*, 139 (1), 209-225.
- Bárdossy, A. 1990, Note on fuzzy regression, *Fuzzy Sets. Syst.*, 37(1), 65-75.
- Bardossy, A., Bogardi, I. and Duckstein, L., 1990, Fuzzy regression in hydrology, *Water resources research*, 26 (7), 1497-1508.

- Bardossy, A., Bogardi, I. and Duckstein, L., 1993, Fuzzy nonlinear regression analysis of dose-response relationships, *European journal of operational research*, 66 (1), 36-51.
- Bardossy, A., Bogardi, I. and Kelly, W., 1987, Fuzzy regression for electrical resistivity-Hydraulic conductivity relationships, In: J. Chameau and J.T.P. Yao (eds.), Proceedings of the North American Fuzzy Information Processing Society Workshop, 333-352.
- Başaran, M.A., 2007, *Çok Değişkenli Bulanık Regresyonda Parametre Tahmini*, Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü.
- Baser, F. and Demirhan, H., 2017, A fuzzy regression with support vector machine approach to the estimation of horizontal global solar radiation, *Energy*, 123, 229-240.
- Bates, D.M. and Watts, D.G., 1988, *Nonlinear regression analysis and its applications*, John Wiley & Sons, Inc.
- Baykal, N. ve Beyan, T., 2004a, *Bulanık mantık ilke ve temelleri*, Bıçaklar Kitabevi, Ankara.
- Baykal, N. ve Beyan, T., 2004b, *Bulanık mantık uzman sistemler ve denetleyiciler*, Bıçaklar Kitabevi, Ankara.
- Behzadi, M.R.B. and Aslaminejad, A.A., 2010, A comparison of neural network and nonlinear regression predictions of sheep growth, *Journal of animal and veterinary advances*, 9 (16), 2128-2131.
- Berberoğlu, E., 2010, *Süt sığırlarında zaman serisi yöntemleriyle laktasyon eğrilerinin modellenmesi*, Doktora Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü.
- Bessedik, S.A. and Hadi, H., 2013, Prediction of flashover voltage of insulators using least squares support vector machine with particle swarm optimisation, *Electric power systems research*, 104, 87-92.
- Borin, A., Ferrao, M.F., Mello, C., Maretto, D.A. and Poppi, R.J., 2006, Least-Squares support vector machines and near infrared spectroscopy for quantification of common adulterants in powdered milk, *Analytica chimica acta*, 579 (1), 25-32.
- Boser, B.E., Guyon, I.M. and Vapnik V.N., 1992, A training algorithm for optimal margin classifiers, *Inproceedings of the fifth annual workshop of computational learning theory*, 5, 144–152, Pittsburgh, ACM.
- Brody, S., Henderson, E.W. and Kempster, H.L., 1923a, The rate of senescence of the domestic fowl as measured by the decline in egg production with age, *J. Gen. Physiol.*, 6 (1), 41-45.

- Brody, S., Ragsdale, A.C. and Turner, C.W., 1923b, The rate of decline of milk secretion with the advance of the period of lactation, *J. Gen. Physiol.*, 5 (4), 441-444.
- Brody, S., Turner, C.W. and Ragsdale, A.C., 1924, The relation between the initial rise and subsequent decline of milk secretion following parturition, *J. Gen. Physiol.*, 6 (5), 541–545.
- Bryson, A.E. and Ho, Y.C., 1969, *Applied optimal control: Optimization, estimation and control*, Blaisdell Publishing Company, New York.
- Buckley, J.J. and Feuring, T., 2000, Linear and non-linear fuzzy regression: Evolutionary algorithm solutions, *Fuzzy Sets. Syst.*, 112 (3), 381-394.
- Buttchereit, N., Stamer, E., Junge, W. and Thaller, G., 2010, Evaluation of five lactation curve models fitted for fat: protein ratio of milk and daily energy balance, *J. Dairy Sci.*, 93 (4), 1702-1712.
- Cason, J.A. and Ware G.O., 1990, Analysis of flock egg production curves using generalized growth functions, *Poult. Sci.*, 69 (7), 1054–1069.
- Çelikyılmaz, A. and Türkşen, I.B., 2009, *Modeling uncertainty with fuzzy logic with recent theory and applications*, Springer, Berlin / Heidelberg,
- Celmins, A., 1987a, Multidimensional least-squares fitting of fuzzy models, *Mathematical modelling*, 9 (9), 669–690.
- Celmins, A., 1987b, Least squares model fitting to fuzzy vector data, *Fuzzy Sets. Syst.*, 22 (3), 245–269.
- Celmins, A., 1991, A practical approach to nonlinear fuzzy regression, *Siam J. Sci., Stat. Comput.*, 12 (3), 521-546.
- Chachi, J., Taheri, S.M. and Rezaei Pazhand H., 2016, Suspended load estimation using L1-fuzzy regression, L2-fuzzy regression and MARS-fuzzy regression models. *Hydrological sciences journal*, 61 (8), 1489–1502.
- Chan, K.Y., Kwong, C.K. and Law, M.C., 2014, A fuzzy ordinary regression method for modeling customer preference in tea maker design., *Neurocomputing*, 142 (2014), 147–154.
- Chang, P. and Lee, S., 1994, Fuzzy least absolute deviations regression based on the ranking of fuzzy numbers, *In Fuzzy Systems, IEEE World Congress on Computational Intelligence, Proceedings of the Third IEEE Conference on IEEE*, 1365-1369.
- Chang, P.T. and Lee, E.S., 1996, A generalized fuzzy weighted least-squares regression. *Fuzzy Sets. Syst.*, 82 (3), 289–298.

- Chang, Y.H.O. and Ayyub, B.M., 1993, Reliability analysis in fuzzy regression, *In: Proceedings of The Annual Conference of The North American Fuzzy Information Processing Society (Nafips '93)*, Allentown, Pa, Us, 93–97.
- Chang, Y.H.O., 2001, Hybrid fuzzy least-squares regression analysis and its reliability measures. *Fuzzy Sets. Syst.*, 119 (2), 225–246.
- Chang, Y.O. and Ayyub B.M., 2001, Fuzzy regression methods- A comparative assessment. *Fuzzy Sets. Syst.*, 119 (2), 187-203.
- Chaturvedi, D.V., 2010, *Modeling and simulation of systems using matlab and simulink*, Crc Press, Taylor & Francis Group, New York.
- Chen, L.H., Hsueh, C.C., 2009, Fuzzy regression models using the least-squares method based on the concept of distance, *IEEE Transactions on Fuzzy Systems*, 17 (6), 1259-1272.
- Chen L.H., Hsueh C.C. and Chang C.J., 2013, A two-stage approach for formulating fuzzy regression models. *Knowledge-Based Systems*, 52 (2013), 302–310.
- Chen, F., Chen, Y., Zhou, J. and Liu Y., 2015, Optimizing h value for fuzzy linear regression with asymmetric triangular fuzzy coefficients, *Engineering Applications of Artificial Intelligence*, 47, 16-24.
- Chen, J., Kok, A., Rimmelink, G.J., Gross, J.J., Bruckmaier, R.M., Kemp, B. and Van Knegsel, A.T.M., 2016, Effects of dry period length and dietary energy source on lactation curve characteristics over 2 subsequent lactations, *J. Dairy Sci.*, 99(11), 9287-9299.
- Chen, Wei., Xiao, Xiao. and Zhang, Jian., 2012, Application of fuzzy least squares support vector machines in landslide deformation prediction, *In: Advanced Materials Research Trans Tech Publications*, (594), 2402-2405.
- Chen, Y.S., 2001, Outliers detection and confidence interval modification in fuzzy regression. *Fuzzy Sets. Syst.*, 119, 259–272.
- Cheng, C.B. and Lee E.S., 1999, Applying fuzzy adaptive network to fuzzy regression analysis. *Computers and mathematics with applications*, 38 (2), 123-140.
- Cheng, C.B. and Lee S., 2001, Fuzzy regression with radial basis function network, *Fuzzy Sets. Syst.*, (1192), 291–301.
- Cheng, C.B. and Lee, E.S, 2001, Fuzzy regression with radial basis function network, *Fuzzy Sets. Syst.*, 119 (2), 291-301.

- Choi C.S. and Abdullah L., 2016, Prediction of carbon dioxide emissions using two linear regression-based models: A comparative analysis, *Journal of applied engineering*, 4 (4).
- Chou T.Y., Liang G.S. and Han T.C., 2013, Application of fuzzy regression on air cargo volume forecast, *Qual Quant.*, 45 (6), 1539-1550.
- Ciavolinoa E. and Calcagni A., 2016, A generalized maximum entropy (gme) estimation approach to fuzzy regression model, *Applied soft computing*, 38 (2016), 51–63.
- Cobby, J.M. and Le Du, Y.L.P., 1978), On fitting curves to lactation data, *Anim. Prod.*, 26, 127-133.
- Craninx, M., Steen, A., Van Laar, H., Van Nespen, T., Martín-Tereso, J., De Baets, B. and Fievez, V., 2008, Effect of lactation stage on the odd- and branched-chain milk fatty acids of dairy cattle under grazing and indoor conditions, *J. Dairy Sci.*, 91, 2662-2677.
- D'urso, P. and Gastaldi, T., 2000, A least-squares approach to fuzzy linear regression analysis. *Computational statistics and data analysis*, 34, 427–440.
- D'urso, P. and Gastaldi, T., 2002, An ordewise polynomial regression procedure for fuzzy data. *Fuzzy Sets. Syst.*, 130, 1–19.
- De Mulder, W., Bethard, S., and Moens, M.F., 2015, A survey on the application of recurrent neural networks to statistical language modeling. *Computer Speech & Language*, 30 (1), 61-98.
- Deluyker, H.A., Shumway, R.H., Wecker, W.E., Azari, A.S. and Weaver, L.D., 1990, Modeling daily milk yield in holstein cows using time series analysis, *J. Dairy Sci.*, 73, 539-548.
- Diamond P. and Tanaka H., 1998, *Fuzzy Regression Analysis*, In: Słowiński R. (Eds) Fuzzy sets in decision analysis, operations research and statistics, the handbooks of fuzzy sets series, Vol 1, Springer, Boston, Ma, 349-387.
- Diamond, P., 1988a, Fuzzy least squares, *Information sciences*, 46, 141-157.
- Diamond, P., 1988b, Some maximumlikelihood estimates for the fuzzy linear model, *In proc. conference on information processing and management of uncertainty in knowledge-based systems*, Urbino, Italy.
- Diamond, P., 1997, Korner R. Extended fuzzy linear models and least squares estimate. *Comput. Math. Appl.* 33, 15–32.
- Dubois D. and Prade H., 1979, Fuzzy real algebra: Some results, *Fuzzy Sets. Syst.*, 2 (1979) 327-348.

- Dubois D. and Prade H., 1980, *Fuzzy sets and systems: Theory and application*, Academic.
- Dubois D., 1983, Prade H. Ranking fuzzy numbers in the setting of possibility theory, *Inform. Sci.*, 30, 183-224.
- Dubois, D. and Prade, H., 1978, Operations on fuzzy numbers, *Int. J. Syst. Sci.*, 9 (6), 613–626.
- Dubois, D., 1987. *Linear programming with fuzzy data*, In *analysis of fuzzy information*, Vol. 3 (J.C. Bezdek, Ed.), Crc Press.
- Elman, J.L., 1990, Finding structure in time, *Cognitive science*, 14, 179-211.
- Elmas, Ç., 2011, *Yapay zeka uygulamaları*, Seçkin Yayıncılık, Ankara.
- Falck, T., De Moor, B. and Suykens, J.A., 2014, Kernel based identification of systems with multiple outputs using nuclear norm regularization, *Regularization, optimization, kernels, and support vector machines*, 371.
- Fedrizzi, M. and Kacprzyk, J., 1995, Brief introduction to fuzzy sets, In: Kacprzyk, J. and Onisawa, T. (ed.), Chapter 1, Heidelberg: Physica-Verlag, 31-39.
- Feng H., 2011, Forecasting comparison between two nonlinear models: Fuzzy Regression versus setar, *Applied economics letters*, 18, 17, 1623-1627.
- Fialho, F.B. and Ledur, M.C., 1997, Segmented polynomial model for estimation of egg production curves in laying hens, *British poultry science*, 38, 66–73.
- France, J., Dijkstra, J. and Dhanoa, M.S., 1996, Growth functions and their application in animal sciences, *Annales de zootechnie*, 45, 165–174.
- France, J., Dijkstra, J., Dhanoa, M.S., López, S. and Bannink, A., 2000, Estimating the extent of degradation of ruminant feeds from a description of their gas production profiles observed in vitro: derivation of models and other mathematical considerations, *British journal of nutrition*, 83, 131–142.
- Gaeta, M., Loia, V. and Tomasiello, S., 2014, A fuzzy functional network for nonlinear regression problems, *International journal of knowledge engineering and soft data paradigms*, 4 (4), 351-370.
- Gallant, A. R., 1987, *Nonlinear statistical models*, John Wiley & Son, Inc.
- Gavora, J.S., Liljedahl, L.E., McMillan, I. and Ahlen. K., 1982, Comparison of three mathematical models of egg production, *Br. Poult. Sci.*, 23, 339–348.
- Genç, A., 1997, *Çok değişkenli lineer olmayan modeller: Parametre tahmini ve hipotez testi*, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü.
- Ghaffari, A., Abdollahi, H., Khoshayand, M.R., Bozchalooi, I.S., Dadgar, A. and Rafiee-Tehrani, M., 2006., Performance comparison of neural network training algorithms

- in modeling of bimodal drug delivery, *International journal of pharmaceutics*, 327 (1), 126-138.
- Ghazanfari, S., Nobari, K. and Tahmoorespur, M., 2011., Prediction of egg production using artificial neural network, *Iranian journal of applied animal science*, 1.
- Gill, M. and Oldham, J.D., 1993, Growth. In: Forbes, J.M. France, J. (Eds) *Quantitative aspects of ruminants' digestion and metabolism*, Cab International, Wallingford, UK.
- Golebiewski M., Brzozowski P. and Gołębiewski L., 2011, Analysis of lactation curves, milk constituents, somatic cell count and urea in milk of cows by the mathematical model of wood. *Acta. Vet. Brno.*, 80, 073–080.
- Gonzalez-Gonzalez, D.S., Alejo, R.J.P., Cantú-Sifuentes, M., Torres-Treviño, L.M. and Méndez, G.M., 2014, A non-linear fuzzy regression for estimating reliability in a degradation process, *Applied soft computing*, 16, 137-147.
- González-González, D.S., Praga-Alejo, R.J. and Cantú-Sifuentes, M., 2016, A Non-Linear fuzzy degradation model for estimating reliability of a polymeric coating, *Applied Mathematical modelling*, 40 (2), 1387-1401.
- Görgülü, Ö., 2007, *Bulanık mantık (fuzzy logic) teorisi ve tarımda kullanım olanakları üzerine bir araştırma*, Doktora Tezi, Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Hatay, 107s.
- Graupe, D., 2013, *Principles of artificial neural networks*, World Scientific Publishing.
- Grossman, M., Grossman T.N. and Koops W.J., 2000, *A model for persistency of egg production. Poult. Sci.*, 79, 1715–1724.
- Grzesiak, W., Błaszczyk, P. and Lacroix, R., 2006, Methods of predicting milk yield in dairy cows—predictive capabilities of Wood's lactation curve and artificial neural networks (ANNs), *Computers and electronics in agriculture*, 54 (2), 69–83.
- Gujarati, D.N., 1999, *Basic econometrics*, McGraw-Hill.
- Guo, P. and Tanaka, H., 2006, Dual models for possibilistic regression analysis. *Computational statistics & Data analysis*, 51(1), 253-266.
- Han, J., Kamber, M. and Pei, J., 2006, *Data mining concepts and techniques*, Morgan Kaufmann Publishers Inc. San Francisco, Ca, USA.
- Hanss, M., 2005, *Applied fuzzy arithmetic: An introduction with engineering applications*, Springer-Verlag, Berlin.
- Hayashi, I., and Tanaka, H., 1990, The fuzzy GMDH algorithm by possibility models and its application. *Fuzzy Sets and Systems*, 36 (2), 245-258.

- Haykin, S., 1999, *Neural networks: A comprehensive foundation*, 2nd Ed. Prentice-Hall, Upper Saddle River, Nj.
- Haykin, S., 2009, *Neural networks and learning machines*, (3rd Edition) New York: Prentice Hall/Pearson.
- He, Y.L., Wang, X.Z. and Huang, J.Z., 2016, Fuzzy nonlinear regression analysis using a random weight network. *Information sciences*, (364–365), 222-240.
- He, Y.L., Wei, C.H., Long, H., Ashfaq, R.A.R. and Huang, J.Z., 2018, Random weight network-based fuzzy nonlinear regression for trapezoidal fuzzy number data. *Applied soft computing*, 70, 959-979.
- Heshmaty, B. and Kandel, A., 1985, Fuzzy linear regression and its applications to forecasting in uncertain environment, *Fuzzy Sets. Syst.*, 15 (2), 159-191.
- Hojati, M., Bector, C.R. and Simimo, K., 2005, A simple method for computation of fuzzy linear regression. *European journal of operational research*, 166, 172-184.
- Honarbaksh, A., Dashtpajardi, M.M. and Vagharfard, H., 2013, Application of soft computing methods in predicting evapotranspiration, *In international conference on computational and information science*, Springer Berlin Heidelberg.
- Hong, D.H. and Hwang, C., 2003, Support vector fuzzy regression machines, *Fuzzy Sets. Syst.*, 138 (2), 271-281.
- Hong, D.H. and Hwang, C., 2006, Fuzzy nonlinear regression model based on LSSVM, *In feature space, in international conference on fuzzy systems and knowledge discovery*, Lnai 4223, Pp. 208-216.
- Hong, D.H., Hwang, C., Shim, J. and Seok, K.H., 2006, Locally weighted LS-SVM for fuzzy nonlinear regression with fuzzy input-output, *In international conference on computational and information science*, Springer Berlin Heidelberg.
- Hopfield, J.J. and Tank, D.W., 1985, 'Neural' computation of decisions in optimization problems, *Biological cybernetics*, 52, 141-152.
- Hopfield, J.J., 1982, Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the national academy of sciences*, 79 (8), 2554-2558.
- Hosseini-Zadeh, N.G., 2016a, Modelling lactation curve for fat to protein ratio in holstein cows. *Animal science papers and reports*, 34 (3), 233-246.
- Hosseini-Zadeh, N.G., 2016b, Modelling lactation curve for milk fat to protein ratio in iranian buffaloes (*bubalus bubalis*) using non-linear mixed models, *Journal of dairy research*, 83 (3), 334-340.

- Höglund, H., 2013, Fuzzy linear regression-based detection of earnings management, *Expert Syst. Appl.* 40 (15), 6166–6172.
- Hung, K.C. and Lin, K.P., 2013, Long-term business cycle forecasting through a potential intuitionistic fuzzy least-squares support vector regression approach, *Information sciences*, 224, 37-48.
- İçen, D., 2010, Bulanık doğrusal regresyon analizi, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 105s.
- İçen, D. and Cattaneo, M.E., 2016, Different distance measures for fuzzy linear regression with Monte Carlo methods, *Soft computing*, 1-11.
- İçen, D. and Demirhan, H., 2016, Error measures for fuzzy linear regression: Monte Carlo simulation approach, *Applied soft computing*, 46, 104-114.
- İçen, D. ve Günay, S., 2015, Türkiye'deki işsizlik oranının bulanık doğrusal regresyon analiziyle tahmini, *İstatistikçiler dergisi: İstatistik & Aktüerya*, 8, 10-26.
- İkiz, F., Püskülcü, H. ve Eren, Ş., 2006, *İstatistiğe giriş*, Barış Yayınları, Fakülteler Kitabevi, İzmir.
- Ishibuchi, H. and Nii, M., 1996a, Fuzzy regression analysis and non- symmetric fuzzy number coefficients and its neural network implementation, *Proc. IEEE Int. Conf. On fuzzy systems*, September 8–11, 1996, New Orleans, Pp. 318–324.
- Ishibuchi, H. and Nii, M., 1996b, Generating fuzzy if-then rules from trained neural networks: Linguistic analysis of neural networks, *In neural networks, international conference on IEEE*, vol (2), 1133-1138.
- Ishibuchi, H. and Nii, M., 2001, Fuzzy regression using asymmetric fuzzy coefficients and fuzzified neural networks, *Fuzzy Sets. Syst.*, 119, 273–290.
- Ishibuchi, H. and Tanaka, H., 1989, Formulation and analysis of linear programming problem with interval coefficients, *Journal of japan industrial management association*, 40 (5), 320-329.
- Ishibuchi, H. and Tanaka, H., 1990, Several formulations of interval regression analysis, *In: proceedings of sino-japan join meeting on fuzzy sets and systems*, Beijing, China, P. B2-2.
- Ishibuchi, H. and Tanaka, H., 1992, Fuzzy regression analysis using neural networks, *Fuzzy Sets. Syst.*, 50 (3), 257-266.
- Ishibuchi, H., Kwon, K. and Tanaka, H., 1995, A learning algorithm of fuzzy neural networks with triangular fuzzy weights. *Fuzzy Sets. Syst.*, 71 (3), 277-293.

- Ishibuchi, H., Tanaka, H. and Okada, H., 1993, An architecture of neural networks with interval weights and its application to fuzzy regression analysis, *Fuzzy Sets. Syst.*, 57 (1), 27-39.
- Ji, J.H., Liang, R.Q. and He, J.C., 2016, A prediction model for hot metal desulfurization rate based on fuzzy structured element, In international conference on oriental thinking and fuzzy logic, Springer International Publishing.
- Jiang, H., Deng, H. and He, Y., 2008, Determination of fuzzy logic membership function using extended ant colony optimization, *Fuzzy systems and knowledge discovery, FSKD '08. Fifth international conference on*, vol (1), 581-585.
- Kaewtapee, C., Khetchaturat, C. and Bunchasak, C., 2011, Comparison of growth models between artificial neural networks and nonlinear regression analysis in Cherry Valley ducks. *Journal of applied poultry research*, 20 (4), 421-428.
- Kandala, V.M., and Prajneshu., 2004, Fuzzy von bertalanffy growth model for determining age-length relationship, *Indian journal of fisheries*, 51 (1), 55-59.
- Karadavut, U., Tekşen Ü.M., Genç A., Tozluca, A., Palta, Ç., Çarkacı, D.A. ve Yılmaz, T., 2009, *Mısır bitkilerinde büyüme eğrisi parametrelerinin bulanık lineer olmayan regresyon yardımıyla tahmini*, 6. Zootekni Bilim Kongresi, 24-26 Haziran 2009, 3-9.
- Kayri, M., 2016, Predictive abilities of bayesian regularization and levenberg–marquardt algorithms in artificial neural networks: A comparative empirical study on social data, *Mathematical and computational applications*, 21 (2), 20.
- Khoshnevisan, B., Rafiee, S., Omid, M., Mousazadeh, H. and Rajaeifar, M.A., 2014, Application of artificial neural networks for prediction of output energy and GHG emissions in potato production in Iran, *Agricultural systems*, 123, 120-127.
- Kim, B. and Bishu, R.R., 1998, Evaluation of fuzzy linear regression models by comparing membership functions, *Fuzzy Sets. Syst.*, 100, 342–352.
- Kim, K.J., Mosskowitz, H. and Koksalan, M., 1996, Fuzzy versus statistical linear regression, *European journal of operational research*, 92, 417–434.
- Kınacı, A.C., 2006, *Görsel yazılım geliştirme ortamı ile beraber bir yapay sinir ağı kütüphanesi tasarımı ve gerçekleştirimi*, Yüksek Lisans Tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü.
- Kitsikoudis, V., Spiliotis, M. and Hrissanthou, V., 2016, Fuzzy regression analysis for sediment incipient motion under turbulent flow conditions, *Environmental processes*, 3 (3), 663-679.

- Klir, J.G. and Yuan, B., 1995, *Fuzzy sets and fuzzy logic: Theory and application*, Prentice Hall, New Jersey.
- Kohonen, T., 1982, Self-Organized formation of topologically correct feature maps, *Biological cybernetics*, 43, 5949.
- Kohonen, T., 1989, *Self-Organization and associative memory* (3rd Ed.), Springer-Verlag, Berlin.
- Kohonen, T., 1990, Improved versions of learning vector quantization, In *Neural Networks, IJCNN International Joint Conference on* (pp. 545-550). IEEE.
- Kramer, E., Stamer, E., Spilke, J., Thaller, G. and Krieter, J., 2009b, Analysis of water intake and dry matter intake using different lactation curve models, *J. Dairy Sci.*, 92, 4072- 4081.
- Kröse, B. and Van Der Smagt P., 1996, *An introduction to neural networks*, The University of Amsterdam.
- Kula, K.Ş., Dalkılıç, T.E. and Apaydın, A., 2010, Bağımlı değişkenin simetrik bulanık sayı olması durumunda parametre tahmini, *İstatistikçiler dergisi: İstatistik ve aktüerya*, 3 (2), 54-62.
- Kula, K.Ş., Tank, F. and Dalkılıç, T.E., 2012, A study on fuzzy robust regression and its application to insurance. *Mathematical and computational applications*, 17 (3), 223-234.
- Kumar, A., Srinivas, P. S., Mishra, A. K. and Chandrasekhran, H., 2014, Fuzzy regression interval models for forewarning onion thrips, *In computing for sustainable global development (indiacom), international conference on, IEEE*, 197-201.
- Lee, H.T. and Chen, S.H., 2001, Fuzzy regression model with fuzzy input and output data for manpower forecasting, *Fuzzy Sets. Syst.*, 119, 205–213.
- Lee, K.H., 2005, *First course on fuzzy theory and applications*, (Vol. 27), Springer Science & Business Media.
- Leksakul, K., Holimchayachotikul, P. and Sopadang, A., 2015, Forecast of off-season longan supply using fuzzy support vector regression and fuzzy artificial neural network, *Computers and electronics in agriculture*, 118, 259-269.
- Li, Q., Du, Q., Ba, W. and Shao, C., 2012, Multiple-input multiple-output soft sensors based on KPCA and MKLS-SVM for quality prediction in atmospheric distillation column, *International journal of innovative computing, information and control*, 8 (12), 8215-8230.

- Lin, J.W., 2012, Fuzzy regression decision systems for assessment of the potential vulnerability of bridge to earthquakes, *Natural hazards*, 64 (1), 211-221.
- Lin, K.P. and Pai, P.F., 2010, A Fuzzy support vector regression model for business cycle predictions, *Expert systems with applications*, 37 (7), 5430-5435.
- Lin, K.P., Pai, P.F., Lu, Y.M. and Chang, P.T., 2013, Revenue forecasting using a least-squares support vector regression model in a fuzzy environment, *Information sciences*, 220, 196-209.
- Liu, H., Mi, X.W. and Li, Y.F., 2018, Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network, *Energy conversion and management*, 156, 498-514.
- Liu, H.T., Wang, J., He, Y. and Ashfaq R.A.R., 2016, Extreme learning machine with fuzzy input and fuzzy output for fuzzy regression, *Neural Comput Appl.*, 28 (11), 3465-3476.
- Liu, X. and Chen, Y., 2013, A Systematic approach to optimizing h value for fuzzy linear regression with symmetric triangular fuzzy numbers, *Math. Prob. Eng.*, Article ID 210164.
- Liu, Y., Zhou, J. and Chen, Y., 2014, Using fuzzy non-linear regression to identify the degree of compensation among customer requirements in QFD, *Neurocomputing*, 142, 115-124.
- López, S., 2008, *Non-Linear functions in animal nutrition*, In: J. France. E. Kebreab, (ed.), Chapter 3, Cab International, Wallingford, UK.
- López, S., France. J., Gerrits, W.J.J., Dhanoa, M.S., Humphries, D.J. and Dijkstra, J., 2000, A generalized Michaelis–Menten equation for the analysis of growth, *Journal of animal science*, 78, 1816–1828.
- López, S., Prieto, M., Dijkstra, J., Dhanoa, M.S. and France, J., 2004, Statistical evaluation of mathematical models for microbial growth, *Int. J. Food Microbiol.*, 96, 289–300.
- Lu, C., Gao, S. and Zhou, Z., 2013, Maize disease recognition via fuzzy least square support vector machine. *Journal of information and computing science*, 8 (4), 316-320.
- Macciotta, N.P., Dimauro, C., Rasso, S.P., Steri, R. and Pulina, G., 2011, The mathematical description of lactation curves in dairy cattle, *Italian journal of animal science*, 10 (4), E51.

- Macciotta, N.P.P., Vicario, D., Pulina, G. and Cappio- Borlino, A., 2002, Test day and lactation yield predictions in Italian simmental cows by arma methods, *J. Dairy Sci.*, 85, 3107- 3114.
- Marek, J., Rajmon, R. and Haloun, T., 2015, Critical evaluation of seven lactation curve estimation models, In intelligent data analysis and applications, (Pp. 73-84), Springer, Cham.
- McCulloch, W.S. and Pitts, W., 1943, A logical calculus of the ideas immanent in nervous activity, *Bull. Math. Biophys.*, 5, 115–133.
- McMeekin, T.A., Olley, J.N., Ross, T. and Ratkowsky, D.A., 1993, *Predictive microbiology: Theory and application*, Wiley, New York.
- McMillan, I., Fitz-Earle, M. and Robson, D.S., 1970a, Quantitative genetics of fertility I. lifetime egg production of drosophila melanogaster—Theoretical. *Genetics*, 65 (2), 349.
- McMillan, I., Fitz-Earle, M. Butler, L. and Robson, D.S., 1970b, Quantitative genetics of fertility II. lifetime egg production of drosophila melanogaster—Experimental. *Genetics*, 65 (2), 355.
- McMillan, I.A.N., 1981, Compartmental model analysis of poultry egg production curves, *Poult. Sci.*, 60 (7), 1549-1551.
- McNally, D.H., 1971, Mathematical model for poultry egg production, *Biometrics*, 27, 735–738.
- Megri, F., Megri, A.C. and Djabri, R., 2016, An integrated fuzzy support vector regression and the particle swarm optimization algorithm to predict indoor thermal comfort, *Indoor and built environment*, 25 (8), 1248-1258.
- Mehrotra, K., Mohan C.K. and Ranka, S., 1997, *Elements of artificial neural networks*, The Mit Press, London.
- Mercer, J., 1909, Functions of positive and negative type, and their connection with the theory of integral equations. *Philosophical transactions of the royal society of London, Series A*, 209 (441-458), 415-446.
- Minsky, M.L. and Papert, S.A., 1969, *Perceptrons*, Cambridge, M A: Mit Press.
- Miyazaki A., Kwon K., Ishibuchi, H. and Tanaka, H., 1994, Fuzzy Regression analysis by fuzzy neural networks and its application, *Proc. of The 3rd IEEE International conference on fuzzy systems* (Orlando, Usa) pp.52-57.
- Montgomery, D.C., Peck, E.A. and Vining, G.G., 2012, *Introduction to linear regression analysis*, John Wiley & Sons.

- Moskowitz, H. and Kim, K., 1993, On assessing the h value in fuzzy linear regression, *Fuzzy Sets. Syst.*, 58, 303–327.
- Nabiyev, V.V., 2003, *Yapay zeka*, Seçkin Yayıncılık, Ankara.
- Narinc, D., Uckardes, F. and Aslan, E., 2014, Egg production curve analyses in poultry science, *World's poultry science journal*, 70 (4), 817-828.
- Narushin, V.G. and Takma, C., 2003, Sigmoid model for the evaluation of growth and production curves in laying hens, *Biosystems engineering*, 84 (3), 343-348.
- Nasrabadi, M.M., Nasrabadi, E. and Nasrabad, A.R., 2005, Fuzzy linear regression analysis: a multi-objective programming approach, *Applied mathematics and computation*, 163 (1), 245-251.
- Negnevitsky, M., 2005, *Artificial intelligence, a guide to intelligent systems*, Pearson Education, Harlow.
- Nelder, J.A., 1961, The fitting of a generalization of the logistic curve, *Biometrics*, 17 (1), 89–110.
- Neshat, N., 2015, An approach of artificial neural networks modeling based on fuzzy regression for forecasting purposes, *International journal of engineering*, 28 (11), 1651-1655.
- Nguyen H.T., 1978, A note on the extension principle for fuzzy sets, *J. Math. Anal. Appl.*, 64, 369-380.
- Oh, S. B., Kim, W., and Lee, J. K., 1990, An approach to causal modeling in fuzzy environment and its application, *Fuzzy Sets. Syst.*, 35 (1), 43-55.
- Özelkan, E.C. and Duckstein, L., 2000, Multi-Objective fuzzy regression: A general framework, *Computers and operations research*, 27 (7), 635-652.
- Öztemel, E., 2003, *Yapay sinir ağları*, Papatya Yayıncılık, İstanbul.
- Pandit, P.K., 2014, Fuzzy nonlinear regression using artificial neural networks, *Int. J. Adv. Appl. Math. and Mech.*, 2 (1), 53-63.
- Panik, M., 2009, *Regression modeling: Methods, theory, and computation with SAS*, Crc Press.
- Papajcsik, I.A. and Boderó, J., 1988, Modelling Lactation curves of Friesian cows in a sub-tropical climate, *Animal production*, 47 (2), 201–207.
- Parks, J.R., 1982, *A theory of feeding and growth of animals*, Springer-Verlag, Berlin,
- Patil, S.M. and Mudholkar, R.R., 2016, Fuzzy regression model for knee osteoarthritis disease diagnosis, *International research journal of engineering and technology (IRJET)*, 3 (2), 366-369.

- Pehlivan, N.Y. and Apaydin, A., 2016, Fuzzy radial basis function network for fuzzy regression with fuzzy input and fuzzy output, *Complex & Intelligent systems*, 2 (1), 61-73.
- Peleg, M., 1997, Modeling microbial populations with the original and modified versions of the continuous and discrete logistic equations, *Critical reviews in food science and nutrition*, 37 (5), 471–490.
- Peters, G., 1994, Fuzzy linear regression with fuzzy intervals, *Fuzzy Sets. Syst.*, 63 (1), 45–55.
- Pollott, G.E., 2000, A biological approach to lactation curve analysis for milk yield, *J. Dairy Sci.*, 83 (11), 2448–2458.
- Priddy, K.L. and Keller, P.E., 2005, *Artificial neural networks: An introduction* (Vol. 68), SPIE press,
- Qu, H.C. and Ding, X.B., 2012, Civil aeroengine fault diagnosis based on fuzzy least square support vector machine, In *applied mechanics and materials*, Trans. Tech. Publications, 130, 2047-2050.
- Rafique, S.F., Jianhua, Z., Rafique, R., Guo, J. and Jamil, I., 2018, Renewable generation (wind/solar) and load modeling through modified fuzzy prediction interval. *International journal of photoenergy*, Article ID 4178286.
- Ratkowski, D.A., 1983, *Nonlinear Regression Modeling*. Marcel Dekker, New York.
- Rattanalertnusorn, A., Thongteeraparp, A. and Bodhisuwan, W., 2014, Parameter estimation of fuzzy linear regression model: The extension of Chen and Hsueh method, *Journal of applied sciences*, 14 (7), 631-640.
- Ricker, W.E., 1979, *Growth rates and models*. In: Hoar, W.S. Randall, D. J. Brett, J. R. (Eds) *Fish Physiology*, Vol. 8, Academic Press, New York.
- Ritz, C. and Streibig, J.C., 2008, *Nonlinear regression with R*. Springer Science & Business Media.
- Roldán, C., Roldán, A. and Martínez-Moreno, J., 2012, A fuzzy regression model based on distances and random variables with crisp input and fuzzy output data: A case study in biomass production, *Soft computing*, 16 (5), 785-795.
- Rook, A.J., France. J. and Dhanoa, M.S., 1993, On the mathematical description of lactation curves, *J. Agric. Sci.*, 121 (1), 97-102.
- Rosenblatt, F., 1962, *Principles of neurodynamics*, Washington, Dc: Spartan.
- Ross, T.J., 2004, *Fuzzy logic with engineering applications*, John Wiley & Sons Ltd. Chichester.

- Roush, W.B., Dozier III W.A. and Branton, S.L., 2006, Comparison of gompertz and neural networks models of broiler growth, *Poult. Sci.*, 85 (4), 794–797.
- Sainz, R.D. and Baldwin, R.L., 2003, *Modeling and growth*. In: Scanes, C.G. (Ed.) *Biology of growth of domestic animals*, Iowa State Press/Blackwell, Ames, Iowa.
- Sakawa, M. and Yano, H., 1990, Multiobjective fuzzy linear regression analysis and its application, *Electronics and communications in Japan*, 73 (12), 1-10.
- Sakawa, M. and Yano, H., 1992, Multiobjective fuzzy linear regression analysis for fuzzy input-output data, *Fuzzy Sets. Syst.*, 47 (2), 173–181.
- Sakawa, M., 2013, *Fuzzy sets and interactive multiobjective optimization*, Springer Science & Business Media.
- Sarkar, M.R., Rabbani, M.G., Khan, A.R. and Hossain, M.M., 2015, Electricity demand forecasting of rajshahi city in bangladesh using fuzzy linear regression model, *In electrical engineering and information communication technology (ICEEICT), International conference on (Pp. 1-3), IEEE*.
- Savegnago, R.P., Nunes, B.N., Caetano, S.L., Ferraudo, A.S., Schmidt, G.S., Ledur, M.C. and Munari, D.P., 2011, Comparison of logistic and neural network models to fit to the egg production curve of white leghorn hens, *Poult. Sci.*, 90 (3), 705-711.
- Savegnago, R.P., Cruz, V.A.R., Ramos, S.B., Caetano, S.L., Schmidt, G.S., Ledur, M.C., El Faro, L., and Munari, D.P., 2012, Egg production curve fitting using nonlinear models for selected and nonselected lines of White Leghorn hens. *Poultry science*, 91 (11), 2977-2987.
- Savic, D.A. and Pedryzc, W., 1991, Evaluation of fuzzy linear regression models, *Fuzzy Sets. Syst.*, 39 (1), 51–63.
- Seber, G.A.F. and Wild, C.J., 1989, *Nonlinear regression*, John Wiley&Sons, Canada.
- Seber, G.A.F. and Wild, C.J., 2003, *Nonlinear regression*, John Wiley and Sons, Hoboken, NJ.
- Semsarian, S., Pasha Eskandari Nasab, M., Zarehdaran, S. and Dehghani, A.A., 2013, Prediction of the weight and number of eggs in mazandaran native fowl using artificial neural network, *International journal of advanced biological and biomedical research*, 1 (5), 532-537.
- Seng, K.Y., Nestorov, I. and Vicini, P., 2009, Fuzzy least squares for identification of individual pharmacokinetic parameters. *IEEE transactions on biomedical engineering*, 56 (12), 2796-2805.

- Shakouri H. and Nadimi, R., 2013, Outlier detection in fuzzy linear regression with crisp input–output by linguistic variable view, *Applied soft computing*, 13 (1), 734-742.
- Siddique, N. and Adeli, H., 2004, *Computational intelligence: Synergies of fuzzy logic, Neural networks and evolutionary computing*, John Wiley & Sons, 2013.
- Simondon, K.B., Simondon, F., Delpeuch, F. and Cornu, A., 1992, Comparative study of five growth models applied to weight data from congolese infants between birth and 13 months of age, *American journal of human biology*, 4, 327–335.
- Smola, A.J., and Schölkopf, B., 2004, A tutorial on support vector regression, *Statistics and computing*, 14 (3), 199-222.
- Song, R. and Sun, Y., 2015, Application of fuzzy linear regression model in predicting the freight volume of city, *Journal of information & computational science*, 12 (1), 191-200.
- Strathe, A.B., Danfær, A., Chwalibog, A., Sørensen, H. and Kebreab, E., 2010, A multivariate nonlinear mixed effects method for analyzing energy partitioning in growing pigs, *Journal of animal science*, 88 (7), 2361-2372.
- Su, Z.G., Wang, P.H. and Song, Z.L., 2013, Kernel based nonlinear fuzzy regression model, *Engineering applications of artificial intelligence*, 26 (2), 724-738.
- Suharjito, M. and Marimin, M., 2015, DSS for agricultural products supply chain risk balancing using stakeholder dialogues and fuzzy nonlinear regression, *International Journal of hybrid information technology*, 8 (1), 11-26.
- Sumathi, S. and Paneerselvam, S., 2010, *Computational intelligence paradigms: Theory & applications using matlab*, Crc Press.
- Suykens, J.A. and Vandewalle, J., 2000, Recurrent least squares support vector machines. *IEEE transactions on circuits and systems I: Fundamental theory and applications*, 47 (7), 1109-1114.
- Suykens, J.A., 2001, Support vector machines: A nonlinear modelling and control perspective. *European journal of control*, 7 (2-3), 311-327.
- Suykens, J.A., and Vandewalle, J., 1999, Least squares support vector machine classifiers. *Neural processing letters*, 9 (3), 293-300.
- Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. and Vandewalle, J., 2002, *Least squares support vector machines*, World Scientific, Singapore.
- Suzuki, S., Furukawa, K., Inoue, Y., Nakagawa, K., 1990, A proposal of rock mass classification for tunnels by the fuzzy regression model. *Doboku Gakkai Ronbunshu*, 418, 181-190.

- Şanlı, K., 2005, *Bulanik robust regresyon çözümlemesi*, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü.
- Şen, Z., 2004, *Mühendislikte bulanik (fuzzy) mantık ile modelleme prensipleri*, Su Vakfı.
- Tabachnick, B.G. and Fidell, L.S., 2015, Çok değişkenli istatistiklerin kullanımı, Çev. Edt. M. Baloğlu, Ankara: Nobel Yayın Dağıtım.
- Tanaka, H. and Lee, H., 1997, Fuzzy linear regression combining central tendency and possibilistic properties, *Proceedings of Fuzz-IEEE* (Pp. 63–68), 63–68.
- Tanaka, H. and Watada, J., 1988, Possibilistic linear systems and their applications to the linear regression model, *Fuzzy Sets. Syst.*, 27, 275–289.
- Tanaka, H., 1987, Fuzzy data analysis by possibilistic linear regression models, *Fuzzy Sets. Syst.*, 24, 363–375.
- Tanaka, H., Hayashi, I. and Watada, J., 1989, Possibilistic linear regression analysis for fuzzy data, *European journal of operational research*, 40, 389–396.
- Tanaka, H., Uejima, S. and Asia, K., 1982, *Linear regression analysis with fuzzy model*, *IEEE transactions on system, man and cybernetics*, 12, 903–907.
- Tekerli, M., Akinci, Z., Dogan, I. and Akcan A., 2000, Factors affecting the shape of lactation curves of Holstein cows from the balikesir province of Turkey, *J. Dairy Sci.*, 83, 1381–1386.
- Tekşen, Ü.M. and Evren, A., 2012, Artificial neural network and entropy approach in fuzzy nonlinear regression. *Journal of Selcuk University Natural and Applied Science*, 1 (1), 14-29.
- Tekşen, Ü.M. and Genc, A., 2011, LS-SVM method for fuzzy nonlinear regression, *Selcuk Journal of applied mathematics*, 53-60.
- Tekşen, Ü.M., 2008, *Lineer Olmayan Bulanık Regresyonda Tahmin*, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Torres-Valencia, C.A., Álvarez, M.A. and Orozco-Gutiérrez, Á.A., 2014, Multiple-Output support vector machine regression with feature selection for arousal/valence space emotion assessment, *In engineering in medicine and biology society (EMBC), 36th annual international conference of the IEEE* (pp. 970-973).
- Trundle, P., Neagu, D., Craciun, M. and Chaudhry, Q., 2007, Development of multi-output neural networks for data integration—A case study, *Innovations in hybrid intelligent systems*, 80-87.
- Tseng, F.M., 2008, Quadratic interval innovation diffusion models for new product sales forecasting, *Journal of the operational research society*, 59 (8), 1120-1127.

- Türkşen, I.B., 2015, *Derceli (Bulanık) sistem modelleri*, Abaküs Yayın Dağıtım Hizmetleri, İstanbul.
- Turner, M.E., Bradley, E., Kirk, K. and Pruitt, K., 1976, A theory of growth, *Mathematical biosciences*, 29, 367–373.
- Tzimopoulos, C., Papadopoulos, K. and Papadopoulos, B.K., 2016, *models of fuzzy linear regression: An application in engineering*, In mathematical analysis, approximation theory and their applications, Springer International Publishing.
- Vapnik, V.N., 1995, *The nature of statistical learning theory*, New York.
- Vapnik, V.N., 1998, *Statistical learning theory*, Wiley, New York.
- Vojvoda, A. and Gold, H., 2002, Neural Networks in modelling maintenance unit load status, *Promet-Traffic & Transportation*, 14 (2), 85-91.
- Wang H. and Tsaur R.C., 2000a, Insight of a fuzzy regression model, *Fuzzy Sets. Syst.*, 112 (3), 355–369.
- Wang, H.F. and Tsaur, R.C., 2000b, Resolution of fuzzy regression model, *European journal of operational research*, 126, 637–650.
- Wang, L., 1997, *A course in fuzzy systems and control*, Prentice Hall, New Jersey.
- Wellock, I.J. Emmans, G.C. and Kyriazakis, I., 2004, Describing and predicting potential growth in the pig, *Animal science*, 78, 379–388.
- Widrow, B., 1962, *Generalization and information storage in networks of adaline neurons*, In self-organizing systems, Eds. M. Yovitz, G. Jacobi, and G. Goldstein, Washington, Dc: Spartan.
- Wieszczy, P. and Grzegorzewski, P., 2016, *Support vector machines in fuzzy regression*, In challenging problems and solutions in intelligent systems, Springer International Publishing.
- Wilmink, J.B.M., 1987, Adjustment of test-day milk, fat and protein yield for age, season and stage of lactation, *Livest. Prod. Sci.*, 16, 335-348.
- Wood, P.D.P., 1967, Algebraic model of the lactation curve in cattle, *Nature*, 216, 164-165.
- Xie, Y., 2010, Cost controller for construction projects based on fuzzy least squares support vector machines, *Intelligent computation technology and automation (ICICTA), international conference on*, 11-12 May 2010.
- Xu, R. and Li, C., 2001, *Multidimensional least-squares fitting with a fuzzy model*, *Fuzzy Sets. Syst.*, 119, 215–223.

- Xu, Z. and Khoshgoftaar, T.M., 2001, Software quality prediction for high-assurance network telecommunications systems, *The Computer. Journal.*, 44 (6), 557-568.
- Xu, Z. Khoshgoftaar, T.M. and Allen, E.B., 2000, Prediction of software faults using fuzzy nonlinear regression modeling, *Fifth IEEE international symposium on high assurance systems engineering*, 15-17 Kasim 2000, Albuquerque, New Mexico, 281-290
- Yabuuchi Y., Kawaura T. and Watada J., 2016, Analysis of the relation between health statistics and eating habits in Japanese prefectures using fuzzy robust regression model, *Computers in biology and medicine*, 72, 256-262.
- Yager, R., 1986, *A characterization of the extension principle*, *Fuzzy Sets. Syst.*, 18 (3), 205–217.
- Yang, M.S. and Ko, C.H., 1997, On cluster-wise fuzzy regression analysis, *IEEE transaction on systems, man and cybernetics part B: Cybernetics*, 27 (1), 1-13.
- Yang, M.S. Lin T.S., 2002, Fuzzy Least-Squares linear regression analysis for fuzzy input-output data, *Fuzzy Sets. Syst.*, 126, 389–399.
- Yang, W., Li, M., Zheng, L. and Sun, H., 2014, Evaluation model of winter wheat yield based on soil properties. In *international conference on computer and computing technologies in agriculture*, 638-645, Springer, Cham.
- Yao, C.C. and Yu, P.T., 2006, Fuzzy regression based on asymmetric support vector machines. *Applied Mathematics and Computation*, 182 (1), 175-193.
- Yapıcı Pehlivan, N. and Apaydın A., 2005, Artificial neural networks approach to fuzzy linear programming, *Selçuk J. Appl. Math.*, 6 (2), 9-26.
- Yapıcı Pehlivan, N., 2005, *Parametrik olmayan regresyonda bulanık tahmin ediciler*, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Yongqi C., 2012, Least squares support vector fuzzy regression, *Energy Procedia*, 17, 711 – 716.
- Yu, R., Leung, P. and Bienfang, P., 2006, Predicting shrimp growth: Artificial neural network versus nonlinear regression models, *Aquacultural engineering*, 34 (1), 26-32.
- Zadeh, L., 1975, The Concept of a linguistic variable and its application to approximate reasoning I, *Information sciences*, 8, 199–249
- Zadeh, L.A., 1965, Fuzzy sets, *Information and control*, 8 (3), 338-353.
- Zeide, B., 1993, Analysis of growth equations, *Forest science*, 39, 594–616.

- Zhang, D., Deng L.F., Cai K.Y. and So A., 2005, Fuzzy nonlinear regression with fuzzified radial basis function network, *IEEE, Transactions on fuzzy systems*, 13 (6), 742-760.
- Zhu, B. and Wei, Y., 2013, Carbon price forecasting with a novel hybrid arima and least squares support vector machines methodology, *Omega*, 41 (3), 517-524.
- Zimmermann, H. J., 2001, *Fuzzy set theory and its applications*, Kluwer Academic Press, Dordrecht.
- Zimmermann, H.J., 1991, *Fuzzy set theory and its application*, Kluwer Academic Press, Dordrecht.
- Zolfaghari Z.S., Mohebbi M. and Najariyan M., 2014, Application of fuzzy linear regression method for sensory evaluation of fried donut, *Applied soft computing*, 22, 417–423.
- Zwietering, M.H., Jongenburger, I., Rombouts, F.M. and Van't Riet, K., 1990, Modeling of the bacterial growth curve, *Applied and environmental microbiology*, 56, 1875–1881.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Aslı Akıllı
Doğum Yeri	İzmir
Doğum Tarihi	29.01.1984
Uyruğu	<input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer:
Telefon	03862804841
E-Posta Adresi	asliakilli@ahievran.edu.tr

Eğitim Bilgileri	
Lisans	
Üniversite	Celal Bayar Üniversitesi
Fakülte	İktisadi ve İdari Bilimler Fakültesi
Bölümü	İktisat Bölümü
Mezuniyet Yılı	2008

Yüksek Lisans	
Üniversite	Ege Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Zootekni Anabilim Dalı
Programı	Biyometri ve Genetik Bilim Dalı
Mezuniyet Tarihi	2012

Doktora	
Üniversite	Ahi Evran Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Zootekni Anabilim Dalı
Programı	Biyometri ve Genetik Bilim Dalı
Mezuniyet Tarihi	03.01.2019

Makale ve Bildiriler	
Uluslararası Hakemli Dergilerde Yayımlanan Makaleler:	
Görgülü Özkan, Akıllı Aslı (2018). Egg Production Curve Fitting Using Least Square Support Vector Machines And Nonlinear Regression Analysis. European Poultry Science, 80, 1-14., Doi: 10.1399/Eps.2018.235.	
Görgülü Özkan, Akıllı Aslı (2018). Estimation Of 305-Days Milk Yield Using Fuzzy Linear Regression In Jersey Dairy Cattle. The Journal Of Animal And Plant Sciences, 28(3), 1-8.	
Görgülü Özkan, Akıllı Aslı (2017). The Determination of The Levels of Burnout Syndrome Organizational Commitment and Job Satisfaction of The Health Workers. Nigerian Journal of Clinical Practice, 20(1), 48-56., Doi: 10.4103/1119-3077.180051.	

- Akkol Suna, Akıllı Aslı, Cemal İbrahim (2017). Comparison of Artificial Neural Network And Multiple Linear Regression For Prediction of Live Weight in Hair Goats. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 27(1), 21-29.
- Atıl Hülya, Akıllı Aslı (2016). Comparison of Artificial Neural Network and K Means for Clustering Dairy Cattle. *International Journal of Sustainable Agricultural Management And Informatics*, 2(1), 40-52., Doi: 10.1504/Ijsam.2016.077266.
- Akıllı Aslı, Atıl Hülya, Takma Çiğdem, Ayyılmaz Tarık (2016). Fuzzy Logic Based Decision Support System For Dairy Cattle. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 22(1), 13-19., Doi: 10.9775/Kvfd.2015.13516 (Yayın No: 1773447)
- Akıllı Aslı, Atıl Hülya, Kesenkaş Harun (2014). Çiğ Süt Kalite Değerlendirmesinde Bulanık Mantık Yaklaşımı. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*, 20(2), 223-229., Doi: 10.9775/Kvfd.2013.9894 (Yayın
- Karadavut Ufuk, Akıllı Aslı (2012). Genotype Environment Interaction And Phenotypic Stability Analysis For Yield Of Corn Cultivar. *Greener Journal Of Agricultural Sciences*, 2(5), 220-223.
- Uluslararası Bilimsel Toplantılarda Sunulan Ve Bildiri Kitaplarında (Proceedings) Basılan Bildiriler***
- Akıllı Aslı, Coşkun Füsün (2018). Goat Milk Quality Assessment Based on Artificial Neural Network And Cluster Analysis. 10th International Animal Science Conference.
- Akıllı Aslı, Görgülü Özkan (2018). Comparative Assessments of Nonlinear Fuzzy Regression Methods for Milk Prediction. 10th International Animal Science Conference.
- Akıllı Aslı, Görgülü Özkan, Gül Sabri, Keskin Mahmut (2018). Evaluation of Fuzzy Linear Regression Models- Based on Mathematical Programming With Application To Animal Science. 11. International Statistics Days Conference (Isdc).
- Akıllı Aslı, Görgülü Özkan (2018). Comparison of Neural Networks And Multivariate Nonlinear Regression: Case Study For Animal Science. 4th International Researchers, Statisticians and Young Statisticians Congress.
- Görgülü Özkan, Akıllı Aslı (2018). Use of Artificial Intelligence Methods In 305-Day Milk Yield Estimation. 4th International Researchers, Statisticians And Young Statisticians Congress.
- Akıllı Aslı, Görgülü Özkan (2017). Prediction of Milk Yield Using Fuzzy Nonlinear Regression With Neural Networks. The 5th International Fuzzy Systems Symposium (Fuzzyss'17).
- Görgülü Özkan, Akıllı Aslı (2017). Fuzzy Regression Analysis Using Back Propagation Neural Network For Prediction Of Sheep Live Weight. 3rd International Researchers, Statisticians and Young Statisticians Congress (Irsysc-2017).
- Görgülü Özkan, Akıllı Aslı (2017). Comparison of Nonlinear Regression Models And Least Square Support Vector Machines for Egg Production Curve Fitting. 3rd International Researchers, Statisticians And Young Statisticians Congress (Irsysc-2017)24-26 May 2017
- Akkol Suna, Cemal İbrahim, Varol Mustafa, Akıllı Aslı (2016). Prediction of Live Weight From Body Measurement Using The Elastic Net In Adult Hair Goat. The International Conference On Information Complexity And Statistical

- Modeling In High Dimensions With Applications (Ic-Smhd-2016).
- Atıl Hülya, Akıllı Aslı (2015). Investigation of Dairy Cattle Traits By Using Artificial Neuralnetworks And Cluster Analysis. 7th International Conference On Information And Communication Technologies In Agriculture, Food And Environment (Haicta 2015), 681-690.
- Görgülü Özkan, Akıllı Aslı (2015). Use of Fuzzy Logic Based Decision Support Systems In Medicine. 36th Annual Conference Of The International Society For Clinical Biostatistics (Iscb 2015), 140.
- Görgülü Özkan, Akıllı Aslı (2015). Power Analyse Review of Research Articles In Journals That Publishing At Life Science Field. 8th Conference of The Eastern Mediterranean Region of The International Biometric Society (Emr-Ibs)., 134.
- Akkol Suna, Akıllı Aslı, Cemal İbrahim (2015). Comparison of Artificial Neural Network And Multiple Linear Regression For Prediction of Live Weight In Hair Goat. 8th Conference Of The Eastern Mediterranean Region of The International Biometric Society (Emr-Ibs)., 142.
- Akıllı Aslı, Atıl Hülya (2015). Effect Of Normalization Techniques On Artificial Neural Network Performance For 305 Day Milk Yield Prediction. 8th Conference Of The Eastern Mediterranean Region Of The International Biometric Society (Emr-Ibs)., 133
- Karadavut Ufuk, Akıllı Aslı, Genç Serdar, Taşkın Atilla (2014). Artificial Neural Networks And Non Linear Model Comparison at the Definition on The Growth Of Japanese Quails. 9. Uluslararası İstatistik Günleri Sempozyumu, 115.
- Akıllı Aslı, Atıl Hülya (2013). Classification Of Milk Yield Characteristics With Cluster Analysis. 6. International Balkan Animal Conference Balnimalcon, 161.
- Karadavut Ufuk, Akıllı Aslı, Taşkın Atilla, Şahin Ahmet (2012). Mor Karaman Koyunlarında Üretici Tercihlerinin Kısıtlı Değişken Yaklaşımı İle Modellenmesi. Uluslararası Türk Ve Akraba Topluluklar Zootečni Kongresi, 129.
- Atıl Hülya, Akıllı Aslı (2012). Çiftlik Hayvanlarında Hastalık Teşhisinde Yapay Zekanın Rolü. Uluslararası Türk Ve Akraba Topluluklar Zootečni Kongresi, 128.
- Akıllı Aslı, Karadavut Ufuk, Taşkın Atilla, Şahin Ahmet (2012). Kırşehir İlinde Küçükbaş Hayvan Üretiminin Bulanık Mantık Yaklaşımı İle Değerlendirilmesi. Uluslararası Türk Ve Akraba Topluluklar Zootečni Kongresi, 127.
- Akıllı Aslı, Atıl Hülya, Kesenkaş Harun (2012). Çiğ Süt Kalite Değerlendirmesinde Bulanık Mantık Yaklaşımı. Uluslararası Türk Ve Akraba Topluluklar Zootečni Kongresi, 60.
- Ulusal Hakemli Dergilerde Yayımlanan Makaleler***
- Karadavut Ufuk, Şahin Ahmet, Taşkın Atilla, Akıllı Aslı (2014). Japon Bildircinlerinde Coturnix Coturnix Japonica Büyümenin Tek Ve Çok Aşamalı Analizlerinin Seleksiyon Kriteri Olarak Kullanılabilme Olanaklarının Araştırılması. Türk Tarım Ve Doğa Bilimleri Dergisi, 1(4), 539-546.
- Akıllı Aslı, Atıl Hülya (2014). Süt Sığırcılığında Yapay Zeka Teknolojisi: Bulanık Mantık Ve Yapay Sinir Ağları. Hayvansal Üretim, 55(1), 39-45.
- Karadavut Ufuk, Akıllı Aslı (2012). Bitkisel Üretimde Bulanık Mantık Uygulamaları.

Türk Bilimsel Derlemeler Dergisi, 5(2), 77-82.

Ulusal Bilimsel Toplantılarda Sunulan Ve Bildiri Kitaplarında Basılan Bildiriler

Görgülü Özkan, Akıllı Aslı (2015). Bulanık Regresyon Analizinin Zootečni Alanında Uygulanabilirliđi. 9. Ulusal Zootečni Kongresi, 593.

Görgülü Özkan, Akıllı Aslı (2015). Ulusal Zootečni Bilim Kongrelerinde Sunulan Bildirilerin Güç Analizi İle İncelenmesi. 9. Ulusal Zootečni Kongresi, 592.

Akıllı Aslı, Atıl Hülya (2013). Hayvancılıkta Sınıflandırma Problemlerinin Çözümünde Yapay Zeka Yaklaşımı. 8. Ulusal Zootečni Kongresi.

Karadavut Ufuk, Taşkın Atilla, Akıllı Aslı, Şahin Ahmet (2013). Japon Bildircinlarının Ontogenik Ve Dönemsel Büyümlerinin Belirlenmesi. 8. Ulusal Zootečni Kongresi, 261.

Atıl Hülya, Akıllı Aslı, Takma Çiğdem, Ayyılmaz Tarık (2011). Süt Sığırlarında Bulanık Mantık Tabanlı Karar Destek Sistemi. 7. Ulusal Zootečni Bilim Kongresi, 234-238.

Teknik Not, Vaka Takdimi, Araştırma Notu vb.

Görgülü Özkan, Akıllı Aslı (2016). Use Of Fuzzy Logic Based Decision Support Systems In Medicine. Studies On Ethno-Medicine, 10(4), 393-403.