

**T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ PROGRAMI
DOKTORA TEZİ**

**YAPAY SİNİR AĞLARIYLA ZAMAN SERİSİ
TAHMİNLEMESİNDE YENİ BİR MODEL SEÇİM
STRATEJİSİ**

Serkan ARAS

**Danışman
Prof. Dr. İpek DEVECİ KOCAKOÇ**

İZMİR - 2013

TEZ ONAY SAYFASI

YEMİN METNİ

Doktora Tezi olarak sunduğum **“Yapay Sinir Ağlarıyla Zaman Serisi Tahminlemesinde Yeni Bir Model Seçim Stratejisi”** adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

...../...../2013

Serkan ARAS

ÖZET

Doktora Tezi

Yapay Sinir Ağlarıyla Zaman Serisi Tahminlemesinde Yeni Bir Model Seçim

Stratejisi

Serkan ARAS

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü

Ekonometri Anabilim Dalı

Ekonometri Programı

Yapay Sinir Ağları zaman serisi uygulamalarında gittikçe önem kazanan bir yöntem olmasına rağmen, hala birçok metodolojik eksiklikleri içerisinde barındırmaktadır. Bu eksikliklerden bir tanesi, gerçekleştirilen bir sinir ağı deneyi sonucunda hangi sinir ağı modelinin gelecekte kullanılmak üzere seçileceğidir. Başka bir deyişle, sinir ağının girdi ve gizli hücre sayısı ne olmalı ve girdi-gizli hücre sayısı belirlenmişken farklı başlangıç ağırlık değerlerinin sebep olduğu denemeler arasından hangisinin seçileceği sorularına cevap aranmalıdır. Genel uygulama, veri setinin eğitim, doğrulama ve test seti olarak üçe bölünüp doğrulama setinde en küçük hata ölçüsünü veren sinir ağı modelinin seçimi şeklindedir. Ancak bu durumda, doğrulama setine aşırı uyum sağlamış bir sinir ağı modelinin seçimi olasıdır. Doğrulama setine aşırı uyum sağlamış bir ağın, genelleme yeteneğini gösteren test seti üzerindeki performansı düşük olabilecektir.

Bu tez kapsamında, zaman serileriyle sinir ağı tahmini yaparken model seçimine yönelik bir seçim stratejisi önerilmiştir (GGD ayrışımı). Önerilen seçim stratejisi, öncelikle girdi ve gizli hücre sayılarını belirlemekte ve ardından farklı denemeler arasından hem doğrulama hem de eğitim seti performanslarına eşanlı bakarak bir sinir ağı modeli seçmektedir. Önerilen seçim stratejisinin simülasyon ve gerçek veri setleri üzerinde klasik seçim yöntemiyle karşılaştırılması sonucunda, sinir ağı performansını istatistiksel olarak geliştirdiği görülmüştür. Simülasyon deneyi önerilen seçim stratejisinin

altta yatan veri üretim sürecine daha iyi yakınsadığını göstermiştir. ARIMA yöntemiyle olan rekabette, sinir ağında yapılabilecek iyileştirmelerle üstünlüğün sinir ağına daha çok geçebileceği yönünde bulgulara rastlanmıştır. Önerilen seçim stratejisi genel anlamda doğrulama hacmine karşı daha çok direnç sergilemiştir. Ayrıca deneme sayısının klasik seçim yöntemi için önemli bir faktör olmadığı ancak önerilen seçim stratejisi performansı üzerinde etkili olabileceği tespit edilmiştir.

Anahtar Kelimeler: Sinir Ağları, ARIMA, Zaman Serisi, Tahminleme, Model Seçimi.

ABSTRACT
Doctoral Thesis
Doctor of Philosophy (PhD)
A New Model Selection Strategy in Time Series Forecasting With Artificial
Neural Networks
Serkan ARAS

Dokuz Eylül University
Graduate School of Social Science
Department of Econometrics
Econometrics Program

Although artificial neural networks have recently gained importance in time series applications, methodological shortcomings still continue to exist. One of such shortcomings is the selection of the proper neural networks model for future use after finishing an experiment of neural networks. In other words, the number of inputs and hidden neurons must be determined, and when they are determined, the question of which trial among many trials caused by different initial weights will be selected must be answered. The general application is to divide the dataset into training, validation and test sets and selecting the neural network model that gives the smallest error value in the validation set. However, an overfitting neural networks model is likely to be selected in this case. A neural network model overfitting to validation set is likely to underperform in the test set, which shows the generalization ability of the model.

A model selection strategy (GGD separation) for time series forecasting with neural networks is proposed within the scope of this dissertation. The proposed strategy initially determines the number of inputs and hidden neurons, and then selects a neural networks model from various trials by simultaneously considering performance of training and validation sets. A comparison of our proposed selection strategy with classic selection methods using simulation and real datasets shows that our selection model statistically

improves neural networks performance. Simulation experiments indicate that the proposed selection strategy better converges the underlying data generalization process. Findings show that improvements in neural networks may give it a winning edge in the competition with ARIMA method. The proposed selection strategy, in general, exhibits more resistance to the validation size. Moreover, findings show that the number of trials is not a significant factor for the classic selection method; however it may influence the performance of the proposed selection strategy.

Keywords: Neural Networks, ARIMA, Time Series, Forecasting, Model Selection.

YAPAY SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİNDE YENİ BİR MODEL SEÇİM STRATEJİSİ

İÇİNDEKİLER

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
KISALTMALAR	xi
TABLolar LİSTESİ	xii
ŞEKİLLER LİSTESİ	xviii
EKLER LİSTESİ	xx
GİRİŞ	1

BİRİNCİ BÖLÜM

YAPAY SİNİR AĞLARINA GENEL BAKIŞ

1.1. YAPAY SİNİR AĞLARI	5
1.2. GERÇEK VE YAPAY SİNİR AĞI BENZERLİKLERİ	7
1.3. SİNİR AĞLARININ GENEL YAPISI	11
1.4. SİNİR AĞLARININ AVANTAJLARI VE DEZAVANTAJLARI	13
1.5. SİNİR AĞI TAHMİN MODELİ TASARIMINDAKİ ADIMLAR	15
1.5.1. Değişken Seçimi	15
1.5.2. Veri Toplanması	15
1.5.3. Veri Ön İşlemesi	16
1.5.4. Eğitim, Doğrulama ve Test Setleri	16
1.5.5. Sinir Ağının Temel Unsurları	17
1.5.6. Değerlendirme Kriteri	19
1.5.7. Sinir Ağı Eğitimi	19

1.5.8. Uygulama	21
1.6. YAPAY SİNİR AĞLARININ KULLANIM ALANLARI	21
1.7. SOSYAL BİLİMLER İÇERSİNDE SİNİR AĞLARI KULLANIMININ YAYGINLAŞMASINDA KARŞILAŞILAN ENGELLER	24
1.8. GERİ YAYILIM ALGORİTMASI	26

İKİNCİ BÖLÜM

SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİ

2.1. ZAMAN SERİSİ TAHMİNLEMESİ	28
2.2. ZAMAN SERİSİ TAHMİN METOTLARI	30
2.2.1. Doğrusal Metotlar	35
2.2.2. Doğrusal Olmayan Metotlar	38
2.3. SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİNDE YAPILAN ÇEŞİTLİ ÇALIŞMALAR	43
2.4. SİNİR AĞI ÇEŞİTLERİ VE KULLANILAN ALGORİTMALAR	50
2.5. SİNİR AĞLARININ KLASİK YÖNTEMLERLE BENZERLİKLERİ	52
2.6. DİNAMİK AĞLAR	55
2.6.1. Zaman Gecikmeli Sinir Ağları	55
2.7. MATEMATİKSEL AÇILIMIYLA GERİ YAYILIM ALGORİTMASI	60

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARINDA MODEL SEÇME SORUNU VE BİR ÖNERİ

3.1. PROBLEM TANIMI VE AMAÇ	67
3.2. SİNİR AĞLARINDA EN UYGUN MODELİN SEÇİMİNE YÖNELİK YAPILAN BAZI ÇALIŞMALAR	70
3.3. SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİNDE GİRDİ VE GİZLİ HÜCRELERİN ROLÜ VE ETKİSİ	75
3.3.1. Gizli Hücre	76
3.3.2. Girdi Hücresi	80
3.4. AŞIRI UYUM SAĞLAMA PROBLEMİ	82

3.5. ÖNERİLEN YAKLAŞIM: GİRDİ-GİZLİ-DENEME AYRIŞIMI	84
3.5.1. Önerilen Yaklaşımın Formülasyonu	88
3.5.2. TOPSIS Yöntemi	89
3.5.3. Deney Tasarımı ve Veri Setleri	93
3.5.4. Deneylere Ait Sonuçlar	101
3.5.4.1. Simülasyon Verilerine İlişkin Sonuçlar	103
3.5.4.2. Gerçek Verilere İlişkin Sonuçlar	121
3.5.4.3. ARIMA Yöntemiyle Karşılaştırma	129
3.5.4.4. Doğrulama Hacmi Etkisi	134
3.5.4.5. Deneme Sayısının Etkisi	146
3.5.5. Önerilen Yaklaşımın Avantajları	149
 SONUÇ	 151
KAYNAKÇA	159
EKLER	

KISALTMALAR

AIC	Akaike Bilgi Kriteri
AR	Otoregresif Model
ARCH	Autoregressive Conditional Heteroskedastic
ARIMA	Autoregressive Integrated Moving Average
BIC	Bayesian Bilgi Kriteri
DA	Yön Doğruluğu
ELECTRE	ELimination and Choice Expressing REality
FFN	Feed Forward Neural Network
G	Girdi ayrışımı
GAR	Doğrusal Olmayan Otoregresif Model
GARCH	Generalized AutoRegressive Conditional Heteroskedasticity
G-G	Girdi-Gizli ayrışımı
GGD	Girdi-Gizli-Deneme
GUDBO	Gecikme Uzayını Doğru Bulma Oranı
K	Klasik seçim
MA	Hareketli Ortalama
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzdesel Hata
MDA	Modifiye Edilmiş Yön Doğruluğu
MLP	Çok Katmanlı Ağ
MSE	Ortalama Karesel Hata
RMSE	Kök Ortalama Kare Hatası
s.	Sayfa No
SBC	Schwarz Criterion
SSE	Karesel Hatalar Toplamı
STAR	Yumuşak Geçişli Otoregresif Model
TOPSIS	Technique for Order Preference by Similarity to Ideal Solution
WIC	Ağırlıklandırılmış Bilgi Kriteri
YSA	Yapay Sinir Ağları

TABLÖLAR LİSTESİ

Tablo 1: Simülasyon Verisi İçin Oluşturulan Deneyin Tasarım Şeması	s. 95
Tablo 2: Gerçek Veriler İçin Oluşturulan Deneyin Tasarım Şeması	s. 100
Tablo 3: AR2 Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen MSE Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 104
Tablo 4: AR2 Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen MAE Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 105
Tablo 5: AR2 Modeli, 1.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 106
Tablo 6: AR2 Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 108
Tablo 7: AR2 Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 108
Tablo 8: AR2 Modeli, 1.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 108
Tablo 9: AR2 Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 110
Tablo 10: AR2 Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri	s. 110
Tablo 11: AR2 Modeli, 1.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi Ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 110
Tablo 12: AR2 Modeli Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 117
Tablo 13: AR2 Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 117
Tablo 14: AR2 Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 117
Tablo 15: AR2 Veri Seti İçin Tablo Kodlama Sonucu	s. 118
Tablo 16: GAR Modeli ve 1.Gürültü Seviyesinde 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 118

Tablo 17: GAR Modeli ve 1.Gürültü Seviyesinde 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 119
Tablo 18: GAR Modeli ve 1.Gürültü Seviyesinde 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri	s. 119
Tablo 19: GAR Modeli Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 120
Tablo 20: GAR Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 120
Tablo 21: GAR Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 120
Tablo 22: GAR Veri Seti İçin Tablo Kodlama Sonucu	s. 121
Tablo 23: Lynx Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 122
Tablo 24: Lynx Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 123
Tablo 25: Lynx Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 123
Tablo 26: Lynx Veri Seti İçin Tablo Kodlama Sonucu	s. 123
Tablo 27: Sunspot Uzun Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 124
Tablo 28: Sunspot Uzun Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 125
Tablo 29: Sunspot Uzun Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş T Testiyle Karşılaştırılması	s. 125
Tablo 30: Sunspot Uzun Veri Seti İçin Tablo Kodlama Sonucu	s. 125
Tablo 31: Sunspot Kısa Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 126
Tablo 32: Sunspot Kısa Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 126
Tablo 33: Sunspot Kısa Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 126
Tablo 34: Sunspot Kısa Veri Seti İçin Tablo Kodlama Sonucu	s. 127

Tablo 35: IBM Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 128
Tablo 36: IBM Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 128
Tablo 37: IBM Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması	s. 128
Tablo 38: IBM veri seti için tablo kodlama sonucu	s. 129
Tablo 39: Lynx Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 130
Tablo 40: Lynx Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 131
Tablo 41: Sunspot Uzun Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 132
Tablo 42: Sunspot Uzun Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 132
Tablo 43: Sunspot Kısa Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 132
Tablo 44: Sunspot Kısa Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 132
Tablo 45: IBM Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 133
Tablo 46: IBM Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması	s. 134
Tablo 47: Doğrulama Seti Hacminin Etkisinin İncelenmesi İçin Yapılan Kruskal-Wallis H-Test Planı	s. 135
Tablo 48: AR2 Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 136
Tablo 49: AR2 Veri Seti, Gürültü2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 138
Tablo 50: AR2 Veri Seti, Gürültü2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 138

Tablo 51: GAR Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 138
Tablo 52: GAR Veri Seti, Gürültü1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 139
Tablo 53: GAR Veri Seti, Gürültü1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 139
Tablo 54: GAR Veri Seti, Gürültü2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 140
Tablo 55: GAR Veri Seti, Gürültü2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 140
Tablo 56: GAR Veri Seti, Gürültü3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 140
Tablo 57: GAR Veri Seti, Gürültü3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 140
Tablo 58: GAR Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 140
Tablo 59: Lynx Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 141
Tablo 60: Lynx Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 142
Tablo 61: Lynx Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 142
Tablo 62: Sunspot Uzun Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 143
Tablo 63: Sunspot Uzun Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 143
Tablo 64: Sunspot Uzun Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 143

Tablo 65: Sunspot Kısa Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 143
Tablo 66: Sunspot Kısa Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 144
Tablo 67: Sunspot Kısa Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 144
Tablo 68: IBM Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi	s. 145
Tablo 69: IBM Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 145
Tablo 70: IBM Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.	s. 145
Tablo 71: Doğrulama Seti Hacminin Etkisinin İncelenmesi İçin Yapılan Kruskal-Wallis Test Planı	s. 147
Tablo 72: Lynx Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi	s. 148
Tablo 73: Sunspot Uzun Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi	s. 148
Tablo 74: Sunspot Kısa Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi	s. 148
Tablo 75: IBM Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi	s. 148
Tablo 76: Lynx Veri Seti, Doğrulama2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 148
Tablo 77: Lynx Veri Seti, Doğrulama3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 149

Tablo 78: Sunspot Kısa Veri Seti, Doğrulama1, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 149
Tablo 79: Sunspot Kısa Veri Seti, Doğrulama1, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi	s. 149

ŞEKİLLER LİSTESİ

Şekil 1: Gerçek Bir Nöronun Basitleştirilmiş Gösterimi	s. 8
Şekil 2: Yapay Bir Nöronun İşlevselliğinin Temsili Gösterimi	s. 9
Şekil 3: Basitleştirilmiş Bir Sinir Ağı	s. 10
Şekil 4: YSA Transfer Fonksiyonunun Bir Örneği	s. 12
Şekil 5: Tahmin Metotlarının Sınıflandırılması	s. 31
Şekil 6: Zaman Gecikmeli Ağ Yapısı	s. 57
Şekil 7: Kısaltılmış Notasyonla İki Katmanlı Ağ	s. 60
Şekil 8: 2.Gürültü Seviyesinde AR2 Modeli	s. 95
Şekil 9: 2.Gürültü Seviyesinde GAR Modeli	s. 95
Şekil 10: Kanada Vaşak Serisi	s. 98
Şekil 11: Güneş Lekesi Serisi	s. 98
Şekil 12: IBM Hisse Senedi	s. 99
Şekil 13: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 106
Şekil 14: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 107
Şekil 15: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 107
Şekil 16: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 107
Şekil 17: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 109
Şekil 18: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 109
Şekil 19: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 109
Şekil 20: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 110
Şekil 21: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 111

Şekil 22: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı	s. 111
Şekil 23: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 111
Şekil 24: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı	s. 112
Şekil 25: AR2 Modelinden Türetilen Bir Simülasyon Verisinin Kısmi Otokorelasyon Grafiği	s. 113
Şekil 26: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 75 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği	s. 114
Şekil 27: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği	s. 114
Şekil 28: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 25 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği	s. 114
Şekil 29: AR2 Modelinden Türetilen İkinci Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği	s. 115
Şekil 30: AR2 Modelinden Türetilen Üçüncü Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği	s. 115

EKLER LİSTESİ

EK 1: AR2 Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar	ek s.1
EK 2: AR2 Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar	ek s.3
EK 3: AR2 Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar	ek s.5
EK 4: AR2 Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar	ek s.7
EK 5: AR2 Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar	ek s.9
EK 6: AR2 Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar	ek s.11
EK 7: GAR Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar	ek s.13
EK 8: GAR Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar	ek s.15
EK 9: GAR Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar	ek s.17
EK 10: GAR Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar	ek s.19
EK 11: GAR Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar	ek s.21
EK 12: GAR Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar	ek s.23
EK 13: GAR Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar	ek s.25
EK 14: GAR Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar	ek s.27
EK 15: GAR Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar	ek s.29
EK 16: Lynx Veri Setine Ait Sonuçlar	ek s.31
EK 17: Sunspot Uzun Veri Setine Ait Sonuçlar	ek s.34
EK 18: Sunspot Kısa Veri Setine Ait Sonuçlar	ek s.37
EK 19: IBM Veri Setine Ait Sonuçlar	ek s.40

GİRİŞ

Zaman serisi tahminlemesi bilimsel, endüstriyel, ticari ve ekonomik faaliyetler gibi çok farklı alanları içeren önemli ve gittikçe büyüyen bir disiplindir. Hareketli ortalama, üstel düzeltme ve Box-Jenkins teknikleri gibi doğrusal tahminleme metotları uzun süre zaman serisi alanına egemen olmuş ve birçok gerçek uygulamada kendilerine yer bulmuşlardır. Ancak, çoğu gerçek dünya problemi esasen doğrusal olmayan karakteristiğe sahiptir. Böyle bir durumda, doğrusal olmayan tekniklerin kullanılması akla yatkındır. Buradan yola çıkarak, verideki doğrusal olmayan desenleri modelleyebilmek amacıyla ikili doğrusal model (Bilinear), eşik otoregresif model (TAR), yumuşak geçişli otoregresif model (STAR), ARCH ve GARCH gibi doğrusal olmayan tahminleme metotları geliştirilmiştir. Bu model-tabanlı doğrusal olmayan metotlarla ilgili problem, değişkenler arasındaki doğrusal olmayan fonksiyonel ilişkinin belirlenmesi gerekliliğidir. Model-tabanlı doğrusal olmayan tekniklerin bu özelliği uygulamalarının spesifik problemlerle sınırlı kalmasına yol açmıştır (De Goojier ve Kumar, 1992: 136).

Veriyi modellemeden önce doğrusal olmayan fonksiyonu belirleme gerekliliğinin üstesinden gelmek için esnek doğrusal olmayan modellemeye olan ihtiyaç, bazı araştırmacıların cezp edici özellikleri sebebiyle sinir ağları üzerine odaklanmalarına yol açmıştır. Sinir ağları, insan beyninin bilgiyi nasıl işlediği sorusuna cevap bulmak girişimiyle gerçek hücrelerin davranışının taklit edilmeye çalışılmasının bir sonucu olarak ortaya çıkmıştır. Sinir ağlarının ana özelliği, ağ üzerine dağıtılmış çok sayıdaki hücreyi kullanarak paralel veri işlemeyi yerine getirebilmesidir. Sinir ağlarının bazı özellikleri modelleme süreci kapsamında klasik zaman serisi tahminleme teknikleri ile kıyaslandığında oldukça ilgi çekicidir. Sinir ağları veri sürürlü bir yöntemdir. Bu özellik, modellenen değişkenler arasındaki ilişki hakkında herhangi bir fonksiyon varsayımı yapılmaması anlamına gelmektedir. Teorik açıdan bakılacak olursa, bir sinir ağının yeterli derecede sinir hücresine sahip olmasıyla herhangi bir fonksiyonel forma istenilen doğruluk derecesinde yaklaşabileceği ispatlanmıştır (Cybenko, 1989: 303; Hornik ve diğerleri, 1989: 359). Ayrıca, zaman serisi tahminleme problemlerinde sinir ağlarının çok sayıda başarılı

uygulamasý, modellemeci iin deęerli bir ara olduğunu gstermektedir (Zhang ve dięerleri, 1998: 35). Sinir aęları, gemiřteki verilerden ęrenir ve tek ihtiyaı olan řey ilgili probleme ait verinin aęa sunulmasıdır. Bu, veriyi elde etmenin verinin retim srecini teorik olarak tahminlemeden daha kolay olduęu oęu problem iin olduka kullanıřlı bir zelliktir.

Sinir aęlarının zaman serisi tahminlemedeki potansiyel gcn belirlmeye ynelik yapılmıř ok sayıda alıřma bulunmaktadır. Bu ama iin klasik zaman serisi tahminleme yntemleriyle karřılařtırmalar yapılmıřtır. Yapılan alıřmaların bir kısmı sinir aęlarının daha stn olduęu ynnde bulgulara ulařmıř olsa da (Tang ve dięerleri, 1991: 303; Hill ve dięerleri, 1996: 1082; Hu ve dięerleri, 1999: 197; Zhang ve Qi, 2005: 513; Zou ve dięerleri, 2007: 2921; Jain ve Kumar, 2007: 585) klasik tahminleme yntemlerinden daha kt performans gsterdięini rapor eden alıřmalar da bulunmaktadır (Foster ve dięerleri, 1992: 293; Brace ve dięerleri, 1991: 31; Gorr ve dięerleri, 1994: 17; Callen ve dięerleri, 1996: 475). Her ne kadar tm durumlarda dięer tahminleme tekniklerinden stn bir yntemin olmadığı bilinse de (Makridakis ve dięerleri, 1982: 142) sinir aęının kendine ait herkes tarafından kabul edilmiř bir metodolojisinin olmaması bu farklı stnlk sonularının bulunmasına neden olabilmektedir. Sinir aęı deneyi sonucunda hangi sinir aęının gelecekte kullanılmak zere seileceęine karar verme problemi, sinir aęının metodolojiksel eksikliklerinden bir tanesidir.

Veri setinin ardıřık olarak eęitim, doęrulama ve test řeklinde  paraya ayrılmasının ardından, yapılan sinir aęı deneyi sonucunda klasik seim yntemiyle doęrulama setinde en kk hata deęerini veren sinir aęı seilir ve test seti zerinde genelleme yeteneęi deęerlendirilir. Burada ama, eęitim setine ařırı uyum saęlamıř bir aęın seiminden kaınmaksa da veri blnmesinin tahminlerin deęiřkenlięinde artıřa yol aabileceęi bilinmektedir (Faraway, 1992: 220; LeBaron ve Weigend, 1998: 213). Eldeki veri sayısı kısıtlı veya seri zerinde son dnem etkisinin daha yoęun olması durumunda, doęrulama hacminin ok byk seilmesi sıkıntıya yol aabilecektir. Doęrulama seti hacmi kk ise klasik seim yntemiyle seilen aęın genelleme yeteneęi hakkında kuřkular artabilecektir. Bu durumda, zellikle serinin belli bir dneminin kendine has zelliklerini iyi bir řekilde ęrenmiř aęın seilmesi

olasıdır. Bu tezde, doğrulama seti hacminin sebep olduğu genelleme yeteneği düşük ağ seçiminin üstesinden gelmek amacıyla bir seçim stratejisi geliştirilmiştir.

Önerilen seçim stratejisi, daha önce yapılan çalışmalarda elde edilmiş olan “girdi hücresinin gizli hücrelerinden önemlidir” bulgusundan (Lachtermacher ve Fuller, 1995: 390; Zhang, 2001: 1191; Zhang ve diğerleri, 2001: 381; Jasic ve Wood, 2003: 749) yola çıkarak öncelikle girdi veya gecikme hücre sayısını belirlemeye çalışmaktadır. Bunun için doğrulama seti üzerinde farklı girdi hücrelerinin tüm gizli hücre ve deneme sayılarındaki ortalama hata performansına bakılmaktadır. En iyi ortalama performansı veren girdi hücre sayısı belirlendikten sonra, farklı gizli hücrelerin tüm deneme sayılarında yine doğrulama seti üzerindeki ortalama performansına bakılarak da gizli hücre sayısı belirlenmektedir. Son adım olarak, girdi ve gizli hücre sayısı belirlenmişken farklı deneme sayılarının sebep olduğu farklı ağlardan hangisinin seçileceğine hem doğrulama hem de eğitim seti üzerindeki performanslarına bakılarak karar verilmektedir. Buradaki amaç, sadece doğrulama setinde iyi performans gösteren bir ağ değil her iki sette de iyi performans göstermiş ağın seçilmesidir. Bu amaca yönelik olarak çok kriterli karar verme tekniğinden yararlanılmıştır.

Bu tezin amaçlarını aşağıdaki gibi sıralamak mümkündür:

- Simülasyon ve gerçek veri setleri üzerinde klasik seçim yöntemiyle önerilen seçim stratejisinin performanslarını kıyaslamak.
- Gerçek veriler üzerinde, Box-Jenkins metoduyla hem önerilen seçim stratejisinin hem de klasik seçimin karşılaştırmasını yapmak.
- Doğrulama hacminin sinir ağı performansı üzerindeki etkisini her iki seçim yöntemi kapsamında görmek.
- Deneme sayısının sinir ağı performansında bir etkisinin olup olmadığını araştırmak.

Birinci bölüm içerisinde, gerçek nöronların temel elemanları ve işleyişi tanıtılmış ve hangi özelliklerinin yapay nöronlarda nasıl oluşturulmaya çalışıldığına değinilmiştir. Sinir ağlarının genel yapısı açıklanarak avantaj ve dezavantajlarından bahsedilmiştir. Bir sinir ağı tahmin modeli oluşturulurken hangi adımlara dikkat edilmesi gerektiği ve bu adımlar hakkında önemli tanım ve bilgiler verilmiştir.

Yapay sinir ağlarının kullanım alanları anlatılmış ve son olarak sosyal bilimler içerisinde sinir ağlarını kullanırken karşılaşılan sorunlara değinilmiştir.

İkinci bölümde, zaman serisi tahminlemede sinir ağlarının nerede olduğunu görmek amacıyla öncelikle klasik zaman serisinin doğrusal ve doğrusal olmayan metotlarından kısaca bahsedilmiştir. Ardından, sinir ağlarıyla zaman serisi tahminlemede yapılan önemli çalışmalar bulgularıyla ayrıntılı olarak verilmiştir. Çeşitli sinir ağı türlerine ve sinir ağlarının klasik yöntemlerle olan benzerliklerine değinilmiştir. Zaman serisi tahminlemede faydalanan sinir ağı yapısına ilişkin bilgiler verilmiş, matematiksel ayrıntılarıyla beraber geri yayılım algoritmasının işleyişi anlatılmıştır.

Son olarak üçüncü bölümde, oluşturulan yapay sinir ağı deneyi sonucunda nihai olarak seçilecek ağı belirlemedeki problemlerden bahsedilmiştir. Bu amaca yönelik yapılmış çalışmalara ayrıntılarıyla değinilmiştir. Girdi ve gizli hücrelerinin sinir ağıyla yapılan bir zaman serisi tahminlemedeki önemi vurgulanmış ve bu hücre sayılarının belirlenmesi için önerilen bazı parmak kuralları verilmiştir. Sinir ağlarında sıklıkla ortaya çıkan aşırı uyum sağlama problemi tanıtılmıştır. Zaman serisi tahminlemede faydalanabilecek önerilen seçim stratejisi tanıtılmış ve hem simülasyon hem de gerçek veri setleri üzerinde klasik seçim yöntemiyle ayrıntılı kıyaslamalarına yer verilmiştir.

BİRİNCİ BÖLÜM

YAPAY SİNİR AĞLARINA GENEL BAKIŞ

1.1. YAPAY SİNİR AĞLARI

Modern bilgisayarların gittikçe daha gelişmesiyle beraber bilim adamları, insanlar için basit sayılabilecek görevlerde makineleri daha etkili olarak kullanmaya çalışmaktadırlar. Bir öğreticiden alınan bazı geri bildirimler aracılığıyla örneklerle dayanarak bir *A* harfini tanımayı veya bir kuşu bir kediden ayırt etmeyi kolay bir şekilde öğrenebiliriz. Daha fazla deneyimle cevaplarımızı ve performansımızı geliştirebiliriz. Her ne kadar bu tarz kararları verebilecek kuralları tanımlayabilsek de, bu durumdan gerçekte kullandığımız sürecin yansıtıldığı anlamı çıkarılmamalıdır. İnsan olarak herhangi bir öğretici olmadan benzer desenleri birlikte gruplayabiliriz veya bazı kısıtlara göre bir kaynağı maksimize etmeyi içeren bir hedefi yerine getirmeye çalışırız. Bu çeşit problemler bilgisayarların çözüm arayabilecekleri görevler olarak sayılabilir.

Yapay zeka ve sinir biliminin asıl amacı, insan beynine benzer şekilde hesaplama yapan, öğrenen, hatırlayan bir sistemin kurulmasının istenmesidir. Her ne kadar insan beynine yakın benzerlik göstererek onun yetenekleriyle yarışabilecek sistem kurulamamış olsa da, nörolojik modellemenin akla yatkın basitleştirilmiş örnekleri hesaplamsal bir araç olarak geliştirilmiş ve çok farklı alanlarda kendine yer edinerek klasik modelleme teknikleriyle çetin bir rekabet içine girmiştir.

Yapay Sinir Ağları (YSA), ilk olarak bilişsel bilim (cognitive science) ve mühendislik alanlarında evrensel ve yüksek derecede esnek fonksiyon yakınsamasında bir araç iken, yakın zamanda çok çeşitli alanlarda kendine yer edinmiştir. Şirket tahvillerinin risk derecesinin belirlenmesi, kredi değerlendirilmesi ve sigorta poliçesi hazırlama gibi desen eşleştirme, sınıflandırma ve tahminleme gerektiren finansal uygulamaların, sinir ağları için mükemmel çalışma alanları olduğu çoğu çalışmayla desteklenmiştir (Salchenberger ve diğerleri, 1992: 899). Sinir ağlarının basit bir şekilde insan beyninin işleyişine benzemeye yönelik çabanın bir sonucu olduğu bilgisi, özellikle desen tanımlama problemi için oldukça ilgi

çekicidir. Bunun nedeni, şu andaki bilgisayar destekli tekniklerin hiçbirinin beynin desen tanımlama yeteneğini geçememesidir.

Modern mikroçipler, temel işlemleri nanosaniyede yerine getirirken insan beyni ise milisaniyeye gerek duymaktadır. Buna rağmen, insan beyni bilinmeyen görüntü açılarından bilinen nesneleri çok az zorluk çekerek kısa sürede ve doğru olarak tanıyabilmektedir. Bu işlem klasik bilgisayarlar için oldukça zorlu bir görev olmaktadır. Temel farklılık işlem hızında değil, işlemin organizasyonundadır. Beyindeki işlem görevi, 10^{11} ile 10^{12} arasında değişen ve birbirine bağlanmış nöronlar aracılığıyla paralel olarak yerine getirilir. Böylece karmaşık görevlerin çok çabuk bir şekilde üstesinden gelinir. Nörolojik faaliyetin diğer önemli bir özelliği, uyum yeteneği ve kendini örgütleyebilmesidir. Karşılaştığımız olay ve durumların etkisiyle tecrübelerimiz arttıkça, beyin yeni bilgileri özümseyebilmek amacıyla adaptasyon işlemine başlar ve sinir yapıları buna bağlı olarak kendilerini düzenlerler. Yapay zekâ alanındaki araştırmaların temel dayanağı, gerçek beyinde gerçekleşen işlem tarzının ve yapısının öğrenilmeye çalışılarak kopya edilmesidir. Dolayısıyla psikoloji, sinir bilimi ve bilgisayar bilimi gibi birçok farklı alanın ortak uzmanlığını gerektiren bir alanı oluşturmaktadır.


Sinir ağları genellikle öğrenme kabiliyetlerine göre nitelendirilirler. Örnekler iteratif şekilde ağı verilirken, doğru çıktı desenlerini üretmeyi öğrenirler. Çok sayıda algoritma sinir ağlarını eğitmek amacıyla geliştirilmiştir. Öğrenme mekanizmalarını gözetmenli (supervised), gözetmensiz (unsupervised) ve kendinden gözetmenli (self-supervised) öğrenme olarak kabaca üç kategoriye ayırmak mümkündür. Gözetmenli öğrenme de belli bir girdi hücresi vektörüne karşılık gelen istenilen cevap her zaman bilinmektedir. Gerçek çıktı vektörü hedef çıktı vektörüyle karşılaştırılır ve aradaki farkı düşürmek amacıyla ağırlıklar üzerinde düzenleme yapılması yoluna gidilir. Gözetmenli öğrenme, yaygın ve başarılı olarak kullanılmakla beraber biyolojik yapıya uygun olmaması bakımından eleştirilmektedir. Gözetmensiz öğrenme hedef vektörüne gerek duymadığından, daha çok biyolojik öğrenme sistemleri gibi davranmaktadır. Gözetmensiz öğrenmede hedef vektörü bilinmediğinden, girdi vektörleri arasındaki ilişki/yakınlık ölçülerinden faydalanarak girdi vektörlerinin çeşitli sınıflar altında toplanması yoluna gidilir. Kendinden gözetmenli öğrenme, gözetmenli ve gözetmensiz öğrenmenin ortasında bulunmaktadır. Öncelikle sınıfları

veya cevapları bilinen örneklerden öğrenmeye başlar, ardından sınıfı bilinmeyen örneklerde istenilen çıktı değerlerinin belirlenmesine çalışılır.

1.2. GERÇEK VE YAPAY SİNİR AĞI BENZERLİKLERİ

Gerçek bir hücreyi incelediğimizde, nöronların çekirdekte oluşan voltaj tarafından beliren kısa süreli elektriksel sinyaller aracılığıyla iletişim kurduklarını görürüz. Her hücrenin kolları olan dendritlerin üzerinde bulunan ve elektrokimyasal kavşaklar olarak adlandırılacak sinapsler, nöronlar arasındaki bağlantıyı oluşturmaktadır. Her nöron diğer nöronlarla çok sayıda bağlantı kurarak gövdesinde çok sayıda girdi sinyali toplayarak bunları birleştirmektedir. Elde edilen bu girdi sinyalleri belli bir eşik değerini aşarsa, hücre aktif hale geçerek bir voltaj üretiminin ortaya çıkmasına yol açmaktadır. Bu elektriksel sinyal, akson olarak adlandırılan lifin yardımıyla diğer nöronların dendritlerinde bulunan sinapslere gönderilmektedir. Çekirdekte bir nöronun elektriksel sinyal üretip üretmeyeceği belirlenirken hücreye ulaşan bazı girdi sinyalleri engelleyici etki niteliği taşımakta, başka bir deyişle hücrenin girdi sinyallerine cevabı olan elektriksel akımın oluşmasını engellemektedirler. Bazı girdi sinyalleri ise bunun tam tersi tepkinin oluşmasına sebep olan, tetikleyici özelliği taşımaktadırlar. Aşağıdaki Şekil 1 'de oldukça basitleştirilmiş gerçek bir nöronun şekilsel gösterimi, temel elemanlarıyla sunulmuştur. Böylece sinir hücresinin bir sinyal işleme aygıtı olarak sadece fonksiyonelliği ele alınmış olup, diğer hücrelerden ne gibi farklılıklarının olduğu üzerine odaklanılmıştır.


Şekil 1: Gerçek Bir Nöronun Basitleştirilmiş Gösterimi



Kaynak: Cheng ve Titterington, 1994: 7.

Biyolojik nöronların yapay karşılığının tipik bir gösterimi, Şekil 2 'de verilmiştir. Dendritler hücrenin girdilerine karşılık gelmekte ve her girdi hücre gövdesine gönderilmeden önce sinapslere karşılık gelen ağırlık değerleriyle çarpılarak hücre gövdesine gönderilmektedir. Hücre gövdesindeki ağırlıklandırılmış sinyaller veya girdiler bir hücrenin aktivasyon değerinin bulunması için, basit ve yaygın olarak aritmetik toplama işlemi aracılığıyla birleştirilirler. Ardından aktivasyon değeri bir eşik değeriyle karşılaştırılır. Eğer hücrenin aktivasyon değeri belirlenmiş bir eşik değeri geçerse, hücre bir çıktı değeri üretir ve bu geleneksel olarak 1 değeriyle gösterilir. Aksi takdirde ise, hücre 0 değerini çıktı olarak verir ve bunun anlamı hücrenin aktif olmadığıdır. Belirtilmelidir ki gerçek nörondaki akson parçası, yapay nörondaki çıktı birimine karşılık gelmektedir. Aşağıdaki şekilde hücreye giren sinyallerin büyüklüğü her birine karşılık gelen okların genişliği ile simgelendirilmiştir. Ağırlık değerleri daireler içerisindeki çarpım sembolleri ile gösterilmiş olup, değerleri yine sembol büyüklüğüyle doğru orantılı olacak şekildedir. Yalnız pozitif ağırlıklar kullanılmıştır. Bu çeşit bir yapay hücre, en basit ve tarihsel olarak da en eski yapay hücre modelidir.

Şekil 2: Yapay Bir Nöronun İşlevselliğinin Temsili Gösterimi



Kaynak: Gurney, 1997: 3.

Yapay hücrelerin katmanlar içerisinde organize edilerek bir araya getirilmesiyle oluşan yapay hücreler bütünü, bir yapay sinir ağını oluşturur. Yapay sinir ağı daha basitlik sağlaması açısından araştırmacılar tarafından genellikle sadece sinir ağı olarak isimlendirilmektedir. Her hücre (nöron, birim), üzerinde bir ağırlık değeri bulunan yönlendirilmiş bağlantılar aracılığıyla diğer hücrelerle ilişkilendirilmiştir. İki hücre arasında bulunan ağırlık, belli bir problemi çözmek için ağ tarafından atanmış bilgiyi temsil etmektedir. Her hücrenin aldığı girdilerin fonksiyonu olan, aktivasyon değeri olarak isimlendirilen içsel bir konumu vardır. Genellikle, bir hücre aktivasyon değerini bağlantılı olduğu öteki hücrelere bir sinyal olarak gönderir. Her ne kadar bir hücre birden çok hücreye yayılan sinyal gönderse de bir hücre belli bir zamanda sadece tek bir sinyal gönderebilir.

Örneğin, Şekil 3 'den görülebileceği gibi Y hücresi X_1 , X_2 ve X_3 hücrelerinden girdiler almaktadır. Bu hücrelerin aktivasyonlarını x_1 , x_2 , x_3 ve bu hücrelerden Y hücresine bağlantı ağırlıklarını sırasıyla w_1 , w_2 ve w_3 gösterin. Y hücresine olan net girdi, X_1 , X_2 ve X_3 hücrelerinin ağırlıklandırılmış sinyallerinin toplamıdır.


$$y_{netgirdi} = w_1x_1 + w_2x_2 + w_3x_3 \quad (1.1)$$

Y hücresinin aktivasyonu olan y , net girdinin bir aktivasyon fonksiyonundan geçirilmesiyle hesaplanır. Sıklıkla kullanılan aktivasyon fonksiyonu lojistik sigmoid fonksiyondur:

$$f(x) = \frac{1}{1+\exp(-x)} \quad (1.2)$$

Ardından, Y hücresi Şekil 3 'den takip edilebileceği gibi sırasıyla v_1 ve v_2 ağırlıklarıyla Z_1 ve Z_2 hücrelerine bağlıdır. Y hücresi sinyalini bu hücrelere gönderecektir, ancak Z_1 ve Z_2 tarafından alınan farklı v_1 ve v_2 ağırlıklarından ötürü aynı sinyal olmayacaktır. Aşağıdaki şekilde tek hücreden oluşan bir gizli katman verilmiştir. Bununla birlikte, genellikle bir sinir ağındaki gizli katmanda birden fazla gizli hücre olması sebebiyle, Z_1 ve Z_2 hücrelerinin z_1 ve z_2 aktivasyonları birden çok hücreden alınan girdilere bağlı olacaktır.

Şekil 3:Basitleştirilmiş Bir Sinir Ağı



Kaynak: Fausett, 1993: 4.

Biyolojik sistemlerde öğrenme, nöronlar arasında var olan sinaptik bağlantıların düzenlenmesiyle gerçekleşmektedir. Bu durum, yapay sinir ağları için de geçerlidir. Yapay sinir ağlarında öğrenme, hücreler arasındaki bağlantı ağırlıklarının iteratif bir şekilde değiştirilmesiyle gerçekleşir. İstatistik diliyle konuşmak gerekirse, yapay sinir ağları doğrusal olmayan modellemeye ve öğrenme süreci de parametre kestirimine karşılık gelmektedir.

1.3. SİNİR AĞLARININ GENEL YAPISI

Sinir ağları, doğrusal ve doğrusal olmayan en küçük kareler regresyonuna benzerdir ve en küçük kareler problemini çözmede alternatif bir istatistiksel yaklaşım olarak görülebilir (Kuan ve White, 1994: 3). Hem sinir ağları hem de klasik regresyon analizi, hata kareler toplamını minimize etmeye çalışır. Sinir ağlarındaki sabit girdi birimi terimi (bilgisayar bilimcileri bunu “bias” olarak adlandırır) regresyon denklemindeki kesim (intercept) terimiyle benzerdir. Girdi hücre sayısı bağımsız değişken sayısına, çıktı hücresi ise bağımlı değişkene karşılık gelmektedir. Hücreler arasındaki bağlantı ağırlıkları, doğrusal en küçük kareler yöntemindeki katsayılar ile aynı işlevi görmektedir. Ayrıca doğrusal regresyon modelini gizli katmanı olmayan ve doğrusal transfer fonksiyonuna sahip tek çıktı hücreli bir sinir ağı olarak görmek mümkündür. Tek gizli katmana sahip sinir ağı ise, doğrusal olmayan regresyon modellerine benzemektedir.

Sinir ağları, ilgilenilen Y çıktı değişkenini bazı X girdi değişkenleriyle ilişkilendiren transfer fonksiyonlarının bir araya getirilmesi şeklinde tanımlanabilir. Buradaki X girdi değişkeni de başka açıklayıcı değişkenlerin fonksiyonu olabilir ($X = g(Z)$). Sinir ağı literatüründe çok farklı transfer fonksiyonları kullanılmış olsa da, $Y = a + (1 + \exp[-(c + bX)])^{-1}$ doğrusal olmayan lojistik fonksiyon belki de en popüler olanıdır. İstenildiği takdirde, $Y = a + bX$ gibi doğrusal fonksiyonlarda kullanılabilir. Şekil 4, yatay ekseninde X girdi değerlerini dikey ekseninde Y çıktı değerlerini gösteren basit bir sinir ağı örneğinin temsidir. Dört gizli hücreye sahip olan ağ, X ile Y ‘i şu şekilde ilişkilendirmektedir:


$$\begin{aligned} y_1 &= 1 + 0.1X \\ y_2 &= 0.5 - (1 + \exp[-(75 + 40X)])^{-1} \\ y_3 &= 0.5 - (1 + \exp[-(0 + 2X)])^{-1} \\ y_4 &= 1 - (1 + \exp[-(170 - 85X)])^{-1} \end{aligned} \tag{1.3}$$

Ardından, $Y = \sum_{i=1}^4 y_i$ hesaplanır.

Şekil 4 ‘e dikkat edilirse, $X < -2$ iken $y_2 \approx 0.5$, $y_3 \approx 0.5$ ve $y_4 \approx 0.5$ olacak ve Y ‘nin davranışı büyük bir ölçüde $y_1 = 1 + 0.1X$ doğrusal hücresi ile

belirlenecektir. X değeri -2 'yi artarak geçtiğinde, y_2 hızlı bir şekilde $y_2 = -0.5$ minimumuna erişecek böylece X değeri -1,6 civarına yaklaştığında, $Y = \sum y_i$ değeri 1,8 'den 0,8 'e düşecektir. Ardından X değeri sıfıra doğru yaklaştığında, her ne kadar y_3 'ün cevabı y_2 ile kıyaslandığında daha ani cevap vermese de ($40X$ yerine $2X$), y_3 hücresi aktif olmaya başlayacaktır. Böylece $X = 1.5$ iken $Y \approx 0.2$ olacaktır. Son olarak, X değeri 2 'yi geçerek artmaya başladığında, y_4 hücresi 0 'dan 1 'e artarak aktif olacak Y 'nin 0,2 'den 1,2 'ye yükselmesine sebep olacaktır. X 'de daha fazla meydana gelecek artışın Y 'deki etkisi artık büyük miktarda doğrusal y_1 hücresi tarafından belirlenecektir. Şekil 4 'ün sinir ağı tarafından oluşturulan nihai durumu, farklı bölümlerinde farklı eğimlere sahip karmaşık derinlemesine bir deseni ortaya çıkarmıştır. Bu örnekten yola çıkarak, X 'in çeşitli aralıkları üzerinde farklı eğim ve kesime sahip birçok hücrenin aktif ve pasif hale getirilmesiyle X girdisinin neredeyse tüm fonksiyonlarına karşılık gelen Y çıktı cevabı üretilebilir (veya $X_1, \dots, X_n$ grup girdisi mevcutken, aynı durumun genellemesi yapılabilir). Aslında çoğu araştırmacı tarafından gösterildiği gibi sinir ağları, örnek hacmine oranla tahminlenecek az sayıda parametreyle çok geniş bir sınıfta fonksiyona keyfi derecede yaklaşabilme yeteneğine sahiptir (Donaldson ve Kamstra, 1997: 22).

Şekil 4: YSA Transfer Fonksiyonunun Bir Örneği



Kaynak: Donaldson ve Kamstra, 1997: 22.

1.4. SİNİR AĞLARININ AVANTAJLARI VE DEZAVANTAJLARI

Bilgi işleme teknolojisi olarak da görülebilecek sinir ağlarının klasik modelleme tekniklerinden temel bir farklılığı vardır. Parametrik istatistiksel modeller, kullanıcının bağımsız değişkenlerle bağımlı değişken arasındaki fonksiyonel ilişkinin doğasını belirlemesini zorunlu kılarlar. Fonksiyonel form hakkında bir kez varsayım yapıldıktan sonra, optimizasyon tekniklerinden faydalanarak hata ölçüsünü minimize eden parametre setinin belirlenmesine çalışılır. En az bir gizli katmana sahip bir sinir ağı, kendisine verilen örnekleri kullanarak değişkenler arasındaki ilişkinin bir içsel gösterimini geliştirmeye çalıştığından, altta yatan parametre dağılımları hakkında bir ön varsayıma gerek duymaz. Dolayısıyla değişkenler arasındaki ilişkinin varsayılan modele uymadığı durumlarda, sinir ağlarının parametrik istatistiksel yöntemlere göre daha iyi sonuçlara ulaşılması beklenebilir. Ancak hem sinir ağının doğası hem de birçok parametreye karar verilmesi, sinir ağının sonuçlarının değişken yapılı olmasına yol açtığından kesin iyi bir sonuca ulaşamamaktadır.

İleri beslemeli geri yayılım ağı, kendine en çok kullanım alanı bulmuş ve araştırmacılar tarafından en çok tercih edilmiş sinir ağı türüdür. Hornik ve diğerleri (1989), keyfi bir transfer fonksiyonuna sahip standart bir ileri beslemeli ağın yeterli sayıda gizli hücreye sahip olması durumunda, herhangi bir ölçülebilir fonksiyona istenilen derecede yaklaşabileceğini göstermişlerdir. Ayrıca, Hecht-Nielsen (1989) üç katmanlı ileri beslemeli ağın sonlu sayıda gizli katman birimiyle herhangi bir sürekli fonksiyonu temsil edebileceğini ispatlamışlardır. Bu teorik sonuçlar, ileri beslemeli sinir ağlarını herhangi bir kompleks fonksiyona yakınsama görevi için akla yatkın bir aday haline getirmektedir. Sinir ağları, bir zaman serisindeki değişiklikleri yönlendiren altta yatan kompleks, doğrusal olmayan herhangi bir fonksiyonu temsil etme potansiyeline sahiptir. Sinir ağları, model tabanlı tahminleme yöntemlerinden farklı olarak bağımlı ve bağımsız değişkenler arasındaki fonksiyonel ilişki hakkında herhangi bir kısıtlayıcı varsayımda bulunmayan veri sürüşlü bir metottur. Yapay sinir ağlarının bu özellikleri, çok sayıda verinin bulunduğu ancak bu verileri üreten altta yatan sürecin bilinmediği tahminleme durumları için uygulamacıları cezp etmektedir.

Sinir ağırları yüksek derecede doğrusal olmayan ve karmaşık ilişkileri temsil edebilir, bağımsız şekilde değişen veri desenleri aracılığıyla bir olayın farklı durumlarını tespit edebilir ve uygun bileşenler arasında otomatik olarak değişimleri yerine getirebilir. Bu yüzden, sinir ağırları karmaşık bir olayın içerisinde cereyan eden ilişkiler hakkında yeterli bilgiye sahip olmadığımız ancak olayın iyi tanımlanmış ölçümlerine sahip olduğumuz durumlar için özellikle uygun bir yöntemdir. Ayrıca kendini uyarlama ve otomatik modelleme özelliklerinden dolayı, tahminleme problemleri için ideal bir yöntem olduğu söylenebilir. Sinir ağlarının bazı sınırlamalarından bahsetmek gerekirse, tahminleme açısından olmasa da elde edilen sonuçların açıklanması aşamasında (nedensel modelleme ve hipotez testi) sorun yaşamaktadır. Sinir ağlarının model formu, model katsayılarında doğrusal olmadığından normal olasılık modeli uygulanamaz (Gorr ve diğerleri, 1994: 19). Bunun sonucu olarak, t ve F dağılımlarına dayanan model anlamlılığı ve katsayı testleri gibi parametrik istatistiksel özelliklere sahip değildir. Sinir ağının ortalama karesel hata fonksiyonunun çok modlu olmasından ötürü, ağ ağırlıklarının tespit edilmesinde doğrusal olmayan optimizasyon algoritmalarının kullanılması gereklidir. Ancak bu algoritmalar global minimum yerine, yerel minimuma yakınsayarak optimal olmayan modellemeye neden olabilirler. Ayrıca bağımsız değişkendeki bir birimlik değişimin bağımlı değişken üzerindeki etkisini ortaya koyan marjinal değişim, sinir ağlarında kolayca elde edilebilir olmadığından tahminlenen ağın ağırlıklarını yorumlamak zordur.

Sinir ağırları, iddia edilen ve yapılan çok sayıda çalışmayla da desteklenmiş yararlı özelliklerine rağmen yoğun bir şekilde eleştiri almaktan kurtulamamıştır. Bu eleştirilerin kaynağını, başta elde ettiği çözümlerin kara kutu doğasına sahip olması, eğitim için harcanan aşırı zaman, sabit bir çözümün elde edilmesindeki zorluk, aşırı uyum sağlama tehlikesi ve iyi bir tahmin oluşturmak için deneysel olarak seçilmesi gerekli olan çok sayıdaki parametre oluşturmaktadır (Kaastra ve Boyd, 1996: 216). Ayrıca mevcut sinir ağı metodolojilerinin büyük miktarda veriye gereksinim duyması pratik kullanımının önündeki engellerden biri olarak sayılabilir. Mevcut metodolojiler ele alınan probleme bağlı olarak ağ oluşturma sürecinde birkaç saat ve hatta güne ve yüzlerce gözleme ihtiyaç duyabilmektedir.

1.5. SİNİR AĞI TAHMİN MODELİ TASARIMINDAKİ ADIMLAR

Bir sinir ağı tahmin modelini oluşturmada sırasıyla izlenecek adımlar kısaca aşağıda verilmiştir.

1.5.1. Değişken Seçimi

Kuşkusuz ki her çözüm yönteminin olduğu gibi sinir ağlarının da başarılı olmasındaki gerek koşul ele alınan problemin çok iyi bir şekilde anlaşılmasıdır. Tahminlemenin yapılacağı alanda hangi girdi değişkenlerinin önemli olduğunun bilinmesi kritik bir noktayı oluşturmaktadır. Bu noktada hangi alanda tahminleme yapılacaksa o alandaki teorik bilgilerden faydalanmak bir çözüm yol olabilecektir. Yapılacak diğer bir tercih ise teknik ve/veya temel değişkenlerin kullanımına karar verilmesidir. Teknik değişkenler bağımlı değişkenin gecikmeli değerleri veya gecikmeli değerlerden hesaplanan göstergelerdir. Temel değişkenler ise bağımlı değişkeni etkilediğine inanılan öteki değişkenlerdir. Ayrıca veri frekansının seçimi araştırmacının amaçlarına bağlı olarak değişecektir. Örneğin işsizlik, milli gelir gibi makro ekonomik göstergeleri tahminleyen bir ekonominin aylık veya çeyreklik verileri kullanması muhtemeldir.

1.5.2. Veri Toplanması

Bir önceki adımda seçilen değişkenlerin verilerini toplarken, bu verilerin mevcut olma durumunu ve maliyetini araştırmacının hesaba katması gerekir. Ayrıca araştırmacı verilerin doğruluğunun yanı sıra kayıp gözlemleri de kontrol etmelidir. Kayıp gözlemler analizden çıkarılabilir, kayıp gözlemin olduğu değişkenin değerinin değişmediği varsayılabilir veya yakın değerlerin ortalaması alınabilir. Sıklıkla faydalanan yöntemlerden biri ise kayıp gözlem durumlarına yönelik olarak ağa bir girdi hücresi eklenmesi ve eğer kayıp gözlem varsa bu hücrenin girdisi 1 yoksa ise 0 olarak kodlanmasıdır.

1.5.3. Veri Ön İşlemesi

Veri ön işlemesi, girdi ve çıktı değişkenlerindeki gürültünün minimize edilmesi, önemli ilişkilerin ön plana çıkarılması, trendin tespit edilmesi ve değişkenlerin dağılımının yassılaştırılması için transformasyona uğratılması ve analiz edilmesidir (Kaastra ve Boyd, 1996: 221). Sinir ağlarının desen eşleştiricisi olmasından ötürü, verinin gösterim şekli başarılı bir ağın tasarımında önemli yer tutmaktadır. Girdi ve çıktı değişkenlerinin ağa ham veri olarak sunulması nadir karşılaşılan bir durumdur. Klasik zaman serisi ve sinir ağı tahminlemesinde en yaygın olarak kullanılan iki veri transformasyonu, değişkenin doğal logaritması ve farkının alınmasıdır. Birinci farklar veya bir değişkendeki değişimlerin kullanılması, veriden trendin kaldırılmasına yardımcı olabilir. Logaritmik transformasyon ise hem küçük hem büyük değerleri alabilen ve sağa çarpık dağılım durumlarında faydalıdır. Ayrıca diğer kullanılabilecek veri ön işleme teknikleri kapsamında oranlardan faydalanmak, girdi ve çıktı değişkenlerinin düzgünleştirilmesi, çeşitli teknik göstergeler ve veri üzerinde filtreleme işlemlerinin yapılması sayılabilir.

1.5.4. Eğitim, Doğrulama ve Test Setleri

Veri setinin sırasıyla eğitim, doğrulama ve test seti olarak adlandırılan üç farklı gruba ayrılması genel bir uygulama pratiğidir. Eğitim setinden kurulacak her farklı sinir ağı modelinin tahmin edilmesi amacıyla faydalanılır. Ağın eğitimde görmediği verilerden oluşan doğrulama seti, bu farklı parametrelere sahip modellerden hangisinin seçileceğinin belirlenmesi ve kimi uygulamalarda eğitimin durdurulması için de kullanılır. Test seti ise her zaman bir zaman serisinin en son gözlem grubundan oluşturulur ve ağın genelleme yeteneği hakkında bilgi elde edilmesine aracılık eder. Eğitim, doğrulama ve test setleri hakkında daha fazla bilgi üçüncü bölüm içerisinde verilmiştir.

1.5.5. Sinir Ağının Temel Unsurları

Sinir ağını oluşturan temel parçalar veya unsurlar girdi hücre sayısı, gizli katman sayısı, gizli hücre sayısı, çıktı hücresi ve transfer fonksiyonlarıdır. Bunlara ait bilgiler kısaca aşağıda verilmiştir.

1.5.5.1. Girdi Hücre Sayısı

Özellikle zaman serisi tahminlemesi açısından bakıldığında, girdi hücre sayısının elde edilecek sonuçları direkt olarak etkileyen bir faktör olduğu ve seçiminin kolay bir iş olmadığı rahatlıkla söylenebilir. Analizde teknik değişkenler kullanılıyorsa ne kadar gecikmeye izin verileceği sorusuna, sadece temel değişkenler veya hem temel hem de teknik değişkenler bir arada faydalandığı durumlarda yine ne kadar gecikmeye izin verileceği sorusuna cevap aranması gerekir. Ayrıca hangi temel değişkenlerin kullanılacağı sorusu da ele alınmalıdır.

1.5.5.2. Gizli Katman Sayısı

Teoride yeterli sayıda gizli hücreye sahip tek gizli katmandan oluşan sinir ağının herhangi bir sürekli fonksiyona yaklaşma yeteneği gösterilmiştir (Hornik ve diğerleri, 1989: 359; Cybenko, 1989: 303). Uygulamada bir veya nadiren de olsa iki gizli katmanlı ağların sıklıkla kullanıldığı ve iyi sonuçların alındığı bilinmektedir. Gizli katman sayısının artırılması, hesaplama zamanının artmasına yol açması yanında aşırı uyum sağlama problemine de neden olabilecektir. Aşırı uyum sağlama kısaca modelin çok fazla parametreye sahip olarak genelleme yeteneğinin düşük kalması durumudur. Dolayısıyla bir en fazla iki gizli katmanın tercih edilmesi yararlı olacaktır.

1.5.5.3. Gizli Hücre Sayısı

Bilindiği üzere, gizli hücre katmanının olmadığı ilk sinir ağlarının performansı yetersiz kalmış ve bu durum sinir ağlarına olan ilginin düşmesine yol

açmıştır. Sinir ağı uygulamalarına olan ilgide meydana gelen büyük artışın ağa gizli hücre eklenmesi vasıtasıyla gerçekleşmesi bile gizli hücrenin ağ içindeki önemini anlatmak için yeterli bir sebeptir. Gizli hücre ağın doğrusal olmama ve genelleme yeteneklerini kazanmasını sağlamaktadır. Ancak bir ağda olması gereken gizli hücre sayısının belirlenmesi, işin bir ucunda yetersiz gizli hücre sebebiyle ağın yeteri derecede öğrenecek argümanlara sahip olamaması, diğer ucunda ise çok fazla gizli hücreyle ağın aşırı argümana sahip olarak kendine gösterilen desenleri ezberleyebilmesine dolayısıyla da genelleme yeteneğini kaybetmesine neden olması açısından önemli bir problemdir. Gizli hücre sayısının belirlenmesine yönelik olarak uygulanabilecek çeşitli yaklaşımlara üçüncü bölüm içerisinden ulaşılabilir.

1.5.5.4. Çıktı Hücre Sayısı

Çıktı hücre sayısının belirlenmesi diğer parametre kararları ile kıyaslandığında daha kolaydır. Tek bir çıktı hücrelerine sahip olan ağın performansı, birçok çıktı hücresi olan ağa göre daha üstündür. Sinir ağları, çıktı hücrelerindeki ortalama hatayı minimize eden optimal bağlantı ağırlık değerlerini bulmaya çalışır. Dolayısıyla, örneğin bir adım ileri tahmin yapan bir çıktı hücreli ağ ile üç adım ileri kadar tahmin yapan üç çıktı hücreli ağın olası performanslarını karşılaştırsak, üç çıktı hücreli ağ en büyük hataya sebep olan çıktı hücresi hangisi ise onun üzerine odaklanacaktır. Böylece, eğer üçüncü adımı tahmin eden çıktı hücresinin hatası birinci adımı tahmin eden çıktı hücresinin hatasından büyükse birinci adımın tahminlerinde önemli ölçüde iyileşme beklenemeyecektir. Her adım tahmini için ayrı bir ağ kurularak, sinir ağlarını bu tahminler üzerinde uzmanlaştırmak daha yararlı bir yaklaşım olacaktır.

1.5.5.5. Transfer Fonksiyonları

Bir hücrenin çıktısını belirleyen matematiksel fonksiyonlardır. Genellikle sigmoid fonksiyonu kullanılır ancak hiperbolik tanjant, adım fonksiyonu, doğrusal fonksiyon gibi öteki fonksiyon türlerinden de yararlanılabilir. Transfer fonksiyonu kullanılmasıyla herhangi bir hücrenin çıktısının çok büyük değerlere ulaşarak eğitimi

aksatmasının önüne geçilmeye çalışılır. Ayrıca bu fonksiyonlar ağı doğrusal olmama yeteneğini de kazandıran birimlerdir. Bunun bir diğer anlamı, doğrusal transfer fonksiyonlarının doğrusal olmayan yapıların incelenmesi için uygun olmadığıdır. Sigmoid fonksiyonunun sürekli türevi alınabilir ve doğrusal olmama yapısı, hem sinir ağının öğrenme algoritması hem de doğrusal olmama problemine uygunluğu nedeniyle tercih sebebidir.

1.5.6. Değerlendirme Kriteri

Sinir ağında minimize edilen hata fonksiyonu kullanılan programın önerdiği seçeneklere göre farklılık gösterebilir. En çok kullanılan değerlendirme fonksiyonları Ortalama Karesel Hata (MSE) ve Ortalama Mutlak Hata (MAE) kriterleridir. Ancak bu hata fonksiyonları ağı bazı özellikleri hakkında bilgi vermezler. Mesela finansal piyasalar için hatanın küçüklüğünden daha çok tahmin yönü daha fazla önem arz etmektedir. Hatanın küçük ama yönün yanlış olduğu bir tahmin değeri yerine hatanın nispeten daha büyük ama yönün doğru olduğu tahmin, alım-satım kararları için kullanıcıya daha çok getiri sağlayacaktır. Bu yüzden kar veya getirinin modelin doğru şekilde veya en küçük hatayla tahminlenmesinden daha önemli olduğu durumlarda değişim yönünün analiz edilmesi işlemi sinir ağlarında yapılabilir. Zaman serisi üzerindeki küçük fiyat değişimlerinin çoğunu kaldıracak bir filtreleme yapılmasıyla ağı daha büyük fiyat değişimleri üzerine odaklanmasına ve dolayısıyla karlılık oranının yükseltilmesine çalışılabilir.

1.5.7. Sinir Ağı Eğitimi

Sinir ağları eğilirken eğitim örnekleri ağı iteratif olarak verilir ve eğitimin amacı hata fonksiyonunu global bazda minimum yapan hücreler arasındaki bağlantı değerlerinin bulunmasıdır. Bu çalışmada kullanılan geri yayılım algoritması, bağlantı ağırlıklarını ayarlamak için hata yüzeyinden aşağı doğru inerken en dik iniş (steepest descent) yönteminden faydalanır. Bu yöntem bir yerel arama algoritmasıdır ve hata yüzeyinin birden çok yerel minimuma sahip olması durumunda global minimumu garanti etmez. Hata fonksiyonunun minimum değeri olarak, yerel bir minimum

değerini bulması olası bir durumdur. Bunun üstesinden gelmek için farklı başlangıç ağırlık değerleriyle algoritmanın tekrarları yapılır ve hızlandıran teriminden faydalanarak global minimum değerine ulaşılmaya çalışılır.

1.5.7.1. Eğitim İterasyonu Sayısı

Eğitimin ne zaman durdurulması gerektiğine dair iki görüş bulunmaktadır. İlk görüşe göre, araştırmacı makul sayıda rassal olarak seçilmiş başlangıç ağırlık değerleriyle yapılmış denemelerde hata fonksiyonunda bir düşüş meydana gelmediğinde eğitimi durdurulmalıdır. Hata fonksiyonunda artık düşüşün olmadığı nokta yakınsama (convergence) noktası olarak adlandırılır. İkinci görüş ise eğitim-doğrulama set performanslarına eğitim boyunca eş zamanlı bakar ve ağıın genelleme yeteneğini gösteren doğrulama seti üzerindeki performansı düşmezse, eğitime devam edilir aksi durumda ise eğitim sonlandırılır. Burada önceden belirlenmiş olan iterasyon sayısının ardından, ağıın eğitime ara verilip doğrulama seti performansına bakılarak eğitime devam veya sonlandırma kararı verilir. Bu ikinci görüşe olan eleştiri iterasyonun durdurulması yerine eğitime devam edilmesi halinde ağıın genelleme yeteneğinin artabileceği ya da doğrulama setinde birden çok iniş ve çıkışın olabileceğidir. Dolayısıyla öğrenme erken kesilmiş olabilir. Nihai ağı seçerken her iki yöntem de doğrulama setinden faydalanacaktır. Yakınsama yaklaşımı aşırı öğrenme gibi bir kavramın olmadığını, sadece aşırı uyum sağlamanın olduğunu savunur. Aşırı uyum sağlama da ağıın çok fazla ağırlık değerine sahip olmasıdır. Bu yüzden gizli hücre sayısı azaltılarak ve/veya eğitim seti hacmi artırılarak bu problemin üstesinden gelinebileceği söylenir. Eğitim-doğrulama seti yaklaşımı ise, aşırı uyum sağlamadan kaçınmak için eğitimi ağıın genelleme yeteneğine göre durdurmaya çalışır. Yakınsama yaklaşımının avantajı, eğitim-doğrulama yaklaşımı sonuçlarına göre daha az oynaklık göstermesi ve eğitimin durdurulacağı noktayı düşünmeye gerek olmamasıdır. Eğitim-doğrulama yaklaşımının avantajı ise serbestlik derecesi daha düşük ağların genelleme yeteneğinin, yakınsama yaklaşımının ağlarına göre daha iyi olabileceğidir. Diğer bir avantajı ise daha az eğitim zamanına gereksinim duymasındır.

1.5.7.2. Öğrenme Oranı ve Hızlandırıcı Terimi

Öğrenme oranı, sinir ağlarında bağlantı ağırlıkları değiştirilirken bu ağırlık değişiminin büyüklüğünü belirler. Öğrenme oranının çok büyük olması hata fonksiyonu yüzeyinde arama uzunluğunun fazla olması anlamına gelir ki bu bazı çekim bölgelerinin üzerinden atlanmasına sebep olabilir. Böylece global minimuma sahip bir çekim bölgesine girilmemiş olunabilir. Çok küçük bir öğrenme oranı ise hata yüzeyinin dar bir bölgesinde sıkışılmasına veya çalşıılmasına sebep olabilir. Ayrıca eğitim zamanının artmasına sebep olacaktır. Öğrenme oranını hata yüzeyinde bir salınıma yol açmadan arttıracak bir metot, hızlandırıcı teriminden faydalanılmasıdır. Hızlandırıcı terimi, geçmiş ağırlık değişiminin mevcut ağırlık değişimi üzerindeki etkisinin nasıl olacağını belirler. Bu durumda her yeni arama yönü, mevcut ve önceki gradyanların ağırlıklı toplamı şeklindedir. Genel uygulama, büyük bir öğrenme oranıyla eğitime başlanması ve eğitim ilerledikçe bu değerin düşürülmesidir. Çoğu sinir ağı yazılım programları varsayılan bir öğrenme oranı ve hızlandırıcı terimi kullanırlar ve yakınsama arttıkça öğrenme oranını otomatik olarak düşürüp hızlandırıcı terimini arttıırırlar.

1.5.8. Uygulama

Aslına bakılırsa uygulama adımı sonda olmasına rağmen veri mevcudiyeti, değerlendirme kriteri gibi adımların kararında etkin rol oynar. Dikkat edilmesi gereken nokta, veri ölçeklendirmesi, transformasyon ve tüm öteki parametrelerin test setinde olduğu gibi değiştirilmeden gerçek kullanımda korunmasıdır. Sinir ağları, değişen koşullara periyodik şekilde yeniden eğitim yaptırılmasıyla uyum sağlayabilir. Yeniden eğitim yapma sıklığının test seti hacmiyle aynı olması genel uygulama pratiğidir.

1.6. YAPAY SİNİR AĞLARININ KULLANIM ALANLARI

Kişinin amacına bağlı olarak sinir ağı çalışmaları farklı bakış açılarından ele alınabilmektedir. Aynı zamanda hangi sorunun cevaplanmaya çalışıldığının bilinmesi

de bu konuda yardımcı olacaktır ve böylece sinir ağıları denildiğinde ortaya çıkabilecek karışıklığının önüne geçilmiş olunacaktır.

Sinir ağıları istatistiksel analiz ve veri modellemede sıklıkla kullanılmaktadır. Burada sinir ağıları, kümeleme analiz teknikleri veya standart doğrusal olmayan regresyonun bir alternatifi olarak görülmektedir (Choudhury ve diğerleri, 2006: 84; Tagliaferri ve diğerleri, 2001: 69). Sinir ağıları, çok sayıdaki girdinin az sayıdaki çıktı sınıfına haritalanmasını içeren sınıflandırma problemleri için kullanılabilir (Curram ve Mingers, 1994: 440). Benzer şekilde, eksik veya bozulmuş girdilerin doğru sınıfının tanımlandığı tamamlama problemlerinin de üstesinden gelmektedir (Gupta ve Lam, 1996: 229; Brouwer ve Pedrycz, 2003: 23). Böylece sinir ağıları, faktör analizi ve diskriminant fonksiyon analizine bir alternatif olmaktadır. Sinir ağıları, özellikle yapısal eşitliklerle kolay bir şekilde açıklanamayan birbiriyle doğrusal olmayan tarzda ilişkili çok sayıda girdinin mevcut olduğu durumlardaki tahminleme problemlerinde oldukça başarılıdır (Chen ve Leung, 2005: 403). Tahminlemede, sinir ağıları çok değişkenli genel doğrusal hipotez modellerine, yapısal eşitlik modellerine ve uzman sistemlere bir alternatiftir (Kurfess, 2000: 7). Ayrıca sinir ağıları, planlama gibi birçok parçadan oluşmuş faaliyetleri içeren kısıt doyurma problemlerini ve karmaşık talep kısıtlarını karşılamaya çalışan kaynak tahsis problemlerini çözebilmekte böylece doğrusal programlama ve dinamik sistem analizlerine bir alternatif olabilmektedir (Jain ve Meeran, 1998: 1249). Genelde ele alınan problem karmaşık ve yapısal olarak ortaya konamıyorsa, eksik veriler varsa, çok sayıda birbiriyle rekabet halde bulunan girdiler ve yapısal eşitliklerle formülasyonu önleyen karışık doğrusal olmayan yapıda ilişkili kısıtlar bulunuyorsa, sinir ağıları tarafından üretilen yaklaşık çözümleri araştırmacının kabul etmesi koşuluyla, sinir ağıları klasik istatistiksel yöntemlerden daha iyi sonuçlar ortaya koyabilir (Yoon ve diğerleri, 1993: 51). Bazı örnekler görüntü, ses, metinsel karakter tanımlanması ve sağlık teşhisi, jeolojik petrol arama, finansal pazar göstergesi tahmini gibi insan uzmanlık alanlarını içermektedir (Courrieu, 2006: 429). İnsan uzmanlık alanları klasik yapay zeka içerisine de girmektedir. Mühendisler ve bilgisayar bilimciler sinir ağılarını, makine zekasında egemen olan geleneksel algoritmik tekniklere alternatif sağlayan paralel dağıtılmış hesaplamanın bir türü olarak görmektedirler (Hakeem ve diğerleri, 2008: 1572). Paralellik her hücrenin

veya düğümün diğer hücre veya düğümlerle eşzamanlı ve bağımsız olarak işleme dahil olması gerçeğine dayanmaktadır. Ağ içerisindeki bilgi, klasik bir bilgisayarda olduğu gibi birkaç hafıza konumuna yerleştirilmektense tüm ağırlık seti üzerine dağıtılmıştır. Bu alanın uygulamacıları biyolojik gerçeklik ile kendilerini ilgili görmemekte ve dijital donanım problemlerinin çözümünün kolaylaşması veya belirli tekniklerin doğruluğu ve verimliliğiyle ilgilenmektedir.

Nörobilimci ve psikologlar gerçek sinir dokusunun bilgi işleme için gerekli olduğuna inanılan özelliklerinin özetlenmesiyle geliştirilen, hayvan beyninin hesaplama modelleri olarak sinir ağları ile ilgilenirler (Galizia ve Szyszka, 2008: 81). Oluşturulan yapay nöronlar genellikle biyolojik nöronların oldukça basitleştirilmiş şeklidir ve çoğu nörobilimci beyin fonksiyonelliğini açıklamak için daha fazla ayrıntıya gerek duyulduğu konusunda ısrar ederek, bu zayıflatılmış modellerin nihai gücü hakkında kuşkuya düşmektedirler.

Son olarak fizikçi ve matematikçiler doğrusal olmayan dinamik sistemler ve istatistiksel mekaniklere olan ilgiden ötürü, sinir ağları çalışma alanı içerisinde kendilerine yer bulurlar (Schindler ve Sanguineti, 2003: 179). Hatırlatmak gerekirse uygulamalı matematiğin işi, bilimin diğer alanlarında önceden kullanılan araçları kullanarak yeni sistemin özelliklerini keşfetmek ve formülleştirmektir. Örneğin özel bir tür ağ ile (Hopfield) manyetik sistemler arasında yüksek derecede bir bağlantı bulunmaktadır.

Bütün bu farklı gruptaki bilimciler farklı sorular sormaktadırlar: Nörobilimci hayvan beyninin nasıl çalıştığını bilmek ister, mühendisler ve bilgisayar bilimciler zeki makineler inşa etmek ister ve matematikçiler ise kompleks sistemler olarak sinir ağlarının temel özelliklerini anlamak isterler. İş ve endüstri dünyasının çeşitli alanlarında bulunan ve belki de daha büyük olan diğer bir grup insan ise sinir ağlarını, çalışma alanlarında doğal olarak ortaya çıkan büyük ve anlaşılması zor veri setlerini analiz ve modellemek için kullanırlar.

1.7. SOSYAL BİLİMLER İÇERSİNDE SİNİR AĞLARI KULLANIMININ YAYGINLAŞMASINDA KARŞILAŞILAN ENGELLER

Sinir ağları analizi son yıllarda tahminlemenin önemli olduğu sosyal bilimler uygulamalarında sıklıkla kullanılan bir metodoloji olmuş ve örneğin hisse senetlerinin finansal analizi gibi bir alan içerisinde karşılaşılmaya başlanmış bir durum haline gelmiştir. Buna bakılarak sosyal bilimlerde kullanılan geleneksel yaklaşımların yerine hızlı bir şekilde geçebileceği düşünülebilir fakat gerçekte bu böyle olmamaktadır. Bunun böyle olmamasının nedenlerine ve aynı zamanda sinir ağları araştırmacısının karşılaştığı zorluklara bakmak gerekmektedir. Bu nedenlerden biri yaklaşımın yeniliğinden kaynaklanmaktadır. Rumelhart ve McClelland çalışmaları 1986 yılında yayımlanmış ve sosyal bilimcilerin kullanabileceği sinir ağı yazılımları ancak 1990 'lı yılların başlarında olanaklı olmuştur. Yöntemin yeniliğinin haricinde, sosyal bilimlerde sinir ağları analizinin yayılmasına engel olan dört farklı neden bulunmaktadır.

İlk olarak, sinirsel modeller tahminleme alanında kendilerine yer bulsa da nedensel analizde yer bulamamaktadır. Sinirsel ağların sonuçlarına nasıl ulaştığını anlamak oldukça zor olabilmektedir. Şimdiye kadar tasarlanan sistemler, alternatif tekniklerin mesela uzman sistemlerde olduğu gibi sistemin sonuçlarına nasıl vardığını açıklayabilme yeteneğine sahip değildir. Daha da fazlası, sinir ağları uzman sistemlerin bir uzman sistem olarak var olan avantajlarını ele geçirecek şekilde tasarlanamazlar. Özellikle gizli katmanların işin içerisinde olması, sinirsel analiz algoritmalarının nedensel bir yorumu ağ ağırlıklarına ilişkilendirmesinin zor olmasına sebep olmaktadır. Sinirsel modelleri kullanan birkaç tane nedensel analiz yaklaşımı bulunsa da açık bir şekilde sosyal bilimcilerin ana ilgisi basit bir tahminleme değil açıklama olduğu ortadadır. Sinirsel modellerin kullanımının şu anda olduğundan daha yaygın olmamasının ana nedeni bu olmuştur. Bu bağlamda Andrew Hunter (1997) sinir ağları ile şu gözlemini aktarmıştır¹:

“Bir makinenin gerçekte tam anlamıyla nasıl çalıştığını anlamamanın olanaklı olamayabileceği kabul edilmektedir. Gerekli fonksiyonları yerine getirmeyi öğrenebilecek ağların inşa edilebilmesiyle, bizim aslında tam olarak onların nasıl

¹ Aktaran Garson, 1997: 16

işlediğini anlamaya ihtiyacımız yoktur. Klasik eğitilmiş bir bilimci bakış açısından, bir şeylerin anlaşılmadan oluşturulması neredeyse dinsel/toplumsal değerlere aykırı görüş ile eşdeğer anlam taşımaktadır.”

İkinci neden ise sinir ağı modellerinin çok sayıda ve karmaşık olmasıdır. Geri yayılım modeli en çok kullanılan teknik olmasına rağmen, sinir ağları analizi sadece bir teknikten oluşmamaktadır. Oldukça fazla sayıda sinirsel modeller bulunmaktadır. Bir insan tüm hayatını alternatif ağlarla deney yaparak, onları optimize etmeye çalışarak ve farklı parametrelerin etkilerini araştırarak geçirebilir. Sinirsel modelleme bir sanat dalı ve sosyal bilimci ise işi hiç sonlanmayan bir sanatçı veya topluma sunduğu analiz sonuçlarının optimal olduğundan asla emin olamayan bir zanaatçı gibi görülebilir. Sinir ağı modellerinin çekiciliğinden etkilenerek işin içine dahil olan sosyal bilimci, genellikle sonradan onun karmaşıklığı tarafından geri püskürtülmektedir.

Üçüncüsü, uygulama düzeyinde çoğu sosyal bilimci için araştırma metodolojisini oldukça sınırlayarak tanımlayan SAS, SPSS ve diğer standart istatistiksel paketlerin içerisinde sinir ağı analizi barındırmaları biraz yavaş olmuştur. Fakat son yıllarda sinir ağlarına olan ilginin önemli derecede artmış olmasının da etkisiyle, bu durum değişmeye başlamıştır. Şu anda SPSS ve SAS içinde de sinirsel model oluşturulabilmektedir.

Dördüncüsü, belki diğerlerine göre sosyal bilimlerde sinir ağının yayılması önünde daha az öneme sahip bir engel olarak görülebilecek neden, sosyal bilime uzak alanlarda ortaya çıkan metod olması gerçeğidir. Sinir ağları literatürünü okumaya başlayan sosyal bilimci oldukça farklı bir teknik dil ile karşılaşmaktadır.

1. Gözlemlere veya olaylara “desen” denilmektedir.
2. Değişkenlere “özellik” denilmektedir.
3. Bağımsız değişkenlere “girdiler” denilmektedir.
4. Bağımlı değişkenlere “hedefler” veya “çıktılar” denilmektedir.
5. Artıklara “hatalar” denilmektedir.
6. Parametrelerin tahminlenmesine ise eğitim, öğrenme veya kendini ayarlama (self organization) denilmektedir.
7. Örnek periyoduna “eğitim seti” denilmektedir.
8. Geçerliliğe (Validation) ise “genelleştirme” denilmektedir.

Ayrıca araştırmacı regresyon ve diskriminant analizi ile gözetmenli öğrenme arasında, ana bileşenler analizi ile gözetmensiz öğrenme arasında ve rekabetçi öğrenme ile sınıflandırma analizi arasında bir bağlantı kurmalıdır. Bu ve diğer terminolojik problemler, sinir ağları analizinde yeni olan sosyal bilimci için zorluklar çıkarmaktadır (Garson, 1997: 17).

1.8. GERİ YAYILIM ALGORİTMASI

Gizli hücresi olmayan ağın hata yüzeyinde sadece bir minimum nokta bulunacaktır. Gizli hücrelere sahip bir hata yüzeyinin çok sayıda yerel minimum içerebilmesi nedeniyle, ağırlık uzayındaki en dik iniş aramasının kötü bir yerel minimumda takılı kalması olasıdır. Ancak uygulamada bu ciddi bir problem olarak gözükmemektedir (Hinton, 1989: 199). Hinton (1989), çok çeşitli problemler için geri yayılım algoritmasını denemiş ve kötü yerel minimuma nadiren rastlamıştır. Bunun bir nedeni, genellikle farklı, çok sayıda iyi çözümün bulunmasıdır. Sinir ağlarında geri yayılım algoritmasının 1980 'lerde kullanılmasıyla beraber ağın yetenekleri ve uygulama alanları artmıştır.

Geri yayılım algoritması, ileri beslemeli çok-katmanlı ağın (MLP) eğitilmesinde iyi tanımlanmış bir öğrenme metodudur. Geri yayılım ağlarının amacı girdi-çıkı desen çiftleri arasındaki doğrusal olmayan haritalamayı öğrenmektir. Algoritma, gerçek değerler ve ağın çıktı değerleri arasındaki ortalama karesel hatayı iteratif eğitim iniş yöntemiyle minimize edecek şekilde tasarlanmıştır. Geri yayılım algoritması, ileri ve geri yayılma şeklinde iki adımdan oluşmaktadır.

İleri yayılım aşamasında, eğitim verisi girdi katmanına verilir ve gizli katman veya katmanlar aracılığıyla çıktı hücrelerine ulaştırılarak (ileri besleme) ağın çıktısı ile gerçek değer arasındaki hata değeri hesaplanır. Ardından geri yayılım algoritmasının ikinci aşaması olan geri yayılıma geçilir. Gizli katman hücreleri hata ile doğrudan bağlantılı olmadığından kendi hatalarını tahmin etme gereği duyarlar. Bu, hata geri yayılımının kullanarak kendi bağlantı ağırlıklarını değiştirebilme imkanını verir. Ağ tarafından yapılan hata miktarı, ilk olarak doğrusal olmayan transfer fonksiyonunun değişim oranı seviyesinde bir hata sinyaliye dönüştürülür. Bu hata sinyali daha sonra bağlantı ağırlıkları aracılığıyla gizli katman birimlerine geriye gönderilir (geri

yayılır). Gizli birimler, bağılı olduğu çıktı birimlerinden aldığı hata sinyallerinin ağırlıklandırılmış bir toplamı olarak kendi hatalarını tahmin eder. Bir çıktı birimin hatası veya gizli birim ve çıktı birimi arasındaki ağırlık büyükse, bu takdirde gizli birim için hata sinyali de büyük olacaktır. Hata sinyalinin işareti ağırlık değişiminin yönünü gösterecektir. Gizli birimin hata sinyalleri tahminlendikten sonra, tüm bağlantı ağırlıkları onların hata sinyali orantısında güncelleştirilir. Geri yayılım algoritmasının işlemsel ayrıntılarına, bu çalışmanın ikinci bölümünden ulaşılabilir.

İKİNCİ BÖLÜM

SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİ

2.1. ZAMAN SERİSİ TAHMİNLEMESİ

İş, yönetim ve bilimsel topluluklar içerisinde sürekli olarak ortaya çıkan bir problem, bir zaman serisinin gelecek değerlerinin tahminlenmesidir. Zaman serisi modellemesi ve tahminlemesi, hem akademik araştırma hem de pratik uygulamalar için önemli bir alan olmaya devam etmektedir. Örneğin, hava araçlarının tahminlenen rotalarına dayanarak havada çarpışmaların önlenmesi gibi birçok uygulamada sıklıkla ihtiyaç duyulmaktadır. Radar tarafından aktarılan ölçülmüş konumlara dayanarak, hava taşıtının gelecekteki koordinatlarının tahminlenmesi bir zaman serisi problemi olarak görülebilir. Tahminleme yapılacak olaydaki geçmiş değerler toplanır ve altta yatan veri üretim sürecinin öğrenilmesini sağlayacak bir modelin belirlenmesi için analiz edilir. Ardından bu model kullanılarak geleceğin tahmin edilmesine çalışılır. Bir zaman serisinin gelecek değerlerini tahminleme girişimi çok çeşitli disiplinleri içine almaktadır. Tahmin yapmak için geliştirilen teknikleri biyoloji, bilgisayar bilimi, ekonomi, mühendislik, matematik, fizik, istatistik ve diğer alanların ortak bir mirası olarak görmek mümkündür. Bu metotlar hayvan popülasyonları, turist geliş deseni, göç alış ve veriş trendi, bir ülkenin GSMH miktarı, işgücü ve işsizlik, banka faizleri ve döviz kuru, hisse senetlerinin gelecek değerleri, elektrik kullanımı, emlak fiyatları, yeni girişimlerin karlılığı, hastalık kontrolü, meteorolojik ölçümler, astronomik gözlemler gibi çok farklı veri setlerinde kendilerine uygulama alanları bulmaktadırlar.

Bir kuruluş hedeflerini oluşturur ve çevresel faktörleri tahmin etmeye çalışır. Ardından bu hedeflere ulaşılmasına katkı sağlayacağı düşünülen eylemleri belirler. Tahminlemeye olan ihtiyaç, yönetimin şansa olan bağımlılığı azaltmaya çalışmak ve çevresel faktörlerle baş etmede daha bilimsel olmak istemesiyle artar. Bir organizasyonun her biriminin diğer birimleriyle ilişkili olmasından ötürü, iyi veya kötü tahminler tüm organizasyon üzerinde bir etkiye yol acar. Örneğin, satış tahminlerindeki hatalar bütçe tahminleri, işlem giderleri, nakit akışı, envanter

düzeyi, fiyatlama vb. etmenler üzerinde tepkiler gözlenmesine neden olabilir. Açıkça görüldüğü gibi, organizasyonun farklı tahminleme birimleri arasında yüksek bir karşılıklı bağımlılık bulunmaktadır. Kaçınılmaz olan tahminleme hatalarını minimize ederek tahminlemeyi mümkün olduğunca güvenilir yapmak amacıyla çok çeşitli tahminleme teknikleri geliştirilmiştir. Bu çeşitlilik en son gözlemin tahmin değeri olarak kullanılması gibi en basit metotlardan, sinir ağları veya ekonometrik eşanlı denklem sistemi gibi yüksek seviyede karmaşık yaklaşımlara kadar değişebilmektedir.

Makridakis ve diğerleri (1998: 558), organizasyonel bakış açısından bir tahminleme görevindeki temel adımları şu şekilde tanımlamışlardır:

1. Problem Tanımı: Problemin tanımlanması bazen tahmincinin en zor görevi olabilmektedir. Tahminleme problemini doğru düzgün tanımlayabilmek için çok sayıda soruya cevap aranması gerekmektedir. Örneğin, neyin tahmininin yapılacağı ve tahmini yapılacak şeyin ne gibi özellikleri olduğu, tahminlerin nasıl kullanılacağı, kimin tahminlere ihtiyaç duyduğu, organizasyon içinde tahminleme fonksiyonunun nasıl yapılandırılacağı ve benzeri sorular hakkında düşünülmelidir. Verilerin toplanmasına dahil olan, veri tabanlarını yönlendiren ve gelecek planlaması için tahminleri kullanacak herkesle iletişim kurmak faydalı olacaktır.

2. Bilginin Toplanması: En azından iki tür bilgi her zaman mevcuttur: a) genellikle sayısal olan istatistiksel veri b) bir uzmanın bilgi birikimi ve tecrübesi. Her iki tür bilgide hesaba katılmalıdır. Tahminleme yapmak amacıyla bir model oluşturabilmek için ilgilenilen değişkenin tarihsel verisinin toplanması gereklidir.

3. Ön Analiz: Bu adım, verilerin ne anlattığının görülmesi amacını taşır. İlk etapta verinin görsel araştırma için grafiği çizilir ve basit tanımlayıcı istatistikleri hesaplanır. Eğer birden fazla ilişkili seri varsa, her seri çiftinin yayılım grafiği çizilerek ilgili tanımlayıcı istatistikleri (korelasyon gibi) oluşturulabilir. Bu aşamada şu sorular sorulur: Sürekli tekrarlayan desenler mevcut mu? Belirgin bir eğilim var mı? Mevsimsellik önemli mi? Konjonktür dalgalarına ait izler mevcut mu? Veri

uzman bilgisiyle açıklanabilecek herhangi bir uç gözlem içermekte mi? Analizde kullanılacak değişkenler arasındaki iliksiler ne kadar güçlü?

4. Modelin Seçilmesi ve Uydurulması: Bu adım birkaç nicel tahminleme modelinin seçilmesi ve bunların uydurulmasını içermektedir. Aslında, ön analiz adımı tahminlemede kullanılacak modelin seçilmesinde yararlı olabilecek nicel yöntemleri araştırmacı için sınırlandıracaktır. Her modelin dayandığı açık ve kapalı varsayımları ve bir veya birden fazla belirlenmesi gereken parametreleri vardır.

5. Tahminleme Modelinin Kullanılması ve Değerlendirilmesi: Bir model akla uygun olarak seçilip ve parametreleri de doğru bir şekilde belirlendikten sonra, tahminleme yapmak amacıyla kullanılabilir. Zaman içerisinde modelin avantaj ve dezavantajları, tahminlerin kullanıcısı tarafından değerlendirilecektir.


2.2. ZAMAN SERİSİ TAHMİN METOTLARI

Tahminleme metotlarını aşağıdaki şekilde görüldüğü gibi, nicel ve nitel yöntemler olarak iki sınıfa ayırmak mümkündür (Setyawati, 2005: 2). Nicel tahminleme, şu üç koşulun var olması durumunda uygulanabilir: 1) Geçmiş hakkında bilginin mevcut olması, 2) Bu bilginin rakamsal veri formunda sayısal hale getirilebilmesi, 3) Geçmiş veri deseninin bazı boyutlarıyla gelecekte tekrar edeceğinin varsayılabilmesi (Makridakis ve diğerleri, 1998: 13). Son koşul, devamlılık varsayımı olarak bilinir ve ne kadar gelişmiş olursa olsun tüm nicel ve çoğu nitel tahminleme tekniklerinin altta yatan dayanak noktasıdır. Nitel tahminleme yöntemlerine, sayısal bilginin çok az bulunduğu veya mevcut olmadığı ancak nitel bilginin var olduğu durumlarda başvurulabilir. Nitel yöntemin girdisi, özel olarak eğitim almış birkaç kişinin yargı ve bilgi birikiminden oluşur. Genellikle belirli sayısal tahmin üretmek yerine, planlamacıya yardım edecek ipuçları sağlamak ve nicel tahminlere tamamlayıcı olmak amaçlarıyla kullanılırlar. Bu tez kapsamında nicel tahminleme tekniğiyle ilgilenileceğinden, nicel tahminleme teknikleri hakkında kısaca bilgi verilecektir.

Literatürdeki nicel tahminleme teknikleri burada bahsedilemeyecek kadar çok çeşitlidir. Burada, sadece temel ayrıma ve tekniklere değinilmiştir. Daha çok

tercih edilen nicel yöntemler, nedensel tahminleme ve zaman serisi tahminlemesinden oluşmaktadır. Regresyon analizinin tipik bir örneği olduğu nedensel tahminleme yaklaşımında, tahminlenecek değişkenle ilişkili bir veya birden çok bağımsız değişken analizin içine katılıp bu bağımlı değişkenle bağımsız değişkenler arasındaki nedensellik ilişkisinden yararlanılarak tahmin yapılmaya çalışılır. Zaman serisi tahminlemesi, belli bir büyüklüğün zaman içerisindeki değişimini yansıtan sayısal değer dizisini kullanarak verinin barındırdığı desenleri tespit etmeye çalışıp, bu desenlere dayanarak serinin gelecekteki değerlerini tahmin etme yöntemidir. Zaman serisi metotları, önceden tanımlanmış bağımlı ve bağımsız değişkenler arasında bir neden-sonuç ilişkisi varsaymaması bakımından nedensel veya açıklayıcı metotlardan ayrılırlar. Nedensel metottan yararlanan araştırmacılar, genellikle bağımlı değişkene etkisi olan ilgili bağımsız değişkenleri belirlemeyi çok zor bir görev olarak görürler.

Şekil 5: Tahmin Metotlarının Sınıflandırılması



YSA, nicel tahminleme yöntemlerinin her iki dalı olan nedensel ve zaman serisi tahminleme alanlarında kullanılmaktadır. Nedensel tahminleme açısından bakarsak, bağımlı ve bağımsız değişkenler arasındaki fonksiyonel ilişki hakkında herhangi bir bilgi bulunmadığında veya ilişkinin doğrusal olmasının gerekli olmadığı durumlarda YSA 'nın kullanılmasının uygun olacağı büyük çoğunlukla kabul görmüştür. Denton (1995) nedensel tahminleme probleminde, sinir ağları ve çoklu regresyonun performanslarını karşılaştırmış ve ideal koşullar altında sinir ağlarıyla regresyon modelinin tahminleme yeteneği arasında çok küçük bir farklılık olduğunu bulmuştur. Ancak YSA 'nın veride sapan gözlemlerin bulunduğu, bağımsız değişkenler arasında yüksek ilişki olduğu ve model spesifikasyon hatası gibi ideal koşullardan uzaklaşıldığı durumlarda, doğrusal regresyon modellerinden daha iyi performans gösterdiğini ortaya koymuştur.

Klasik zaman serisi modelinin genel işleyişi, veriye mümkün olduğunca yakın şekilde uyum sağlayan desenin tespit edilmesidir. Başka bir deyişle, sistemin geçmiş gözlemleri olan girdiler ile tahminlerin oluşturduğu çıktılar arasındaki ilişkiyi en iyi şekilde tanımlayan fonksiyonel formun belirlenmesidir. Benzer durumun sinir ağlarının öğrenme sürecinde mevcut olduğu görülebilir. Sinir ağları girdi ve çıktı vektör setleri arasındaki ilişkiyi, bu vektör setleri arasındaki haritalama fonksiyonlarına yakınsamaya çalışılmasıyla öğrenir. Zaman serisi tahminlemesi açısından ise sinir ağları, doğrusal ve parametrik olmayan veri sürüştü zaman serisi modelidir. Ayrıca doğrusal otoregresif modele, gizli hücrenin bulunmadığı sinir ağının özel bir durumu gözüyle bakılabilir. İstatistiksel metotlarda bulunan normallik varsayımından farklı olarak, sinir ağları alta yatan veri süreci hakkında herhangi bir varsayım gerektirmez ve klasik zaman serisi tahminleme yöntemlerinden daha iyi performans gösterdiği de çok sayıda çalışma tarafından desteklenmektedir (*Bakınız: 2.3.Sinir Ağlarıyla Zaman Serisi Tahminlemesinde Yapılan Çeşitli Çalışmalar*).

Zaman serisi tahminlemede kullanılan yöntemler de doğrusal ve doğrusal olmayan metotlar olarak sınıflandırılır. En çok faydalanılan doğrusal metotlar: Düzeltme (Smoothing), Ayırıştırma (Decomposition) ve Box-Jenkins metodolojisi tahminleme prosedürleridir. Geleneksel olarak, doğrusal istatistiksel tahminleme metotları çoğu gerçek yaşam uygulamalarında yaygın olarak kullanılmışlardır. Doğrusal modellerin geliştirilmesi, uygulanması, anlaşılması ve yorumlanması

basittir. Çok fazla sayıda tahminleme yapılmasına gerek duyulduğu ve/veya tahmin doğruluğunun istenilen bir gereklilik olmadığı durumlarda, bu özellikler özellikle çekici olabilmektedir. Bununla birlikte çoğu gerçek yaşam probleminin doğrusal olmayan yapıda olması, doğrusal modellerin kullanım alanını sınırlamaktadır. Karmaşık doğrusal olmayan problemlere doğrusal modeller kullanarak yakınsamaya çalışılması, özellikle tahminlenecek nokta sayısı arttıkça genellikle tatmin edici sonuçlar vermeyecektir (Zhang ve diğerleri, 2001: 388). Büyük ölçekli tahminleme yarışmaları, tek bir doğrusal modelin tüm veri setleri ve tüm durumlarda egemenlik sağlamadığını göstermektedir (Makridakis ve diğerleri, 1982: 142). Bu metotlar, doğrusal zaman serilerinde iyi bir şekilde çalışmalarına rağmen karmaşık doğrusal olmayan zaman serilerini modellemede başarısız olmaktadır.

Doğrusal olmayan sistemlerin tahminleme performansını geliştirmek amacıyla çok çeşitli doğrusal olmayan zaman serisi modelleri önerilmiştir. İkinci jenerasyon zaman serisi modelleri olarak adlandırılabilen bu modeller, hem gerçek problemleri çözme de hem de bazı doğrusal olmayan sistemlerin davranışını anlamada yararlıdırlar. Bu doğrusal olmayan parametrik modellere ilişkin problem, belirli problemler için özellikle geliştirilmiş olmaları ve öteki durumlar için uygulanabilirliklerinin sınırlı olmasıdır. Doğrusal olmayan yöntem olarak kullanılabilen akla yatkın aday model çeşitliliğinin aşırı büyüklüğü, gerçek veri üretim sürecine iyi bir yakınsama sağlama görevini zorlu hale getirmektedir. Mevcut çok sayıdaki parametrik doğrusal olmayan modeller, aslında doğrusal olmayan veri üretim süreçlerinin çok küçük bir alt kümesi olma konumundadırlar (Diebold ve Nason, 1990: 315). Doğrusal olmayan zaman serisi tahminlemesi teknikleri basit olmamakla birlikte, değişkenler arasındaki fonksiyonel ilişki hakkında ön bilgi sağlayacak bir aracı bulunmamaktadır. Eşik otoregresif modeller ve ikili doğrusal model gibi klasik doğrusal olmayan metotlar, kullanılacak doğrusal olmayan fonksiyonun önceden belirlenmesini gerektirirler. Doğada sonsuz sayıda doğrusal olmayan fonksiyonun tanımlanabilecek olması sebebiyle uygun doğrusal olmayan fonksiyonun seçilmesindeki zorluk, bu gibi metotların doğrusal olmayan zaman serisi modellemesinde etkisinin özel durumlarla sınırlı kalmasına yol açmıştır.

Göreceli olarak daha yeni bir teknik diyebileceğimiz sinir ağları, genelleştirilmiş doğrusal olmayan modelleme ailesinin bir üyesi, veri sürüşlü ve

incelenilen problemin hakkında önbilgiye gereksinim duymayan bir yöntemdir. Dolayısıyla doğrusal olmayan fonksiyonun önceden belirlenmesi probleminin üstesinden gelebilmektedir. Örneklerden öğrenerek altta yatan ilişki bilinmese veya bu ilişkinin tanımlanması zor olsa bile, veriler aracılığıyla gizli fonksiyonel ilişki ele geçirilebilir. Böylece çözümü için belirlenmesi zor bir bilginin gerektiği ancak yeterli veri veya gözlemin olduğu problemler için oldukça uygundur. Bu modelleme yaklaşımı, verileri üreten sistemin iyi bir teoriksel tahmininin veri elde etmekten daha zor olduğu çoğu pratik problem için epey yararlıdır. Ayrıca sinir ağları kendisine sunulan örneklerden öğrenmesinin ardından örnek verisi gürültü bilgisini içeriyor olsa bile, popülasyonun geriye kalan görülmemiş kısmı hakkında genellikle doğru bir şekilde çıkarsama yapabilir. Tahminlemenin geçmiş örneklerden görülmemiş olan gelecek davranışın belirlenmeye çalışılması, sinir ağları için ideal bir uygulama alanı olarak durmasına sebep olmaktadır. Teoriksel olarak Cybenko (1989), Hornik ve diğerleri (1989) sinir ağlarının evrensel olarak fonksiyon yakınsayıcısı ve istenilen doğrulukta herhangi bir doğrusal olmayan fonksiyona yakınsayabileceğini ispatlamışlardır. Sinir ağlarının genel ve esnek modelleme yeteneği hem doğrusal olmayan yapıları bulabilmesine bunun yanı sıra doğrusal süreçleri de modelleyebilmesine imkân verdiği için, tahminleme uygulamalarında çekici bir araç olmasını sağlamaktadır (Zhang, 2001: 1183). Çok sayıda başarılı uygulama, sinir ağlarının zaman serisi modellemesi ve tahminlemesinde çok yararlı bir araç olduğunu göstermiştir (Zhang ve diğerleri, 1998: 35).

Tüm durumlarda en iyi performansı sergileyen bir tahminleme metodunun olmamasından ötürü ilgilenilen tahmin modelinin değerlendirilmesi yapılmadan önce, araştırmacı aşağıdaki faktörlere göre en uygun metodun hangisi olduğunu belirlemelidir (Kang, 1991: 3).

- **Veri deseni:** Zaman serisi trend, mevsimsellik, döngü veya bu bileşenlerin bazı bileşimlerini sergileyebilir.
- **Doğruluk ölçüsü:** Tahminleme metodlarının göreceli performansı kullanılan doğruluk ölçüsüne bağlıdır.
- **Tahminleme periyodu:** Tahminleme periyodunun uzunluğu tahminlerin doğruluğuna etki edebilir.

- **Tahminleme maliyeti:** Bir modeli geliştirme ve sürekliliğini sağlamanın maliyeti gibi bazı maliyetler var olabilir.
- **Kullanım ve işlem kolaylığı:** Bir modelin başarılı uygulamasının anahtar özelliği kullanıcılarıdır.

2.2.1. Doğrusal Metotlar

2.2.1.1. Düzeltme Metotları

Düzeltme metotları, hareketli ortalama metotları ve üstel düzeltme metotlarından oluşmaktadır. Basit hareketli ortalama metodu, gelecek dönemi tahminlemek için en son N veri noktasının ortalamasını kullanır. Bu metot basit ve kullanımı kolay olmasına rağmen, trend ve mevsimselliğin üstesinden gelemediği için uygulamada pek tercih edilmez. Üstel düzeltme metotları, eşit olmayan ağırlık setini verilere uygular. Üstel düzeltme metodunda, ağırlıklar en yeni gözlemden en uzaktaki gözleme doğru üstel şekilde azaltılır. Üstel düzeltme metotları, basitliği ve doğruluğu bakımından yoğun bir şekilde kullanılmıştır. Makridakis ve diğerleri (1982), üstel düzeltme metodunun bazen Box-Jenkins yöntemi kadar iyi sonuçlar verebileceğini belirtmişlerdir. Diğer düzeltme metotları: çift üstel düzeltme, yüksek dereceli üstel düzeltme, Winter metodu ve çift hareketli ortalama metotlarıdır. Basit üstel düzeltme metoduyla bir adım sonrası tahmini aşağıdaki şekilde tanımlanabilir.

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (2.1)$$

$$F_{t+1} = F_t + \alpha(Y_t - F_t) = F_t + \alpha e_t \quad (2.2)$$

Burada: $F_{t+1} = S_t = t + 1$ zamanındaki tahmin; Y_t , t zamanındaki gerçek değer; α ($0 \leq \alpha \leq 1$) düzeltme parametresi; e_t , bir dönem önceki tahmininin hatası.

Basit üstel düzeltme metodu, veride trend mevcutken iyi çalışmaz. Bu durumda, γ ($0 \leq \gamma \leq 1$) sabitine sahip ikinci bir eşitlikle üstel düzeltme kullanılır. Çift üstel düzeltme yöntemi şu şekildedir:

$$F_t = \alpha Y_t + (1 - \alpha)(F_{t-1} + b_{t-1}) \quad (2.3)$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.4)$$

Burada, γ ($0 \leq \gamma \leq 1$) çift üstel düzeltme parametresidir.

Yoğun bir şekilde kullanılan düzeltme metotlarının temel avantajı basitliği ve düşük maliyetidir. Kısa süre içinde çok fazla sayıda tahminleme işleminin yapılmasının gerektiği durumlarda, kabul edilebilir hızlı uygulamalara imkân verirler.

2.2.1.2. Ayırıştırma Metotları

Ayırıştırma metotları, zaman serisini karakterize eden altta yatan temel desenin üç ayrı bileşenini tespit etmeye çalışır. Ayırıştırma işlemi, verinin desen ve hatadan oluştuğunu ve desenin de trend, konjonktür ve mevsimsellik parçalarının bulunduğunu varsayar. Trend ve konjonktür parçaları, serideki uzun dönem değişimleri temsil ederler. Mevsimsel faktör; yağış, sıcaklık, yılın bazı ayları, tatil zamanları ve şirket politikaları gibi nedenlerden kaynaklanan sabit uzunluktaki periyodik dalgalanmalarla ilgilidir. Ayırıştırma yaklaşımının genel matematiksel gösterimi aşağıdaki gibidir:

$$Y_t = f(S_t, T_t, C_t, E_t) \quad (2.5)$$

Burada; $Y_t = t$ dönemindeki zaman serisi değeri

$S_t = t$ dönemindeki mevsimsel bileşen

$T_t = t$ dönemindeki trend bileşeni

$C_t = t$ dönemindeki konjonktür bileşeni

$E_t = t$ dönemindeki hata bileşeni

Bu yaklaşımın içerisinde Toplamsal Ayırıştırma Metodu ve Çarpımsal Ayırıştırma Metodu şeklinde iki yöntem bulunmaktadır. İlk yöntem f fonksiyonunun

toplama $Y_t = S_t + T_t + C_t + E_t$ şeklinde olduğunu, ikinci yöntemde ise mevsimsellik etkisinin zaman içerisinde çarpımsal olarak $Y_t = S_t \times T_t \times C_t + E_t$ değiştiğini varsayar. Ayırıştırma metotlarının ilk adımı, sistematik bir şekilde mevsimsellik, trend ve ardından konjonktürün seriden ayrıştırılmasıdır. İkinci adımda ise, bu bileşenlerin tahmini yapılır ve nihai tahmini elde etmek için farklı iki yöntemle birleştirilirler. Mevsimsel dalgalanmaların büyüklüğü serinin seviyesi ile birlikte değişmiyorsa, toplamsal model daha uygun ancak mevsimsel dalgalanmalar serinin seviyesindeki iniş çıkışlarla orantılı olarak iniş çıkış gösteriyorsa, çarpımsal modelden faydalanmak daha yerinde olacaktır. (Makridakis ve diğerleri, 1998: 85).

2.2.1.3. Box-Jenkins Metodolojisi

Box ve Jenkins (1970) tarafından önerilen ARIMA (Autoregressive Integrated Moving Average) modelleri, bir değişkenin gelecek değerinin bazı geçmiş gözlemlerin ve rassal hataların doğrusal fonksiyonu olduğunu varsayar. Zaman serisini oluşturan altta yatan veri üretim sürecinin aşağıdaki genel formdan geldiği varsayılır.

$$y_t = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.6)$$

Burada y_t ve ε_t sırasıyla t zamanındaki gerçek değeri ve rassal hatayı, ϕ_i ($i = 1, 2, \dots, p$) ve θ_j ($j = 1, 2, \dots, q$) model parametrelerini göstermektedir. p ve q tamsayıları model derecesine karşılık gelmektedir. ε_t rassal hatasının, ortalaması 0 ve sabit σ^2 varyansına sahip olduğu varsayılır.

Yukarıdaki eşitlik, ARIMA model ailesinin bazı önemli özel durumlarını içermektedir. Eğer $q = 0$ ise, eşitlik p dereceden saf otoregresif model (AR) modeli haline dönüşür. $p = 0$ iken ise, model q dereceden saf hareketli ortalama (MA) modeli olacaktır. ARIMA modelinin önemli aşamalarından biri uygun (p, q) model derecesinin bulunmasıdır.

Box ve Jenkins, zaman serisi analizi ve tahminleme uygulamalarını uzun süre domine etmiş pratik bir yaklaşım geliştirmişlerdir. Box-Jenkins metodolojisi model tanımlama, parametre tahmini ve tanısal kontrol aşamalarından oluşan üç iteratif adımdır. Bu iteratif üç adıma geçmeden önce seri durağan hale getirilmelidir. Eğer seri ortalamada durağan değilse, fark alma işlemleri uygulanır. Varyans değerinde durağan olmama durumu mevcutsa, logaritmik transformasyon işleminden faydalanabilir. Model tanımlama aşamasında, teorik otokorelasyon özellikleri ile deneyden elde edilen otokorelasyon yapıları karşılaştırılarak bir veya birkaç muhtemel model belirlenmeye çalışılır. Box ve Jenkins, örnek verisinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının ARIMA modelinin derecesinin belirlenmesinde temel araç olarak kullanılmasını önermişlerdir. Geçici bir model belirlendikten sonra, hata ölçüsünü minimize eden model parametreleri tahminlenir. Metodolojinin son adımı, model yeterliliğinin tanısal kontrolüdür. Bu aşamada, hatalar üzerindeki model varsayımlarının sağlanıp sağlanmadığının kontrolü yapılır. Bazı tanısal istatistiklere ve artıkların grafiklerine bakılarak geçici modelin iyi uyumu incelenir. Eğer model yeterli değilse, adımların baştan takip edilmesiyle yeni bir geçici modelin saptanmasına çalışılır. Bu noktada, tanısal bilgi alternatif modellerin denenmesi konusunda yararlı olabilir. Üç adımdan oluşan model oluşturma süreci, genellikle tatmin edici bir model seçilinceye kadar birkaç kez tekrarlanır. Bu tez boyunca literatürde olduğu gibi, ARIMA modelleri ve Box-Jenkins modelleri birbirinin yerine geçecek şekilde kullanılmıştır.

2.2.2. Doğrusal Olmayan Metotlar

2.2.2.1. Eşik Otoregresif Modelleri

Eşik otoregresif modelleri, sistemin durumuna bağlı olarak y_t serisinin davranışının/rejiminin değişmesine izin verir. Aşağıda temel eşik modeli verilmiştir.

$$y_t = \begin{cases} a_1 y_{t-1} + \varepsilon_{1t} & , \quad y_{t-1} > 0 \\ a_2 y_{t-1} + \varepsilon_{2t} & , \quad y_{t-1} \leq 0 \end{cases} \quad (2.7)$$

$y_{t-1} = 0$ eşitliği bir eşik olarak düşünülebilir. Eşik değerin her iki yanında farklı otoregresif süreçler tarafından yönlendirilen y_t serisi bulunmaktadır. Her ne kadar eşitlik iki doğrusal süreçten oluşsa da, muhtemel rejim değişimlerinden dolayı y_t serisi doğrusal olmayan yapıya bürünecektir. ε_{1t} veya ε_{2t} terimlerindeki şoklar rejim değişiminin sorumlusu olacaktır.

Eşik otoregresif modelinin yaygın bir diğer şekli, iki hata teriminin varyanslarının eşit olduğu halidir. Bu durumda, aşağıdaki eşitlik tanımlanabilir.

$$y_t = a_1 I_t y_{t-1} + a_2 (1 - I_t) y_{t-1} + \varepsilon_t \quad (2.8)$$

Burada, $y_{t-1} > 0$ ise $I_t = 1$ ve $y_{t-1} \leq 0$ ise $I_t = 0$ 'dir ve yukarıdaki eşitlik sırasıyla $a_1 y_{t-1} + \varepsilon_t$ veya $a_2 y_{t-1} + \varepsilon_t$ haline dönüşür.

2.2.2.2. İkildoğrusal Model

Doğrusal olmayan bir modelde, hareketli ortalama terimlerini kullanmak mümkündür. Aşağıdaki basit örneği ele alalım.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \beta_1 \varepsilon_{t-1} + c_1 \varepsilon_{t-1} y_{t-1} + \varepsilon_t \quad (2.9)$$

Hareketli ortalama ve hareketli ortalamanın otoregresif değişkenle etkileşiminin kullanılmasından gaye, genelleştirilmiş otoregresif modele yakınsamaya çalışılmasıdır. İkildoğrusal model y_{t-i} ve ε_{t-j} terimlerinin capraz çarpımını modele katarak, ARMA modellerinin doğrusal olmayan doğal uzantısı olma konumundadır. İkildoğrusal modelin genel formu şu şekildedir:

$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \varepsilon_t + \sum_{i=1}^q \beta_i \varepsilon_{t-i} + \sum_{i=1}^r \sum_{j=1}^s c_{ij} y_{t-i} \varepsilon_{t-j} \quad (2.10)$$

Dikkat edilirse yukarıdaki eşitliğin içerisinde, doğrusal ARMA(p,q) modeli bulunmaktadır. İkildoğrusal modelin stokastik parametre değişimine sahip olduğunu görmek için aşağıdaki eşitlik incelensin.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + c_1 y_{t-1} \varepsilon_{t-1} + \varepsilon_t \quad (2.11)$$

Buradan,

$$y_t = \alpha_0 + (\alpha_1 + c_1 \varepsilon_{t-1}) y_{t-1} + \varepsilon_t \quad (2.12)$$

Yukarıdaki eşitlik, otoregresif katsayının $\alpha_1 + c_1 \varepsilon_{t-1}$ olması haricinde bir otoregresif model gibi gözükmemektedir. Bir bakıma otoregresif katsayı, ortalaması α_1 'e eşdeğer rassal değişkendir. Eğer c_1 pozitif ise otoregresif katsayı ε_{t-1} kadar yükselecek, böylece pozitif ε_{t-1} şokları negatif şoklardan daha devamlı olacaktır.

2.2.2.3. Yumuşak Geçişli Otoregresif Modeller

Bazı süreçlerde eşik otoregresif modelde olduğu gibi, serinin veri üretim süreci yapısında ani bir yapısal değişimin gerçekleşeceğinin beklenmesi akla yatkın olmayabilir. Yumuşak Geçişli Otoregresif Model (Smooth-transition autoregressive (STAR)), otoregresif parametrelerinin yavaşça değiştirilmesine imkân sağlar. Aşağıdaki doğrusal olmayan otoregresif model ele alınsın.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \beta_1 y_{t-1} f(y_{t-1}) + \varepsilon_t \quad (2.13)$$

Eğer $f(\cdot)$ yumuşak sürekli bir fonksiyon ise, $(\alpha_1 + \beta_1)$ otoregresif katsayısı y_{t-1} değeriyle birlikte yavaşça değişecektir. STAR modelinin otoregresif değişim derecesine farklı olarak karar veren iki yararlı şekli bulunmaktadır. STAR modelinin lojistik versiyonu (LSTAR olarak isimlendirilir) otoregresif modelin katsayıları bir lojistik fonksiyon olacak şekilde düzenleme yapar.

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \theta [\beta_0 + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p}] + \varepsilon_t \quad (2.14)$$

Burada,
$$\theta = [1 + \exp(-\gamma(y_{t-1} - c))]^{-1} \quad (2.15)$$

(2.15) eşitliğindeki γ değeri, yumuşatma parametresi olarak isimlendirilir. $\gamma \rightarrow 0$ veya ∞ giderken LSTAR modeli θ 'nin sabit olması nedeniyle AR(p) modeli haline dönüşür. γ 'nin orta değerlerinde otoregresif değişim seviyesi y_{t-1} 'in değerine bağlı olacaktır. $y_{t-1} \rightarrow -\infty$ giderken $\theta \rightarrow 0$ 'a gidecek ve y_t 'nin davranışı

$\alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t$ tarafından belirlenecektir. Benzer şekilde, $y_{t-1} \rightarrow +\infty$ giderken $\theta \rightarrow 1$ 'e gidecek ve y_t 'nin davranışı $(\alpha_0 + \beta_0) + (\alpha_1 + \beta_1)y_{t-1} + \dots + \varepsilon_t$ tarafından belirlenecektir. Böylece y_{t-1} değişirken, sabit ve otoregresif katsayılar iki uç durum arasında yumuşakça değişecektir.

STAR modelinin üstel formu (ESTAR) yine (2.14) eşitliğini kullanır, ancak θ fonksiyonu aşağıdaki gibidir.

$$\theta = 1 - \exp(-\gamma(y_{t-1} - c))^2 \quad (2.16)$$

Dikkat edilirse, θ fonksiyonu karesel terim içermektedir. Dolayısıyla, ESTAR modelinin katsayıları $y_{t-1} = c$ civarında simetriktir. y_{t-1} , c 'e yaklaşırken θ , 0 'a yaklaşır ve y_t 'nin davranışı $\alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_p y_{t-p} + \varepsilon_t$ tarafından belirlenir. y_{t-1} değeri c 'den uzaklaştıkça θ , 1 'e yaklaşır ve y_t 'nin davranışı $(\alpha_0 + \beta_0) + (\alpha_1 + \beta_1)y_{t-1} + \dots + \varepsilon_t$ tarafından belirlenir. ESTAR modeli, bir serinin dönüm noktalarını içeren periyotlarda daha yararlıdır. $y_{t-1} = c$ civarında simetrik olmasından ötürü, U-sekline daha iyi yakınsayabilir. Ayrıca, ESTAR modeli γ sıfıra veya sonsuza yaklaşırken θ 'nin sabit olmasından dolayı $AR(p)$ haline dönüşür. Diğer durumlarda, doğrusal olmayan davranış gösterir.

2.2.2.4. ARCH Süreci

ARCH (Autoregressive Conditional Heteroskedastic) bir zaman serisinin momentlerinin değişken olduğunu, başka bir ifadeyle hata teriminin ARIMA sürecinde olduğu gibi sıfır ortalama ve sabit varyansa sahip olmadığını varsayar. Hata terimlerinin birbiriyle ilişkileri bulunduğunu ve otoregresif (AR) bir süreç tarafından modellenebileceğini öne sürer. Böylece bir ARCH süreci, zaman serisindeki oynaklığı ölçebilir hale gelecektir.

Engle (1982), bir serinin ortalaması ve varyansının eş zamanlı olarak modellenmesinin mümkün olduğunu göstermiştir. Koşullu varyansın sabit olmadığı varsayılırsa bu durumda uygulanabilecek basit bir strateji, tahminlenen artıkların karelerini kullanan $AR(q)$ süreciyle koşullu varyansın tahmin edilmesidir:

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \alpha_2 \hat{\varepsilon}_{t-2}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-q}^2 + v_t \quad (2.17)$$

Burada, v_t beyaz gürültü sürecidir.

Eğer $\alpha_1, \alpha_2, \dots, \alpha_n$ değerlerinin hepsi sıfırsa tahminlenen varyans sabit α_0 ' dır. Aksi halde y_t serisinin koşullu varyansı, yukarıdaki eşitlik tarafından verilen otoregresif sürece göre biçimlenecektir. Ayrıca artıklar otoregresif süreçten, ARMA sürecinden veya standart regresyon modelinden gelebileceğinden ARCH modellerinin çok sayıda varyasyonu vardır. y_t serisi ve koşullu varyansı en çok olabilirlik tekniklerinin kullanılmasıyla en iyi şekilde tahminlenebildiğinden, (2.17) 'deki doğrusal spesifikasyon çok uygun değildir. Bunun yerine, çarpımsal koşullu değişen varyans modelleri Engle (1982) tarafından önerilmiştir:

$$\varepsilon_t = v_t \sqrt{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \quad (2.18)$$

Burada, $\sigma_v^2 = 1$, v_t ve ε_{t-1} birbirinden bağımsız, α_0 ve α_1 sabitleri $\alpha_0 > 0$ ve $0 \leq \alpha_1 \leq 1$ kısıtları altındayken v_t beyaz gürültü sürecidir. $E v_t^2 = 1$ olduğundan, ε_t 'nin $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots$ üzerindeki koşullu varyansı şu şekildedir:

$$E[\varepsilon_t^2 | \varepsilon_{t-1}, \varepsilon_{t-2}, \dots] = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (2.19)$$

(2.19) eşitliğinde ε_t koşullu varyansı, ε_{t-1}^2 'in gerçekleşen değerine bağlıdır. ε_{t-1}^2 gerçekleşen değer büyükse, t zamanındaki koşullu varyans da büyük olacaktır. Eşitlik (2.18) tarafından verilen ARCH süreci, birkaç farklı şekilde genişletilebilir. Engle orjinal çalışmasında (1982), yüksek dereceli ARCH(q) süreçlerinin tüm sınıfını işin içerisine katmıştır:

$$\varepsilon_t = v_t \sqrt{\alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2} \quad (2.20)$$

Eşitlik (2.20) 'de ε_{t-1} 'den ε_{t-q} 'a kadar tüm şokların ε_t üzerinde etkisi vardır. Bu sayede koşullu varyans q dereceden bir otoregresif süreç gibi davranış gösterir.

2.2.2.5. GARCH Modeli

Bollerslev (1986), Engle 'in çalışmasını koşullu varyansın bir ARMA süreciyle modellenmesine izin verecek şekilde geliştirmiştir. Hata süreci aşağıdaki gibi olsun.

$$\varepsilon_t = v_t \sqrt{h_t} \quad (2.21)$$

Burada, $\sigma_v^2 = 1$ ve

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (2.22)$$

v_t bir beyaz gürültü süreci olduğundan, ε_t 'nin koşullu ve koşulsuz ortalamaları sıfıra eşittir. ε_t 'nin beklenen değerinin alınmasıyla $E\varepsilon_t = Ev_t(h_t)^{1/2} = 0$ ifadesine kolaylıkla ulaşılır. Önemli nokta, ε_t 'nin koşullu varyansının $E_{t-1}\varepsilon_t^2 = h_t$ tarafından elde edilmesidir. Böylece, ε_t 'nin koşullu varyansı eşitlik (2.22) 'deki h_t ifadesinin neden olduğu ARMA süreciyle belirlenir.

GARCH (p,q) modeli olarak isimlendirilen Genelleştirilmiş ARCH(p,q), değişen varyans içerisinde hem otoregresif hem de hareketli ortalama bileşenlerini içerir. Eğer $p = 0$ ve $q = 1$ olarak alınırsa, GARCH(0,1) modelinin eşitlik (2.18) tarafından verilen birinci dereceden ARCH modeli olduğu görülür. Tüm β_i değerleri sıfıra eşitse GARCH(p,q) modeli ARCH(q) modeline eş değerdir. Yüksek dereceli bir ARCH modelinin tespit etmesi ve tahminlemesi çok daha kolay olan, daha sade GARCH modeli gösterimine sahip olabilmesi GARCH modelinin avantajıdır.

2.3. SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİNDE YAPILAN ÇEŞİTLİ ÇALIŞMALAR

Öncelikle belirtilmelidir ki tahminleme problemi çok farklı disiplinleri içine alacak şekilde ortaya çıkabilmektedir ve sinir ağlarını kullanarak yapılan tahminleme çalışmalarının literatürü de çok çeşitli alanlara yayılmıştır. Bu bakımdan, bir araştırmacının sinir ağı tahminlemesi alanında şu ana kadar yapılan tüm

alıřmalardan haberdar olması beklenen bir durum deęildir. Dolayısıyla bu bařlık altında sinir aęları kullanılarak yapılan, nemli bulgulara ulařmıř ve epey atıf alarak arařtırmacıların dikkatini ekmiř bazı alıřmalardan bahsedilmeye alıřılacaktır.

Makridakis ve dięerleri, 1982 yılında gerek 1001 adet farklı alandan ve farklı leklerde alınmıř zaman serileri zerinde basit metotlar ile sıklıkla kullanılan doęrusal tahminleme yntemlerinin tahminleme performanslarını karřılařtırmak zere bir yarıřma dzenlemiřlerdir (M-Competition). Bu yarıřmanın sonucunda elde edilen bulgu, herhangi bir tahminleme metodunun tm durumlarda en iyi olmadıęıdır. Ancak bu alıřmada dikkat edilmesi gereken nokta yarıřmada kullanılan yntemlerin basit ve doęrusal tekniklerden oluřtuęudur. Bařka bir deyiřle deęiřen seviyelerde doęrusal olmama zellięi ieren veri gruplarına, doęrusal istatistiki modellerin iyi bir řekilde yakınsaması beklenen bir durum deęildir. Ayrıca alıřmada, farklı tahminleme yntemlerinin sonularının birleřtirilmesiyle iyi sonular alınabileceęi de gzlemlenmiřtir.

Kang (1991), 7 farklı zaman serisi deseninden tretilmiř simlasyon verisi zerinde 18 eřit mimari oluřturmuř ve gizli katman sayısı, gizli hcre sayısı, girdi hcre sayısı ve eęitim seti hacminin aę performansına etkisini incelemiřtir. Girdi hcre sayısının aę performansını etkileyen en nemli faktr olduęunu ve gizli katman sayısının nemli bir faktr olmadıęını tespit etmiřtir. Kk ve byk eęitim setlerinin performans zerinde anlamlı bir etkisi bulunamamıřtır. Ayrıca veride bulunan periyodu yansıtacak kadar girdi hcrenin sinir aęlarına koyulmasıyla, bir zaman serisindeki mevsimsel desenlerin modellenebileceęi grlmřtir. alıřmanın ikinci ařamasında, tahminleme yarıřmasında da kullanılan Box-Jenkins modeliyle kıyaslamaya uygun 50 gerek veri seti aracılıęıyla tahminleme dnemi uzunluęu ve faydalanılan hata lsne gre inceleme yapmıřtır. Box-Jenkins modellerinin genellikle bařarılı tahminler yapması amacıyla en azından 50 veri noktasına gerek duyduęu, ancak sinir aęı tahmin modellerinin 50 ‘den bile az rnek hacmine sahip veri setlerinde iyi alıřtıęını gstermiřtir. Sinir aęının simlasyon verisi iin performans kriterine byk lde baęımlı olmadıęını, ancak gerek veriler iin doęruluk lsne baęımlılıęının gzktęn iddia etmiřtir. Ele alınan problemde bulunan desenlerin karakteristięinin, tahminlenecek periyot uzunluęu ve kullanılan

hata ölçülerine göre sinir ağı tahmin doğruluğunda daha etkili olduğunu gözlemlemiştir.

Tang ve diğerleri (1991), farklı karmaşıklığa sahip üç zaman serisinde sinir ağları ve Box-Jenkins modelini karşılaştırarak sinir ağlarının tahminleme yeteneğini incelemiş ve uzun hafızaya sahip zaman serilerinde sinir ağlarının Box-Jenkins modeliyle rekabet etmesinin zor olduğunu, kısa hafızaya sahip serilerde sinir ağlarının Box-Jenkins modeline üstünlük kurduğunu tespit edilmiştir. Elde ettikleri diğer sonuçlar ise Box-Jenkins modelinin tahminlerini önceki gözlemlere göre oluşturmasından ötürü kısa dönem tahminlerde daha iyi olduğunu, sinir ağlarının ise altta yatan haritalamaya yaklaşarak tahminlerini oluşturmasından dolayı uzun dönem tahminlerde sinir ağıyla daha iyi sonuçlara ulaşıldığını, serinin karmaşıklığı arttıkça Box-Jenkins modelinin sinir ağına karşı rekabet gücünün azaldığını, sinir ağlarıyla modelleme yaparken veri miktarının artırılmasının performansı olumlu yönde etkilediğini, gizli katmanın kullanılmadığı bir ağın Box-Jenkins modeliyle benzer sonucu verdiğini deneysel olarak göstermiştir.

Sharda ve Patil (1992), sinir ağlarıyla tahminleme alanında çalışmalar yapıldığını ancak kesin bir sonuca varılamadığını belirlemiştir. Çeşitli tahminleme tekniklerinin karşılaştırılmasında faydalanan farklı alanlardan gelen ve farklı frekanslar içeren (aylık, çeyreklik, yıllık) yetmiş beş seri üzerinde, sinir ağıyla Box-Jenkins otomatik tahminleme uzman sistemi arasında tahminleme yarışması düzenlemiştir. Uzun hafızaya sahip zaman serilerinde, kısa dönem tahminleme için Box-Jenkins modelleri çok az daha iyi iken, Box-Jenkins ve sinir ağlarının benzer performans göstermiş olduğunu gözlemlemişlerdir. Kısa hafızaya sahip serilerde, sinir ağları Box-Jenkins yönteminden daha iyi performans göstermiştir. Ayrıca eğitim prosedürü ve ağ mimarisinin tahminleme performansı üzerinde çok büyük bir etkisinin olduğuna kanaat getirmişlerdir.

Hill ve diğerleri (1996), M-Competition 'da kullanılan ve göreceli olarak başarı sağlamış 6 tane istatistiksel zaman serisi metodunun tahminleri ile sinir ağlarını karşılaştırmışlardır. Kullanılan verinin frekansı (yıllık, çeyreklik, aylık), doğrusal ve doğrusal olmayan aynı zamanda kesiklilik taşıyan ve taşımayan şeklinde dört farklı desenden oluşan veri seti, tahmin edilecek dönemin uzunluğunun artarken tahminleme performansları ve gözlem sayısı hacminin etkisi kriterlerine göre sinir

ağlarını ve klasik tahminleme yöntemlerini karşılaştırarak, sinir ağlarının hangi durumlarda daha iyi performans verdiğini belirlemeye çalışmışlardır. Buldukları sonuçlar, sinir ağlarının yıllık verilerde değil ancak çeyreklik ve aylık frekansa sahip verilerde klasik metotlardan anlamlı derecede iyi performans gösterdikleri, özellikle süreklilik göstermeyen zaman serilerinde iyi çalıştıkları aynı zamanda doğrusal veri grubunu da modelleyebildiği, tahmin edilecek dönemin uzunluğu arttıkça performansın klasik yöntemlere göre daha iyileştiği ve doğrusal verilerde veri sayısının bir etkisinin bulunmadığı ancak doğrusal olmayan veri setlerinde veri hacmi küçükken klasik yöntemlere göre daha iyi sonuçlar elde edildiği, veri hacmi daha büyük olan veri setlerinde ise olumlu bir etkinin yakalanmadığını belirtmişlerdir. Son olarak ise kullandıkları karşılaştırma tahminleme metotlarına göre, sinir ağlarının ürettikleri tahmin hata varyanslarının her zaman daha küçük olduğudur.

Hansen ve diğerleri (1999), Box ve Jenkins 'in ARIMA yöntemini tanımladıkları orijinal çalışmasında (1970) kullandıkları altı zaman serisi üzerinde sinir ağı modelleri kurmuşlardır. Ayrıca aynı veri setleri üzerinde, normal olmayacak şekilde dağılmış hatalar için ARIMA üzerinde düzenleme yapabilmeyi sağlayan McDonald ve Xu (1994) 'nın uyguladıkları kısmi uyarlamalı tahminleme tekniğinden (apply partially adaptive estimation techniques) faydalanarak elde edilen tahminlerin performanslarını karşılaştırmışlardır. ARIMA yöntemi üzerinde bu şekilde iyileştirmeler yapılmasıyla standart yöntemle göre, %8 ile %13 arasında performans iyileşmesi görülmüştür. Ancak özellikle ağ parametrelerinin genetik algoritmalar tarafından belirlendiği sinir ağı modelindeki performans artışları, %10 ile %40 arasında değişmiştir.

Nelson ve diğerleri (1999), M-Competition 'dan 68 aylık zaman serisini alarak, mevsimsellikten arındırma işleminin sinir ağına yarattığı etkiyi incelemeye çalışmışlardır. Aynı serinin mevsimsellikten arındırılmış ve arındırılmamış hali üzerine sinir ağı kurup bunların performanslarını karşılaştırarak, bir bakıma deneysel olarak sinir ağının mevsimselliği öğrenip öğrenemediğini test etmişlerdir. Buldukları sonuç sinir ağlarının mevsimselliği öğrenemediği, mevsimselliğin söz konusu olduğu serilerde mevsimsellikten arındırılmış verilerle yapılan sinir ağı tahminlerinin

mevsimsellikten arındırılmamış verileri kullanarak üretilen sinir ağı tahminlerine göre anlamlı derecede daha doğru sonuçlar ürettiğidir.

Hu ve diğerleri (1999), haftalık dolar (USD)/ pound(BP) döviz kuru verisini kullanarak 1, 6 ve 12 aylık verilerden oluşan test seti üzerinde tahminlemeler yapmış ve eğitimde faydalanılan veri hacminin tahmin sonuçları üzerinde etkisini incelemişlerdir. Ayrıca elde ettikleri sonuçları, dört farklı değerlendirme kriterine dayanarak rassal yürüyüş modeliyle karşılaştırmışlardır. Sinir ağı tahminlerinin örnek hacmi küçükken bile doğru olduğunu, kısa, orta ve uzun dönem olarak sayılabilecek test veri hacimlerinde rassal yürüyüş modeline göre daha direnç sergilediğini ancak uzun dönemde rassal yürüyüş modelinden istatistiki olarak farkın bulunmadığını, özellikle kısa dönem test seti hacminde rassal yürüyüş modelinden iyi olduğunu, uzun dönem test seti hacminde modeli oluştururken daha fazla veri kullanılmasının tahmin doğruluğunda iyileşme sağlayabileceğini, faydalanılan dört performans ölçüsüne göre sinir ağlarının dirençli olduğunu rapor etmişlerdir.

Zhang (2001), sinir ağlarının doğrusal olmayan problemlere yakınsamadaki becerisinin hem teoriksel olarak ispatlandığını hem de yapılan birçok doğrusal olmayan zaman serisi uygulamasıyla da bunun deneysel olarak da desteklendiğini belirtmiştir. Ancak gerçek bir problemin altta yatan veri üretim sürecinin doğrusal olup olmadığının belirlenmesinin kolay bir iş olmadığını vurgulamıştır. Her ne kadar bazı doğrusal olmayan testler mevcut olsa da, bu testlerin doğrusal olmayan desenlerin özel formlarına karşı geliştirildiğini ve bilinmeyen doğrusal olmayan ilişkileri tespit edecek genel bir yeteneklerinin olmadığına değinmiştir. Ayrıca neredeyse tüm gerçek verilerin rassal hata veya gürültü içerdiğini, böylece klasik doğrusal metotların varsayımlarının gerçekte veri doğrusal bir süreçten gelse bile karşılanamayabileceğini ve yanlış tahminlerin üretilebileceğini söylemiştir. Yaptığı çalışmayla sinir ağlarının doğrusal zaman serilerini modelleme ve tahminlemedeki doğruluğunu araştırmak istemiş ve bu amaç için hem gerçek hem simülasyon verilerini kullanmıştır. Bulduğu sonuç, sinir ağlarının çeşitli şekillere sahip doğrusal zaman serilerini tahminleme ve modellemede oldukça yetenekli olduğu ve özellikle basit ağ yapılarının sıklıkla iyi sonuçlar verdiğidir.

Zhang ve Qi (2005), mevsimsellik ve trendden arındırılmış veriyle ve ham veri üzerinde hem simülasyon hem de gerçek serilerle sinir ağı modelleri kurarak, bu

iki klasik zaman serisi veri işleme yönteminin sinir ağı performansı üzerinde etkisini incelemişlerdir. Ayrıca elde ettikleri sonuçları mevsimsel ARIMA modeliyle kıyaslamışlardır. Toplamda 10 gerçek zaman serisi ve bir simülasyon verisiyle yapılan modellemeler sonucunda, hem mevsimsellik hem de trendden arındırılmış veri üzerine kurulan sinir ağlarının kök ortalama karesel hata (RMSE), MAE ve ortalama mutlak yüzdesel hata (MAPE) değerlendirme kriterlerinin tümünde ham verilerle, sadece trendden arındırılmış verilerle ve sadece mevsimsellikten arındırılmış verilerle kurulan sinir ağlarından daha iyi olduğunu gözlemlemişlerdir. Diğer bir bulgu, sinir ağlarının ham verilerdeki trendi ve mevsimselliği modelleyemediği, veri ön işlemin gerekli olduğu ve bu süreçten geçmiş veriler üzerinde kurulan sinir ağlarının mevsimsel ARIMA modeline göre daha yüksek tahmin doğruluğuna ulaştığıdır. Benzer bir çalışma, Jain ve Kumar (2007) tarafından yürütülmüştür. Ham veri, trendden arındırılmış veri ve hem trendden hem de mevsimsellikten arındırılmış veriler üzerinde dört tip otoregresif, dört tipte sinir ağı modeli kurmuşlardır. Bir zaman serisindeki uzun dönem ve mevsimsel değişimlerin ortadan kaldırılmasıyla elde edilen filtrelenmiş veriye dayanarak en iyi tahmin sonuçlarının elde edildiği ve sinir ağlarının otoregresif modellerden inceledikleri veri setinde daha üstün olduğunu rapor etmişlerdir.

Sinir ağlarının her zaman klasik istatistiksel yöntemlere göre daha iyi sonuçlar vermediğini göstermek adına, bu iddiayı destekleyen sonuçlara ulaşan bazı çalışmalardan bahsetmek gerekirse: Foster ve diğerleri (1992) küçük hacimli ve gürültüye sahip 384 ekonomik ve demografik zaman serisi üzerinde, sinir ağlarını doğrusal regresyon ve altı üstel düzeltme metodunun ortalaması ile karşılaştırmışlardır. Bu çeşit kısmen stokastik serilerde sinir ağlarının doğrusal regresyona göre anlamlı derecede daha az doğru tahminler verdiği, mevsimsel değişkenliğin ortadan kaldırılmasıyla sinir ağı tahmin doğruluğunun geliştiğini ancak üstel düzeltme metodlarının ortalamasından bile hala daha düşük performans verdiğini bulmuşlardır. Ayrıca sinir ağlarını klasik yöntemlerin tahminlerini birleştirmede de kullanmışlar ve küçükte olsa anlamlı bir performans iyileşmesine ulaşmışlardır. Brace ve diğerleri (1991), sinir ağlarının performansının elektrik yük tahminlemede yaygın olarak kullanılan birçok istatistiksel metotlar kadar iyi olmadığını tespit etmişlerdir. Ancak aynı çalışmada sinir ağlarının yürüttükleri

performans yarışmasında başarılı olmamasının sebebi olarak, sinir ağlarının yeteneksizliği yerine sinir ağı geliştiricilerinin yeterli tahminleme tecrübesine sahip olmamasından kaynaklanabileceğini ifade etmişlerdir. Gorr ve diğerleri (1994) öğrenci not ortalamalarını tahminlemede sinir ağlarının doğrusal modellere göre önemli bir üstünlüğe sahip olduğunu bulamamışlardır. Callen ve diğerleri (1996), New York menkul kıymetler borsasında işlem gören 296 kurumun 89 veri noktasından oluşan çeyrek dönemlik muhasebe kazançlarını sinir ağlarıyla tahminlemişlerdir. Elde ettikleri sonuç, sinir ağlarının veriler doğrusal olmayan, mevsimsel ve finansal yapıda olsa bile doğrusal zaman serisi modellerine üstün olması gerekmediğidir.

Heravi ve diğerleri (2004), ekonomik zaman serilerinde AR ve sinir ağı performansını karşılaştırmak üzere Almanya, Fransa ve Birleşik Krallık 'ın önemli sektörlerinin endüstriyel üretimlerinin aylık bazda yıllık büyüme oranlarını tahminlemek amacıyla 24 seriden yararlanmışlardır. Mevsimsel düzenlemenin uygulanmadığı veriler kullanmışlardır. Bunun nedenini, mevsimsel düzenlemenin doğrusal olmayan bir filtreleme olduğunu ve bu filtreleme işlemin neden olabileceği doğrusal olmayan yapıdan (veya mevsimsel düzenlemenin ortadan kaldıracabileceği doğrusal olmayan yapıdan) kaçınılmaya çalışılması olarak açıklamışlardır. Ayrıca, 5 farklı doğrusal olmama testi uygulayarak inceledikleri serilerdeki doğrusal olmayan yapıları tespit etmeye çalışmışlardır. Örnek içi Bayesian bilgi kriteri (BIC) değerini kullanarak en iyi modeli seçmişlerdir. Performans ölçüsü olarak RMSE alındığında, incelenen 24 serinin sadece 5 'inde sinir ağları doğrusal modelden daha düşük RMSE üretebilmiştir. Yön doğruluğunun performans ölçüsü olarak alınması durumunda ise sinir ağları doğrusal yöntemden belirgin şekilde daha iyi sonuçlar vermiştir. Doğrusal olmayan test sonuçlarının sinir ağı modelleri için örnek dışı tahmin doğruluğunu belirlemede, güvenilir bir yol gösterici olmadığı ortaya çıkmıştır. Test sonuçlarına göre, doğrusal olmayan yapı tespit edilen serilerde sinir ağı performansının doğrusal yöntemden daha iyi olduğuna dair delil bulunamamıştır.

Literatürde birbirinden farklı sonuçlar elde edilmesinin nedenini tespit etmek epey zor olsa da sinir ağını etkileyen çok sayıda faktörün olması ve ortada uzlaşmış bir metodoloji olmaması sebebiyle kullanılan araştırma metotlarının birbiriyle uyumlu olmaması, bu durumun en büyük nedenlerinden birisi olabilir. Dolayısıyla

yukarıdaki araştırma bulgularını genelleştirirken dikkatli olmak gerekir. Bu bulgular sınırlı sayıda veri setine ve keyfi olarak seçilmiş mimarilere dayanabilmektedir. Bunun yanı sıra, test setinin hacmi tahmin dönemi uzunluğunu göstermesi bakımından bir etki yaratabilme özelliğine sahiptir ve kullanılan doğruluk ölçüsü de tekniklerin karşılaştırılmasına etki eden bir diğer faktör olabilmektedir. Tespit edilen çoğu bulgunun istatistiksel analize dayandırılmaması, bulguların geçerliliği konusunda şüphelerin ortaya çıkmasına neden olabilmektedir. Ayrıca sinir ağlarının doğrusal istatistiksel modellerden daha kötü veya eş değer performans göstermesinin sebebi, verinin çok fazla karışıklığa uğramamış bir doğrusal yapı içermesi ve ağın performansını etkileyen çok sayıda faktörün etkisiyle ideale yakın ağın kurulamamış olmasıyla da açıklanabilir.

2.4. SİNİR AĞI ÇEŞİTLERİ VE KULLANILAN ALGORİTMALAR

1980 'lerden beri çok farklı sinir ağı modelleri önerilmiştir. Belki de en etkili modeller Çok Katmanlı Algılayıcı (Multi-Layer Perceptrons), Hopfield ağları ve Kohonen Kendini Düzenleyen (Kohonen's Self Organizing Networks) ağlardır. Hopfield (1982) çağrışımlı bir bellek gibi çalışan yinmeli bir sinir ağı (Reccurrent Neural Newtork) önermiştir. Çağrışımlı belleğe sahip ağ, incelenen örneğin bir kısmından veya çarpıtılmış, bozulmuş versiyonundan hatırlayabilme yeteneğine sahiptir. Hopfield ağları tüm hücrelerin birbirine bağlandığı katmansız bir ağ türüdür. Bu ağ türünde, ağın çıktılarının girdilerin bir fonksiyonu olması gerekliliği bulunmamaktadır. Çıktılar iteratif bir sürecin denge durumunu temsil etmektedirler. Kohonen özellik haritaları (Kohonen's feature maps, 1982), insan beyninin kendini düzenleme ve organize edebilme yeteneğinden esinlenerek geliştirilmiştir. Bu çalışmada özellikle tahminlemedeki girdi-çıkı eşlemedeki başarısı sebebiyle Çok Katmanlı Algılayıcı ağı kullanılarak açıklamalar ve uygulama yapılacaktır. Ayrıca bilinmelidir ki Radyal Tabanlı Fonksiyon Ağları (Radial-Basis Functions Networks), Tepe Çokterimli Ağlar (Ridge Polynomial Networks), Dalgacık Ağları (Walvelet Networks) gibi fonksiyon yakınsama yeteneklerinden dolayı bazı uygulamalarda oldukça fayda sağlamış ağ türleri de bulunmaktadır (Zhang ve diğerleri, 1998: 35).

Sinir ağı modeli parametrelerinde (bağlantı ağırlıkları) doğrusal olmadığından doğrusal olmayan arama algoritmalarının kullanılması gereklidir. Tüm sinir ağı algoritmaları parametrelerine rassal olarak seçilmiş değerler atayarak başlatılır. Bu değerlerin iyi bir şekilde çalışmaması muhtemeldir, fakat her gözlem için bir hata değerinin hesaplanmasına imkân verirler. Böylece, model hataları daha küçük yapılacak şekilde bu parametre değerleri değiştirilir. Eğitim algoritması hataların minimize edecek bağlantı ağırlıklarını bulmaya çalıştığından, aslında kısıtsız doğrusal olmayan bir minimizasyon problemidir. Bu amaç için çok farklı optimizasyon metotlarının bulunması, sinir ağı eğitiminde çok çeşitli algoritmaların kullanılmasını beraberinde getirmektedir. Hemen söylenmelidir ki, genel bir doğrusal olmayan optimizasyon probleminin makul bir zaman içerisinde global çözümü bulunduğunu garanti eden bir algoritma bulunmamaktadır. Parametrelerin değiştirilmesi için önceleri en dik iniş metoduna dayanan klasik geri yayılım algoritması kullanılmıştır ve hala da kullanılmaktadır. Her ne kadar bu metot çoğu problem için çalışsa da, oldukça yavaştır ve tahminlemede kullanılan basit modeller için kullanışsızdır. Klasik geri yayılım algoritması ağırlıkların değişim büyüklüğünü belirleyen öğrenme oranının seçimine karşı oldukça duyarlıdır. Küçük öğrenme oranları eğitimi yavaşlatırken daha büyük öğrenme oranları ise ağırlık uzayında salınımına neden olur. Klasik geri yayılım algoritmasının bu dezavantajını ortadan kaldırmak amacıyla hızlandırıcı parametresiyle gelecek ağırlık değişiminin bir önceki değişimle daha fazla veya daha az aynı yönde olması sağlanarak, büyük öğrenme oranının salınım etkisi azaltılır. Çoğu araştırmacı klasik geri yayılım algoritmasına hızlandırıcı parametresi adapte ederek kullanır. Ancak öğrenme oranı ve hızlandırıcı parametresi 0 ve 1 arasındaki herhangi bir değeri alabilir ve bu parametrelerin kapsamlı araştırmasının yapılması oldukça güçtür. Sadece seçilen bazı değerleri araştırmacılar tarafından incelenmiştir. Klasik geri yayılım algoritmasının dezavantaj noktaları göz önüne alınarak, algoritma üzerinde bazı varyasyon ve değişikliklere gidilmiştir. Bunlar arasında Levenberg-Marquardt, quasi-Newton gibi ikinci dereceden metotlar daha etkin, dirençli ve iyi bir yerel minimumu bulma yetenekleriyle sinir ağı eğitiminde çekici konuma gelmiştir. Tahminleme problemleri için bir doğrusal olmayan en küçük kareler algoritması olan, Levenberg-Marquardt metodundan sıklıkla faydalanılır. Bu algoritma ARIMA, üstel düzeltme ve doğrusal

olmayan regresyon modellerini tahminlemek için kullanılan algoritmayla aynıdır (McMenamin, 1997: 19). Belirtilmelidir ki evrimsel algoritmalar, benzetim tavlama yöntemi gibi oldukça değişik ve yeni tür optimizasyon algoritmalarından da sinir ağı eğitiminde faydalanılmaktadır.

2.5. SİNİR AĞLARININ KLASİK YÖNTEMLERLE BENZERLİKLERİ

Ağa belli seviyede doğrusal olmamayı kazandıran transfer fonksiyonun bir diğer adı aktivasyon fonksiyonudur ve bir hücrenin ve ağı girdi ve çıktıları arasındaki ilişkiyi belirler. Teoride herhangi bir türevi alınabilir fonksiyon, transfer fonksiyonu olarak nitelendirilebilir. Chen ve Chen (1995: 6) bir sürekli fonksiyonun aktivasyon fonksiyonu olarak nitelenmesi için genel koşulları tanımlamıştır. Uygulamada en popüler lojistik transfer fonksiyon olmak üzere, sıklıkla kullanılan fonksiyonlar aşağıda verilmiştir.

1. Sigmoid (Lojistik) fonksiyonu

$$f(x) = (1 + \exp(-x))^{-1}$$

2. Hiperbolik tanjant (tanh) fonksiyon

$$f(x) = (\exp(x) - \exp(-x)) / (\exp(x) + \exp(-x))$$

3. Sinus veya cosinus fonksiyonu

$$f(x) = \sin(x) \quad \text{veya} \quad f(x) = \cos(x)$$

4. Doğrusal fonksiyon

$$f(x) = x$$

Çıktı katmanında doğrusal olmayan bir fonksiyonda kullanılabilir ve bu durum desen tanımlamayı içeren birçok sinir ağı problemlerinde uygulanmıştır. Dikkat edilmesi gereken nokta, çıktı katmanındaki hücrelerde lojistik veya hiperbolik tanjant fonksiyonu gibi belli bir aralığa sıkıştırılmış (sırasıyla 0 ve 1, 1 ve -1) doğrusal olmayan transfer fonksiyonları kullanılırsa, hedef değerlerinin ağı çıktı değerleriyle eşleştirilebilmesi için aynı dönüşüme maruz bırakılmaları gerekir. Ancak sürekli çıktı değişkenine sahip çoğu tahminleme probleminde zaten gizli katmanda

doğrusal olmayan fonksiyonlar kullanıldığından, artık çıktı katmanında doğrusal olmayan bir fonksiyon kullanılmasının faydası yoktur. Dolayısıyla çıktı katmanında tahminleme problemi için doğrusal fonksiyon kullanılır. Bu durum basit olmasının yanı sıra yararlıdır. Önemli bir nokta, çıktı katmanında doğrusal olmayan transfer fonksiyonları olan bir ileri beslemeli çok katmanlı ağın trend içeren bir zaman serisini modelleyemeyeceğidir (Cottrell ve diğerleri, 1995: 1355). Bu çeşit sinir ağları için verilerin önce farklarının alınarak trenden ayrıştırma yapılması fayda sağlar (Zhang ve Qi, 2005: 501).

Tek katmanlı sinir ağları, basit desenleri benzer çıktı desenleriyle esleyebilmelerine ve çeşitli uygulamalar için yararlı da olabilmelerine karşın daha önce görmediği desenlerde iyi bir performans sergileyemez, başka bir deyişle genelleme yapamazlar. Buna karşın, gizli hücrelerin oluşturduğu gizli katman veya katmalara sahip ağ içsel gösterimler geliştirme yeteneğine sahiptir. Bu gizli hücreler ham gözlemlerin yüksek seviyeli özelliklerini birleştirebildiklerinden, özellik tespit ediciler olarak da adlandırılmaktadırlar. Gizli hücrelerin bu özelliği sayesinde ağ genelleme yapabilme yeteneği kazanmakta ve çeşitli desenleri tanıyabilmektedir.

Tek katmanlı bir sinir ağının girdi vektörü $\mathbf{x} = (x_1, x_2, \dots, x_n)$ şeklinde, ele alınan problemin özellik değerlerinden ve çıktı katmanı da bir hücreden oluşan $y = g(\mathbf{x})$ skalerinden oluşsun. Şimdi bu başlık altındaki açıklamaların geri kalanında tek çıktı hücresinin, β_i , $i = 0, \dots, n$ tarafından temsil edilen bağlantı ağırlıklarının ve doğrusal transfer fonksiyonunun olduğunu varsayalım. Bu durum şöyle ifade edilebilir:

$$y = g(\mathbf{x}) = \sum \beta_i x_i \quad (2.23)$$

Böylece bilindik doğrusal regresyon modelinin, doğrusal transfer fonksiyonuna sahip tek katmanlı sinir ağına şeklen benzer olduğu görülür.

Doğrusal diskriminant transfer fonksiyonuna sahip tek katmanlı bir sinir ağında, hücreler θ_0 gibi bir eşik değere ulaşınca kadar aktivite edilmezler. Bunu aşağıdaki eşitlikle açıklamak gerekirse:

$$y = F(\sum \beta_i x_i) \quad (2.24)$$

Burada $\sum \beta_i x_i > \theta_0$ olduğunda $F = 1$ 'dir aksi durumda $F = 0$ 'dır. F transfer fonksiyonu herhangi bir sürekli, azalmayan fonksiyon olabileceğinden, F kümülatif dağılım frekansını temsil edebilir. Eğer F fonksiyonu, normal kümülatif dağılım fonksiyonu ise $F(\sum \beta_i x_i)$ değeri probit modelden türemiş bir Bernoulli rassal değişkeninin koşullu beklentisidir. Eğer F lojistik kümülatif dağılım fonksiyonu ise, $F(\sum \beta_i x_i)$ değeri lojistik modelden türetilmiş koşullu beklentidir. Böylece tek katmanlı sinir ağında, ağ çıktı fonksiyonu bilindik lojit ve probit regresyon modelleriyle karşılaştırılabilir.

Şimdi çok katmanlı sinir ağına geri dönüp ve tek çıktı hücrelerine, k tane gizli katman hücrelerinden oluşan tek bir gizli katmanın ve n tane girdi hücrelerinin olduğu ileri beslemeli sinir ağını ele alalım. Herhangi bir gizli katman hücresi, tüm girdilerin ağırlıklandırılmış toplamını ve sapma (bias) terimini alıp bir çıktı sinyali üretir:

$$m_j = f\left(\sum w_{ij} x_i\right) \quad j = 1, \dots, k \quad i = 0, \dots, n \quad (2.25)$$

Burada transfer fonksiyonu f , i . girdi sinyalini x_i , i .girdi hücrelerinden j .gizli katman hücrelerine bağlantı kuvvetini w_{ij} ile gösterilmiştir. Gizli katman hücrelerinin aktivasyon düzeyleri çıktı katman hücrelerine aynı şekilde transfer edilir. Çıktı hücrelerini gizli katman hücreleri çıktıların ağırlıklı toplamı olarak görüp, aşağıdaki eşitlikteki sinyali ürettiğini söyleyebiliriz.

$$y = F\left(\sum v_j f\left(\sum w_{ij} x_i\right)\right) = g(\mathbf{x}, \boldsymbol{\theta}) \quad (2.26)$$

Bu eşitlikte girdi vektörü $\mathbf{x}$, ağ ağırlık vektörü $\boldsymbol{\theta}$ 'dır. Yukarıdaki son eşitliği, tek gizli katmana sahip ileri beslemeli sinir ağını temsil eden doğrusal olmayan regresyon fonksiyonu olarak yorumlayabiliriz (Salchenberger ve diğerleri, 1992: 899). Aynı akıl yürütmeye, eğer girdi vektörü bir zaman serisinin geçmiş değerlerinden oluşuyor ve zaman serisindeki bir sonraki dönemi tahmin etmeye çalıştığımızı varsaydığımızda, bu ileri beslemeli sinir ağını doğrusal olmayan otoregresif regresyon fonksiyonu olarak yorumlamak mümkündür.

2.6. DİNAMİK AĞLAR

Sinir ağları, dinamik ve statik kategoriler olmak üzere iki sınıfa ayrılabilir. Statik ağlar geri besleme elemanı ve mevcut girdi değerinin gecikmesini içermezler. Çıktı, ileri beslemeli bağlantılar aracılığıyla girdi üzerinden hesaplanır. Dinamik ağlarda çıktı sadece ağın mevcut girdisine bağlı değil, aynı zamanda mevcut girdinin gecikmeli değerlerine ve ağın çıktı değerine bağlıdır. Dinamik ağların statik ağlara göre eğitilmesi daha çok zaman alır ve dinamik ağların hata yüzeyleri daha karmaşık olabilmektedir. Dolayısıyla yerel minimuma takılma durumu daha muhtemeldir, optimal sonuca ulaşmaya kadar ağın birkaç kez çalıştırılarak eğitilmesine ihtiyaç duyulabilir (Beale ve diğerleri, 2012: 96). Dinamik ağların eğitilmesi statik ileri beslemeli ağların eğitimine oldukça benzerdir. Ana farklılık tasarım sürecinde ortaya çıkmaktadır, çünkü dinamik ağın girdileri zaman dizisi şeklindedir. Dinamik ağlar da sadece ileri beslemeli bağlantıları olan ağlar ve geri beslemeli veya yinemeli bağlantıları olan ağlar şeklinde iki gruba ayrılmaktadır. Bu çalışmada sadece ileri beslemeli bağlantıları olan ağ türü üzerinde çalışılmıştır.

2.6.1. Zaman Gecikmeli Sinir Ağları

Bir dinamik sistemin t veya t 'den daha küçük zaman dilimindeki gözlenmiş verileri verilmişse tahminleme problemi, y dinamik sistemi ve p geleceğe yönelik tahmin adımını temsil ederken $y(t+p)$ 'yi tahmin etmek için gözlem verilerini kullanmaktır. Zaman serisi tahmininde, Zaman Gecikmeli Sinir Ağları (Time-Delay Neural Networks) tarafından yapılan temel işlem türü budur. Aşağıdaki Şekil 6 $\{y(t), y(t-1), y(t-2), \dots, y(t-n)\}$ sonlu zaman serisinin tek çıktıdan oluşan y ile nasıl eşleştirildiğini göstermektedir. Bu mimarinin kolay bir şekilde x veya y 'nin vektör olduğu durum için genellemesi yapılabilir.


Girdi birimleri, zaman gecikmeli $(y_{t-\Delta}, y_{t-2\Delta}, \dots, y_{t-(m-1)\Delta}, y_{t-m\Delta})$ vektörünü temsil etmektedir. Burada; t zamanındaki gözlemi y_t , bu çalışmada 1 olarak alınacak zaman gecikmesini Δ , altta yatan sistemin dinamiklerinin görüldüğü durum uzayının boyutu m ile gösterilmektedir. y_t serisinin tahminlerini hesaplamak

amacıyla oluşturulan, zaman gecikmeli girdilere sahip ağırlık fonksiyonel formu aşağıdaki eşitlik ile ifade edilebilir:

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-m}) = \varnothing \left(\vartheta_{c0} + \sum_{i=1}^n w_i g \left(w_{ci} + \sum_{j=0}^m w_{ij} y_{t-j} \right) \right) \quad (2.27)$$

Burada; y_{t-j} serinin j zaman önceki gözlemlerini, d modeldeki girdi veya gecikme sayısını, n gizli hücre sayısını, $\{w_{ij}, i = 1, 2, \dots, n, j = 0, 1, \dots, m\}$ girdi hücrelerinden gizli hücrelere olan ağırlık matrisini, $\{w_i, i = 1, 2, \dots, n\}$ i inci gizli hücreden çıktı birimine olan ağırlık vektörünü, g ve $\varnothing$ fonksiyonları ise Faraway ve Chatfield (1998) 'in tahminleme uygulamaları için tavsiyesini dikkate alarak, sırasıyla lojistik ve doğrusal transfer fonksiyonlarını göstermektedir. w_{ci} ve ϑ_{c0} sırasıyla, girdi ve gizli katmanların sabit girdi birimlerini temsil etmektedir.

Şekil 6: Zaman Gecikmeli Ağ Yapısı



Kaynak: Hansen ve diğerleri, 1999: 173.

Yukarıdaki şekle bakıldığında, gizli katmandaki her hücre veya fonksiyonun aynı girdi değerlerini aldığı görülmektedir. Bu durum istatistik eğitimi almış bir kimse için çoklu doğrusal bağlantının özel bir durumu gibi görülebilir. Ancak her fonksiyon aynı girdileri almış olsa da, bu girdiler her fonksiyonun farklı bağlantı ağırlık değerlerine sahip olması sebebiyle farklı bir şekilde işleme sokulurlar. Bu, sinir ağlarının önemli bir silahı olan paralellik özelliğidir. Anahtar nokta, her fonksiyonun farklı parametre değerlerine sahip olacak şekilde tahminleme sürecinin başlatılmasındadır. Böylece, her fonksiyonun parametreleri model uyumunu geliştirmek için değiştirilebilir ve her fonksiyon tahminleme süreci içerisinde farklı bir özellikte uzmanlaşabilir. Ardından bu farklı fonksiyonlar, nihai tahmin modelini elde etmek amacıyla ağırlıklandırılarak birleştirilirler.

Bu çalışmada, ileri beslemeli çok katmanlı sinir ağı kullanılmıştır. Literatürde MLP veya FFN (Multi Layer Perceptron veya Feed Forward Neural network) kısaltmalarıyla da bilinen bu ağ türünün seçilmesinin nedeni, tahminleme çalışmalarında en çok tercih edilen sinir ağı olmasıdır. İleri beslemeli genellikle girdi, gizli ve çıktı hücrelerinin oluşturduğu katmanlardan oluşur. Tek değişkenli zaman serisi problemi için girdi katmanı gecikme değerlerinden, çıktı katmanı ise tahminlenecek değerlerden oluşturulur. Eğer bir adım ileri tahminleme yapılacaksa tek bir çıktı hücresine, ancak birden çok adım ileri tahminlenecekse daha fazla çıktı hücresine ihtiyaç duyulur. Aslında birden çok adım tahminlemesi yapılacaksa iki farklı yol uygulanabilir. İlki iteratif tahminleme olarak adlandırılan Box-Jenkins modelinde olduğu gibi, tahmin değerleri sonraki tahminlenecek değerleri tahminlemek için ağda girdi olarak kullanılırlar. Bu durum için sadece tek bir çıktı hücresi yeterli olmaktadır. Tahminlenecek adım sayısı arttıkça girdi hücrelerinde gözlem değeri yerine tahmin değerleri olacaktır. Aşağıdaki k adım tahminleme eşitliği aracılığıyla iteratif metodun çalışma şekli daha kolay anlaşılabilir.

$$\begin{aligned}
\hat{y}_{t+1} &= f(y_t, y_{t-1}, \dots, y_{t-n}), \\
\hat{y}_{t+2} &= f(\hat{y}_{t+1}, y_t, y_{t-1}, \dots, y_{t-n+1}), \\
\hat{y}_{t+3} &= f(\hat{y}_{t+2}, \hat{y}_{t+1}, y_t, y_{t-1}, \dots, y_{t-n+2}), \\
&\vdots \\
\hat{y}_{t+k} &= f(\hat{y}_{t+k-1}, \hat{y}_{t+k-2}, \dots, \hat{y}_{t+1}, y_t, y_{t-1}, \dots, y_{t-n+k-1}),
\end{aligned} \tag{2.28}$$

Yukarıdaki eşitlikte t zamanındaki gözlem y_t , t zamanındaki tahmin $\hat{y}_t$ ve f ise sinir ağları tarafından tahminlenen fonksiyonu göstermektedir. İkinci yol, doğrudan metot olarak adlandırılır ve çıktı katmanına kaç adım ileri tahmin yapılacaksa, o sayıda çıktı hücresi yerleştirilmesine dayanır. k adım tahminleme doğrudan metot aracılığıyla aşağıdaki gibi yapılır.

$$\begin{aligned}
\hat{y}_{t+1} &= f_1(y_t, y_{t-1}, \dots, y_{t-n}), \\
\hat{y}_{t+2} &= f_2(y_t, y_{t-1}, \dots, y_{t-n}), \\
&\vdots \\
\hat{y}_{t+k} &= f_k(y_t, y_{t-1}, \dots, y_{t-n}),
\end{aligned} \tag{2.29}$$

Burada $f_1, f_2, \dots, f_k$ ağ tarafından belirlenen fonksiyonlardır.

Box-Jenkins yöntemi yoğun bir şekilde gecikme değerleri arasındaki otokorelasyon fonksiyonuna dayanmaktadır. Dikkat edilmelidir ki, otokorelasyon özünde sadece gecikme değerleri arasındaki doğrusal korelasyonu ölçmektedir. Gerçekte otokorelasyon doğrusal olmayabilir ve Box-Jenkins modelleri bu doğrusal olmayan ilişkileri modelleyemeyecektir. Sinir ağları verideki doğrusal olmayan ilişkiyi tespit etmede daha iyidir. Örneğin $x_t = \varepsilon_t + 0.6\varepsilon_{t-1}$ MA(1) modelini ele alalım. t zamanında ε_{t+1} beyaz gürültü değeri tahminlenemeyeceğinden (Dolayısıyla $\varepsilon_{t+1}, 0$ olarak alınırsa) bir adım ileri tahmin $\hat{x}_{t+1} = 0.6(x_t - \hat{x}_t)$ şeklinde olacaktır. Bununla birlikte, t zamanında ε_{t+2} ve ε_{t+1} gelecek gürültü terimleri bilinemeyeceğinden $x_{t+2} = \varepsilon_{t+2} + 0.6\varepsilon_{t+1}$ tahmin edilemez. Böylece optimum tahmin basitçe $\hat{x}_{t+2} = 0$ olacaktır. Benzer şekilde, k adım ileri tahmin $k \geq 3$ için $\hat{x}_{t+k} = 0$ şeklinde gerçekleşecektir. İki veya daha fazla ileri tahmin yapılırken MA(1) serisindeki herhangi bir iki noktanın otokorelasyonu 0 olduğundan, bu sonuçlar beklenir bir durumdur. İki veya daha fazla gecikmeyle ayrılmış gözlemler arasında doğrusal olmayan bir otokorelasyon varsa, Box-Jenkins modelleri bu yapıyı modelleyemezler ve bir adım ileri tahminden daha fazlasını tahminleyemezler. Bu durum yapay sinir ağları için geçerli değildir.

Basit bir şekilde doğrusal olmayan otoregresif model olarak görülebilecek ileri beslemeli ağ, girdi katmanından çıktı katmanına aşağıdaki kapalı fonksiyon eşitliğini uygular.

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}) \quad (2.30)$$

Burada, y_t değeri t zamanındaki gözlem iken p ise y_t değerini tahminlemek için gerekli geçmiş gözlem sayısını veya girdi vektörünün boyutunu göstermektedir. Eğitim setinin $y_1, y_2, \dots, y_N$ şeklinde sıralanmış N gözlemden oluştuğunu ve bir adım öte tahmini yaptığımızı varsayalım. Bu durumda, p gecikmeden oluşan girdi katmanı ve bir çıktı değeri sebebiyle elimizde $N-p$ tane eğitim için gözlem bulunacaktır. İlk eğitim verimizde $y_1, y_2, \dots, y_p$ vektörü girdi ve y_{p+1} hedef değeri olacaktır. İkinci eğitim verimiz ise $y_2, y_3, \dots, y_{p+1}$ girdi vektörü ve y_{p+2} hedef değeri haline

gelecektir. En son eğitim verimizde $y_{N-p}, y_{N-p+1}, \dots, y_{N-1}$ girdi vektörü ve y_N hedef değeri olacaktır. Eğitimin amacı, aşağıdaki karesel hatalar toplamı (SSE) gibi bir tahmin ölçüsünü minimize eden bağlantı ağırlıklarının bulunmasıdır.


$$SSE = \sum_{i=p+1}^n (y_i - a_i)^2 \quad (2.31)$$

Yukarıdaki eşitlikte, a_i ağırlık çıktısını temsil etmektedir.

2.7. MATEMATİKSEL AÇILIMIYLA GERİ YAYILIM ALGORİTMASI

Geri yayılım, gerçek ve ağırlık çıktı değerleri arasındaki global hatayı minimize etmek amacıyla çok boyutlu ağırlık uzayında optimum noktayı arayan bir optimizasyon algoritmasıdır (Lu ve diğerleri, 2001: 299). Bu kısım içerisinde, eğitim iniş yöntemine dayanan geri yayılım algoritmasının matematiksel formüllerinin türetilmesine yer verilmiştir. Kısaltılmış notasyonla üç katmanlı ağ, Şekil 7 'de verilmiştir.

Şekil 7: Kısaltılmış Notasyonla İki Katmanlı Ağ



Ağırlık matrisini $\mathbf{W}$, Şekil 7 'de siyah dikey çubukla ise $\mathbf{p}$ girdi vektörü gösterilmiştir. $\mathbf{p}$ sembolünün altında girdi vektörünün boyutu $R \times 1$ olarak verilmiştir. Sabit 1 değeri nörona bir girdi olarak girmekte ve $\mathbf{b}$ sabit vektörü değeriyle

çarpılmaktadır. f transfer fonksiyonunun net girdisi $\mathbf{n}$, $\mathbf{Wp}$ çarpımı ve sapma $\mathbf{b}'$ nin toplamından oluşmaktadır. Ağırlık çıktısı değeri, $\mathbf{a}$ vektörü tarafından temsil edilmiştir. Matrislerin boyutları matris değişkenlerinin altında gösterilmiştir. Ağırlık matrislerini, çıktı vektörlerini katmanlar bazında ayırt etmek için, ilgili değişkenin ismine katman numarasını gösteren bir üst simge eklenmiştir. Girdi vektörünün elemanları ağırlık matrisi aracılığıyla girer.

$$\mathbf{W} = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \vdots & \vdots & & \vdots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix} \quad (2.32)$$

$\mathbf{W}$ matrisinin elemanlarını gösteren satır indisi ağırlığın varış noktası olan nöronu gösterirken, sütun indisi o nöronu besleyen sinyalin kaynağını göstermektedir. Çok katmanlı ağlarda bir katmanın çıktısı onu takip eden katmanın girdisi olmaktadır.

Algoritmaya doğru ağırlık davranışının aşağıdaki gibi bir örnek setinin verilmesiyle başlanır.

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\} \quad (2.33)$$

Burada $\mathbf{p}_Q$, ağa sunulan girdi ve $\mathbf{t}_Q$ ise ona karşılık gelen hedef çıktı değeridir. Her girdi ağa uygulandıkça, ağırlık çıktısı değeri hedef değer ile karşılaştırılmaktadır. Algoritma, hata karesinin ortalamasını minimize etmek amacıyla ağırlık parametrelerini ayarlamalıdır.

$$F(\mathbf{x}) = E [e^2] = E [(t - a)^2] \quad (2.34)$$

Burada $\mathbf{x}$ ağırlık ve sapmalarının bir vektörüdür. Bunu, ağırlık çoklu çıktıya sahip olması durumuna genelleştirebiliriz.

$$F(\mathbf{x}) = E [\mathbf{e}^T \mathbf{e}] = E [(\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})] \quad (2.35)$$

Anahtar nokta, $F(\mathbf{x})$ ortalama hata karelerin $\hat{F}(\mathbf{x})$ tarafından tahmin edilebilir olmasıdır. (2.35) eşitliğindeki karesel hatanın beklenen değeri, k ıncı iterasyondaki

karesel hata ile yer değiştirmiştir. (2.36) eşitliğiyle hata karesinin ortalamasına yakınsamaya çalışılır.

$$\hat{F}(\mathbf{x}) = (\mathbf{t}(k) - \mathbf{a}(k))^T (\mathbf{t}(k) - \mathbf{a}(k)) = \mathbf{e}^T(k) \mathbf{e}(k) \quad (2.36)$$

Yaklaşık hata kare ortalaması için eğim iniş algoritmasını şöyledir.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (2.37)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (2.38)$$

Burada, α öğrenme oranıdır.

Ardından algoritmanın zor parçası olan kısmi türevlerin hesaplanmasına gerek duyulur. Çok katmanlı ağ durumunda, hata gizli katmandaki ağırlıkların açık bir fonksiyonu değildir, bu yüzden buradaki kısmi türevler kolay bir şekilde hesaplanamamaktadır. Hatanın gizli katmandaki ağırlıkların dolaylı bir fonksiyonu olmasından ötürü türevleri hesaplamak için matematikteki zincir kuralından yararlanılır.

Eşitlik (2.37) ve (2.38) 'daki türevlerin zincir kuralıyla açılımı aşağıdaki gibidir.

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial w_{i,j}^m} \quad (2.39)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial b_i^m} \quad (2.40)$$

Bu eşitliklerdeki ikinci terim m katmanına net girdi, o katmandaki ağırlık ve sapmaların doğrudan bir fonksiyonu olduğu için kolayca hesaplanabilir.

$$n_i^m = \sum_{j=1}^{S^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m \quad (2.41)$$

Böylece;

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1} \quad , \quad \frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (2.42)$$

Şimdi, eşitlik (2.43) tanımını da yapılırsa:

$$s_i^m \equiv \frac{\partial \hat{F}}{\partial n_i^m} \quad (2.43)$$

Eşitlik (2.43) ‘ün anlamı, m inci katmandaki net girdinin i inci elamanındaki değişimlere $\hat{F}$ ‘in duyarlılığıdır. Öyleyse eşitlik (2.39) ve (2.40) ‘ı aşağıdaki şekilde basitleştirebiliriz.

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad (2.44)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m \quad (2.45)$$

Artık, yaklaşık eğim iniş algoritması aşağıdaki gibi ifade edilebilir.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (2.46)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (2.47)$$

Matris formatında yazılırsa,

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{a}^{m-1})^T \quad (2.48)$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m \quad (2.49)$$

Burada;

$$\mathbf{s}^m \equiv \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \begin{bmatrix} \frac{\partial \hat{F}}{\partial n_1^m} \\ \frac{\partial \hat{F}}{\partial n_2^m} \\ \vdots \\ \frac{\partial \hat{F}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.50)$$

Artık, geriye zincir kuralının diğer bir uygulamasını gerektiren $\mathbf{s}^m$ duyarlılıklarının hesaplanması kalmıştır. Geri yayılım ismini ortaya çıkaran bu süreçtir. Çünkü m inci katmandaki duyarlılığı $m+1$ inci katmandaki duyarlılıktan hesaplayan yinelemeli bir ilişkiyi tanımlamaktadır.

Duyarlılıklar için yinelemeli ilişkiyi türetmede aşağıdaki Jacobian matrisinden yararlanılacaktır.

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \equiv \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (2.51)$$

Bu matrisin bir ifadesinin bulunulması amacıyla matrisin i,j inci elemanları ele alınırsa:

$$\begin{aligned} \frac{\partial n_i^{m+1}}{\partial n_j^m} &= \frac{\partial \left(\sum_{l=1}^{s^m} w_{i,l}^{m+1} a_l^m + b_i^{m+1} \right)}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} \\ &= w_{i,j}^{m+1} \frac{\partial f^m(n_j^m)}{\partial n_j^m} = w_{i,j}^{m+1} \dot{f}^m(n_j^m) \end{aligned} \quad (2.52)$$

Burada;

$$\dot{f}^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m} \quad (2.53)$$

Böylece Jacobian matrisi şu şekilde ifade edilebilir:

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \mathbf{W}^{m+1} \dot{\mathbf{F}}^m(\mathbf{n}^m) \quad (2.54)$$

Burada;

$$\dot{\mathbf{F}}^m(\mathbf{n}^m) = \begin{bmatrix} \dot{f}^m(n_1^m) & 0 & \dots & 0 \\ 0 & \dot{f}^m(n_2^m) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \dot{f}^m(n_{s^m}^m) \end{bmatrix} \quad (2.55)$$

Şimdi, matris formunda zincir kuralı kullanılarak duyarlılıklar için yinelemeli ilişki yazılabilir.

$$\begin{aligned} \mathbf{s}^m &= \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \left(\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \right)^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \dot{\mathbf{F}}^m(\mathbf{n}^m) (\mathbf{W}^{m+1})^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} \\ &= \dot{\mathbf{F}}^m(\mathbf{n}^m) (\mathbf{W}^{m+1})^T \mathbf{s}^{m+1} \end{aligned} \quad (2.56)$$

Geri yayılım algoritmasının adının nereden türediği artık görülmektedir. Duyarlılıklar ağıın son katmanından geriye doğru ilk katmanına yayılmaktadır.

$$\mathbf{s}^M \rightarrow \mathbf{s}^{M-1} \rightarrow \dots \rightarrow \mathbf{s}^2 \rightarrow \mathbf{s}^1 \quad (2.57)$$

Geri yayılım algoritmasında zorluk, gradyanların hesaplanması için öncelikle duyarlılıkların geriye doğru yayılması gerekliliğidir. Bu noktada da zincir kuralı etkili bir şekilde kullanılmaktadır.

Geri yayılım algoritmasının tamamlanması için geriye tek bir adım kalmıştır. Eşitlik (2.56) daki yinelemeli ilişki için ihtiyaç duyulan şey, $\mathbf{s}^M$ başlangıç noktasıdır. Bu son katmandan elde edilir:

$$s_i^M = \frac{\partial \hat{F}}{\partial n_i^M} = \frac{\partial (\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})}{\partial n_i^M} = \frac{\partial \sum_{j=1}^{S^M} (t_j - a_j)^2}{\partial n_i^M} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (2.58)$$

Burada;

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial f^M(n_i^M)}{\partial n_i^M} = \dot{f}^M(n_i^M) \quad (2.59)$$

Şu şekilde ifade edilebilir:

$$s_i^M = -2(t_i - a_i) \dot{f}^M(n_i^M) \quad (2.60)$$

Matris notasyonuyla yazarsak,

$$\mathbf{s}^M = -2\dot{\mathbf{F}}^M(\mathbf{n}^M)(\mathbf{t} - \mathbf{a}) \quad (2.61)$$

Böylece geri yayılım algoritmasında kullanılan ağırlık değişimlerinin formülasyonu tanımlanmış oldu. Burada tanımlanan eğim iniş kuralına dayalı geri yayılım algoritmasına temel geri yayılım algoritması denmektedir. Temel geri yayılım algoritması, uygulamalarda hatayı belirli bir seviyenin altına çeken ağırlılık değerlerinin elde ederken oldukça yavaş kalmaktadır. Bu tez kapsamında, işleyişi temel geri yayılım algoritmasına benzer ama daha hızlı olan Levenberg-Marquardt doğrusal olmayan optimizasyon yönteminden faydalanılmıştır. Algoritmanın detayları Hagan ve diğerleri (1996: 12-25) ‘de bulunabilir.

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARINDA MODEL SEÇME SORUNU VE BİR ÖNERİ

3.1. PROBLEM TANIMI VE AMAÇ

Sinir ağlarının evrensel fonksiyon yakınsama özelliği belli bir aralıkta tanımlanmış herhangi bir fonksiyona yakınsamasıyla alakalıdır. Tahminleme açısından bakarsak, altta yatan veri üretim sürecinin oluşturduğu serinin içerisinde çeşitli seviyelerde gürültülerin barınması ve tahminlemeye çalışılan değerin belli aralıkta ağa gösterilmiş serinin dışında kalması, bu özelliğin tahminleme için sınırlı bir değere sahip olduğu çıkarımının yapılmasına yol açabilir. Diğer yandan, teoride ağa keyfi derecede gizli hücre eklenmesiyle herhangi bir fonksiyona yakınsama yeteneği kazandırılmaktadır. Ancak gürültülere sahip olan bir eğitim setine ağın yüksek derecede yakınsaması eğitim setindeki gürültülerin de çok iyi öğrenilmesi veya ezberlenmesi anlamına gelir ki bu durum istatistik diliyle aşırı uyum sağlama problemiyle eş değerdir. Ağın bağlantı ağırlık değerlerine kestirilmeye çalışılan parametreler gözüyle bakılması tıpkı istatistikteki gibi parametre sayısı arttıkça örnek içi performansın yükselip örnek dışı performansın düşmesinin beklenmesine neden olur. Başka bir deyişle, ağdaki hücre sayısının arttırılması parametre sayısını arttıracak ve böylece ağın serinin görmüş olduğu parçası üzerindeki performansı çok iyi olurken serinin görmediği kısımlarında kötü bir performansın elde edilmesine yol açacaktır. Bunun bir sonucu olarak, genelleme yeteneği zayıf olacaktır. Bu durum, sinir ağı hücrelerinin keyfi olarak arttırılmasının neden olabileceği problemi göstermektedir. Dolayısıyla bir ağdaki hücre sayılarının doğruya yakın bir şekilde belirlenmesinin ağın genelleme yeteneğini direkt olarak etkilediğini söyleyebiliriz.

Girdi değişkenlerinin seçimi, ağ mimarisi ve eğitim verisinin miktarı gibi bazı tasarım faktörleri sinir ağı tahminlerinin doğruluğunu yüksek derecede etkilemektedir (Zhang ve diğerleri, 1998: 42). Tang ve diğerleri (1991), sinir ağlarının tahminleme problemleri için umut verici bir alternatif olduğunu ancak etkili öğrenmeyi sağlayacak optimal topoloji ve parametrelerin belirlenmesinde problemler olduğunu belirtmişlerdir. Tang ve Fishwick (1993) sinir ağlarıyla daha iyi

performanslara ulaşılabileceğine ancak model oluşturmada var olan teorik alt yapı ve sistematik prosedür eksikliğinin buna engel olduğunu ifade etmişlerdir. Sinir ağı tahmin modeli geliştirmek için çok sayıda parametreye karar verilmesi gerekliliği, tasarım sürecinin hala birçok deneme ve yanılma içermesini zorunlu kılmaktadır. Dolayısıyla kabul edilebilir bir modele ulaşmadan önce farklı mimari ve parametre değerlerine sahip çok fazla sayıda sinir ağının kurulması gerekir. Bir sinir ağını organize etmede çok fazla sayıda parametreye karar verilmesi aslında sinir ağının güçlü fonksiyon yakınsama yeteneklerinin de sebebi olmaktadır. Bu esnekliğin maliyeti ise araştırmacının parametrelerin doğru kombinasyonunu bulmaya harcadığı zaman ve çabadır. Literatüre baktığımızda, çok az sayıda kesin kural bulunmakla birlikte çok sayıda parmak kuralının veya uygulama tavsiyesinin bulunduğu görülmektedir. Bu parmak kurallarına ilerleyen kısımlar içerisinde değinilecektir. Çoğu çalışma, klasik tahminleme metotlarındaki paradigmalara yoğun bir şekilde bağlı kalarak sinir ağının en önemli özelliklerinden biri olan esnek modelleme yeteneğinin engellenmesine neden olmuşlardır.

YSA çeşitli tahminleme uygulamalarında başarılı bir şekilde kullanılmış olsa da model kurmadaki bazı problemler hala çözülememiştir (Zhang ve diğerleri, 1998: 35). Bu problemlerden birisi uygun yapay sinir ağı mimarisinin nasıl seçileceğidir. En iyi sinir ağı mimarisinin seçilmesinin başarılı bir sinir ağı modellemesinde önemli olduğu bilinmektedir (Hill ve diğerleri, 1996: 1082; Balkin ve Ord 2000: 509). Genellikle fazla sayıda parametrenin tahminlenmesinden ötürü YSA 'nın sıklıkla eğitim verisinin yapısına fazla uyum sağlayarak o verinin kendine has olan özelliklerini veya gürültülerini de öğrenmesi beklenen ve karşılaşılan bir durumdur. Bunun sonucu olarak da örnek içi veya eğitim verisi performansı oldukça iyiysen örnek dışı veya test seti üzerindeki tahminleme performansı zayıf kalacaktır.

Yapılan bir sinir ağı modellemesi sonucunda üretilen her bir çözüm sahip olduğu gizli hücre sayısına bağlı olarak belli bir doğrusal olmama derecesinin ve sahip olduğu girdi hücre sayısına bağlı olarak da belli bir otokorelasyon yapısının etkileşiminin oluşturduğu hata uzayındaki bir noktayı temsil eder. Dolayısıyla farklı girdi ve gizli hücre sayısına sahip her nokta farklı bir fonksiyonel form anlamına gelmektedir. Belli bir çözüm seçilerek aslında belli bir fonksiyonel form seçilmektedir. Bu çözümün sadece doğrulama seti üzerindeki bir minimum hata

kriterine göre seçilmesi, doğrulama seti değişkenliğinin elde edilen performansları etkilemedeki gücü göz önüne alındığında yanlış bir fonksiyonel formun seçilerek sinir ağının gerçek potansiyel gücünden yararlanılamaması olasıdır.

Walczak ve Cerpa (1999), çok sayıda sinir ağı programının ortaya çıkmasıyla sadece ağ mimarisinin belirlenmesi ve eğitim verisinin programa verilmesiyle sinir ağı uygulamalarının kolayca yapılabildiğini ancak bu aşamada dikkat edilmesi gereken dört önemli faktörün var olduğunu, bunların yanlış seçilmesiyle başarısız veya alt-optimal bir sonucun elde edilebileceğini belirtmiştir. Bu dört tasarım faktörünü uygun girdi değişkenleri, öğrenme metodu, gizli katman sayısı ve her gizli katmandaki hücre sayısı olarak sıralamışlardır. Ancak özellikle tahminleme uygulamalarında tek gizli katmana sahip ağın çoğunlukla kullanıldığı ve başarılı sonuçların elde edildiği bilinmektedir (Zhang ve diğerleri, 1998: 44). Gizli katman sayısını arttırmak, modelin parametrelerinin ve dolayısıyla da karmaşıklığının artmasına neden olacaktır. Model karmaşıklığının örnek dışı performansın düşmesine yol açması ise beklenen bir durumdur. Çok çeşitli öğrenme metotları arasında zaman serisi tahminlemesi alanında, gözetmenli öğretime dayanan ileri beslemeli geri yayılım ağ ön plana çıkmış ve yoğun ilgi görmüştür. Dolayısıyla, Walczak ve Cerpa (1999) tarafından ifade edilen dört tasarım faktörünün uygun girdi değişkenlerine ve gizli hücre sayısına indirgenmesi akla yatkındır. Ağın kaç farklı başlangıç ağırlık değeriyle başlatılacağını gösteren deneme sayısı da hesaba katılırsa, sinir ağında model seçim problemini uygun girdi, gizli ve deneme sayısının belirlenmesi olarak görmek mümkündür.

Bu çalışma model seçim problemine yönelik olarak, geri yayılım algoritmasıyla eğitilmiş ileri beslemeli bir sinir ağında bir adım ileri tahmin yapılırken öncelikle girdi ve gizli hücre sayısının seçimi ve ardından seçilen bir girdi-gizli hücre kombinasyonunda ağın başlangıç bağlantı ağırlık değerlerinin farklı seçiminden ortaya çıkan denemeler arasında uygun ağın seçiminin çok kriterli karar verme teknikleri yardımıyla tespit edilmesini önermektedir. Genellikle bir sinir ağı seçiminde kullanılan strateji olan doğrulama setinde en küçük hatayı veren ağın seçimi, model seçim sürecinin veri bağımlı olması anlamını taşımaktadır. Burada önerilen strateji de yine veri bağımlı bir stratejiyken aynı doğrulama seti üzerinde çok sayıda farklı sinir ağı modelinin ortalama performanslarına bakılarak girdi ve

gizli hücreleri sayısının seçimini yapar. Ardından girdi-gizli hücre sayısı belliyken hem eğitim hem de doğrulama seti performanslarına eşanlı bakarak bir ağı seçilmesine ve böylece doğrulama setinin kendine has özelliklerine çok iyi uyum sağlamış bir ağı seçiminden kaçınılmasına dayanmaktadır.

Bu bölüm içerisinde, öncelikle sinir ağlarında model seçimine yönelik olarak yapılan çeşitli çalışmalardan bahsedilecek ve ardından girdi ve gizli hücrelerin tahminlemedeki rolüne ve aşırı uyum sağlama problemine değinilecektir. Son olarak önerilen yaklaşım formüle edilip tanıtılarak, yapılan deney ve bu deneye ait sonuçların ayrıntılı istatistiksel analizi ve tartışmasıyla bu bölüm sonlandırılacaktır.

3.2. SINIR AĞLARINDA EN UYGUN MODELİN SEÇİMİNE YÖNELİK YAPILAN BAZI ÇALIŞMALAR

Sinir ağlarının herhangi bir fonksiyona yakınsama becerisi ilgi çekici bir tahminleme modeli olmasını sağlamaktadır. Ancak bu yetenek çok fazla sayıda parametrenin ayarlanmasıyla kazanılmaktadır. Çok sayıda bağımsız parametrenin bulunması, sinir ağının analiz edilmesi ve yorumlanmasını güçleştirmektedir. Öte yandan doğrusal regresyon modelleri oluşturmak ve yorumlamak çok daha kolaydır. Bu modeller ise karmaşık veri üretim sürecine yaklaşmakta yetersiz kalabilmektedirler. Sinir ağlarını doğrusal regresyon modellerinin uzantısı olarak görmek mümkündür. Gizli hücreleri olmayan ileri beslemeli ağ doğrusal regresyonla aynı işlevi yapmaktadır. Doğrusal regresyonda model seçimi regresyon doğrusunun ağırlıklarının (başka bir deyişle parametrelerinin) doğru şekilde kestirimine indirgenmiştir. Örneklem değişkenliği hakkındaki olağan varsayımlar sağlanmışken iyi yapılanmış istatistiksel teori kullanıcıya her parametrenin önemini test etmesine imkân vermektedir. Dinamik yapı açısından baktığımızda, örneğin Box-Jenkins doğrusal zaman serisi modellerinde model seçimi için iyi bir şekilde tanımlanmış istatistikler mevcuttur. Sinir ağlarını yine doğrusal dinamik zaman serisi modellerinin doğrusal olmayan uzantısı olarak görmek mümkündür. Sinir ağı modelleriyle ilgili problem doğrusallık ve örneklem dağılımı hakkındaki olağan varsayımların çiğnenmesidir. Bu durum, model seçim ve değerlendirmesi için istatistiksel anlamlı testlerin oluşturulmasına yönelik çoğu çabayı

geçersizleştirmektedir. Bu soruna ilişkin bazı adımlar atılmış olsa da dağılımların mevcut olmamasından ötürü başarısız olmuşlardır (Virili ve Freisleben, 2001: 451). Aşağıda sinir ağlarında en iyi modeli belirlemeye yönelik yapılmış bazı çalışmalardan bahsedilmiştir.

Lachtermacher ve Fuller (1995), sinir ağıyla modelleme sürecinin tanımlayıcı genel bir metodolojisinin bulunmamasından ötürü çok zaman aldığını ve yüzlerce gözleme gerek duyduğunu belirtmişlerdir. Ağ hacminin olabildiğince küçük tutan bir modelin seçilmesiyle bu iki problemin üstesinden gelinebileceğini ifade etmişlerdir. Box-Jenkins modelleme aşamasından faydalanarak ağın girdi hücre sayısının belirlenmesine ve sezgisel bir yöntemle de gizli hücre sayısının tespit edilmesine çalışmışlardır. Ayrıca doğrulama seti için sentetik (yapay) zaman serisi kullanarak küçük hacimli zaman serilerinin sinir ağıyla modellenmesi probleminin üstesinden gelmeyi amaçlamışlardır. Önerilerini hem bir adım ileri tahminleme hem de çok adım ileri tahminleme için durağan ve durağan olmayan veri setleri üzerinde incelemişlerdir. Box-Cox transformasyonu ve normalleştirme yöntemlerinin kullanılıp, küçük ağ mimarisinin seçilmesiyle sinir ağlarının tahminlemede pratik bir araç olduğunu belirtmişlerdir. Durağan serilerde, çalışmada kullanılan tüm klasik zaman serisi metotlarından ortalamada sadece çok küçük bir iyileşmenin gerçekleştiğini ancak durağan olmayan serilerde ilgilendikleri dört veri setinin üçünde ARIMA 'dan daha iyi sonuçlar elde edildiği ve iyileşmelerin durağan serilere göre daha iyi olduğu bulgularına ulaşmışlardır. Doğrusal olmayan bir yöntem için, doğrusal otokorelasyon fonksiyonuna dayanarak girdi hücresinin belirlenmesi ve gizli hücre seçiminde sistematik bir yöntemin var olmaması çalışmalarının eksik yönlerini oluşturmaktadır.

Cottrell ve diğerleri (1995), sinir ağlarında mimari seçim problemine diğer çoğu ağ budama yöntemlerinden farklı olarak ağırlık tahminlerinin asimptotik özelliklerine dayanan istatistiksel tekniklerle çözüm aramışlardır. Diğer çoğu budama yöntemlerinde, fazla parametre sayısına maliyet yükleme görevini yerine getiren ceza terimiyle ağırlık eliminasyonu gerçekleştirilirken, Cottrell ve diğerleri (1995) çalışmalarında istatistiksel geriye doğru adımsal eliminasyon yöntemini kullanmışlardır. Böylece, hangi ağırlıkların önemsiz olduğunu ve silinmesi gerektiğini belirleyerek ağ mimarisini basitleştirip parametre sayısını azaltma yoluna

gitmişlerdir. Test seti kullanmanın bir sinir ağının kalitesini ölçmede yeterli olmadığını, iki modeli karşılaştırmak için modifiye edilmiş artık varyans formülü, Akaike bilgi kriteri (AIC) ve BIC kriterlerinin daha iyi bir ölçü olduğunu belirtmişlerdir. Öteki budama teknikleriyle iki gerçek veri seti ve bazı yapay seriler üzerinde karşılaştırma yapmışlardır. Önerdikleri yöntem, bazı istatistiksel varsayımlara dayanmakta ve elde edilen nihai model başlangıç modeline bağlı olabilmektedir. Ayrıca modelleri karşılaştırmada, sinir ağları için özel olarak geliştirilmemiş ve sinir ağları için iyi bir model seçim kriteri olmadığı deneysel olarak gösterilen (Qi ve Zhang, 2001: 666) AIC ve BIC kriterlerini kullanmışlardır.

Faraway ve Chatfield (1998), orjinal Box-Jenkins çalışmasında faydalanılmış olan havayolu verisini kullanarak farklı girdi ve gizli hücre sayılarında ağın örnek içi ve örnek dışı performanslarını karşılaştırmışlardır. Oluşturan farklı girdi-gizli modelleri arasından, sinir ağı modelinin kötü girdi değişken seçimini telafi edemeyeceğini belirtmişlerdir. En iyi girdi-gizli hücre kombinasyonunu belirlemek amacıyla örnek içi hata kareler ölçüsünü, AIC ve BIC ölçülerini kullanmışlardır. Çok sayıda parametreye sahip modellerin örnek içi hata kareler ve AIC değerinin düşük olduğunu ve tecrübesiz bir araştırmacıyı yanıltabileceğini ancak BIC kriterinin ilave edilen parametreleri daha fazla cezalandırması sebebiyle farklı ve daha iyi modelin seçilmesini sağladığını, yine de hala hava yolu modelinin Box-Jenkins modelinden daha iyi olacak şekilde seçilmediğini ifade etmişlerdir. Ayrıca, Brockwell ve Davis (1991) tarafından önerilen AIC_C , AIC kriterinin yanlış düzeltme (bias-corrected) versiyonu, denenmiş ve model seçimindeki etkisinin BIC kriterine yakın olduğu gözlenmiştir.

Anders ve Korn (1999), farklı istatistiksel prosedürlere dayanan beş sinir ağı model spesifikasyon stratejisi önermişlerdir. Bu stratejiler, öncelikle optimal gizli hücre sayısının seçilmesine ardından girdi bağlantı sayısının azaltılmasına dayanmaktadır. İlgisiz girdi bağlantılarını elemek amacıyla Wald istatistiği ve bilgi kriterlerinden (AIC, Network Information Criterion (NIC)) yararlanılmıştır. Gizli hücre seçiminde Terasvirta, Lin ve Granger (1993) tarafından önerilen TLG doğrusal olmama testi veya White (1989) tarafından önerilen test kullanılabilir. Hem Wald testleri hem de bilgi kriterleri ilgisiz gizli hücrelerin bulunması durumunda teoriksel olarak doğrulanamazlar. Bu yüzden girdi bağlantı testinden önce gizli hücre testinin

yapılması mecburidir. Hatta gizli hücre seçimi için AIC veya NIC kriterlerini de kullanmak mümkündür ancak Taylor serisi açılımı yardımıyla doğrusal olmayan gizli hücre transfer fonksiyonunun doğrusallaştırılması gerekmektedir. Toplamda dört strateji şu şekildedir: 1)White-Wald 2)TLG-Wald 3)AIC-AIC 4)NIC-NIC. Beşinci strateji ise Çapraz-Doğrulama (Cross-Validation) dayanmaktadır. Çapraz-Doğrulama tanımlama problemlerinden etkilenmediği ve olasılıksal varsayımlara dayanmadığından, sinir ağları model seçiminde en genel uygulanabilir stratejidir (Anders ve Korn, 1999: 316). Ancak çapraz değerlendirme, eğer her olası gizli hücre ve girdi bağlantı kombinasyonu için yapılırsa hesaplama açısından oldukça maliyetlidir. Ayrıca zaman serilerinde bir tahmin modelini Çapraz-Doğrulama ile test etmek mümkün değildir. Aksi takdirde bu durum gelecek gözlemlerin geçmiş tahminlemek amacıyla kullanılması anlamına gelecektir. Yapılacak en makul yol, bu çalışmada da uygulanan temel çapraz değerlendirme yönteminden faydalanılmasıdır.

Balkin ve Ord (2000), tahminleme problemleri için sinir ağı mimarisinin otomatik seçilmesine yönelik bir prosedür geliştirmeye çalışmışlardır. Durağan olmayan verileri sinir ağıyla modellerken fark almanın gereksiz olduğunu, dolayısıyla ilk adımın serinin doğal logaritmasının alınmasına gerek olup olmadığına karar vermek olduğunu belirtmişlerdir. Buna, bir en çok olabilirlik oranı karşılaştırmasıyla karar vermişlerdir. Ağın eğitilmesi için seçilecek girdileri ileri adımsal regresyon (forward stepwise regression) prosedüründen yararlanarak belirlemiş ve 1 'den başlayarak bu belirlenmiş girdi hücre sayısına kadar değişen, tek katman içerisindeki gizli hücre sayılarıyla ağ eğitimi yapmışlardır. En iyi ağ seçimini ise GVC (Generalized Cross-Validation) değeri en küçük olan şekilde yerine getirmişlerdir. Bununla da yetinmeyip doğrusal AR modeli, sinir ağı ve rassal yürüyüş modellerini SBC (Schwarz criterion) kriterine göre kıyaslayıp en küçük değere sahip modelden tahminler oluşturmuşlardır. Böylece sinir ağının ele alınan problem için gerekli olup olmadığının görülmesi amaçlanmıştır. Bu prosedürü denedikleri iki veri setinin birisinde başarılı diğerinde başarısız olmuşlardır.

Qi ve Zhang (2001), örnek içi model seçim kriteri olarak AIC, BIC ve bu kriterlerin bazı uzantılarını kullanarak yaptıkları finansal zaman serisi tahminlemesi için sinir ağı modelleri seçmeye çalışmışlardır. S&P 500 indeksi, döviz kuru ve faiz oranlarına ait verilerden faydalandıkları çalışmalarında; inceledikleri örnek içi model

seim kriterlerinin rnek dıřı performansta iyi sonular vermediğini, rnek ii ve rnek dıřı performanslar arasında aık bir iliřkinin gzkmediğini belirtmiřlerdir. rnek iinde kullandıkları model seim kriteri, rnek dıřı tahminleri iin en iyi sinir ağı modelini tespit edememiřtir. Bunun nedeni olarak, AIC ve BIC kriterlerinin parametre sayısının genellikle az olduėu klasik istatistiksel modeller iin oluřturulduėunu sylemiřlerdir. Sinir ağılarında ok sayıda parametre olmasından tr AIC ve BIC kriterlerindeki ceza teriminin model seimini ok fazla domine ederek en basit modellerin seimine yol amıřtır.

BuHamra ve diėerleri (2003), aylık su tketimini sinir ağılarıyla tahminlemede girdi hcre veya gecikme hcre sayısını belirlemek amacıyla bir deney yapmıř ve Box-Jenkins ynteminin otokorelasyon fonksiyonuna dayanarak nerdiėi girdi hcre sayısının performansı ile karřılařtırmıřlardır. Ayrıca sinir ağı analizine bařlamadan nce, kayıp olan gzlem deėerlerini Box-Jenkins yntemiyle tahminlemiřlerdir. Mevsimsel deėiřimle birlikte yukarı doėru bir trendin olduėu veri setlerinde, deneysel ynteme dayanarak belirledikleri girdi hcre sayısına sahip sinir ağı performansının Box-Jenkins ynteminin nerdiėi gecikme sayısına dayandırılarak oluřturulan sinir ağı performansından daha kt olduėunu tespit etmiřlerdir. Bunun yanında, alıřmalarında genellikle tahminleme uygulamalarında tercih edilmeyen iki gizli katmandan oluřan bir ağı kullanmıřlar ve gizli hcre sayılarına deneysel olarak karar vermiřlerdir. alıřmalarında, girdi hcre sayısını tespit etmek iin deneysel olarak ok kapsamlı ve doėru bir uzay araması yaptıkları sylenemez. Dolayısıyla da deneysel yntemden elde ettikleri girdi hcre sayısının doėru olduėunu iddia etmek gereki olmayacaktır. Bilindiėi gibi, Box-Jenkins metodu gecikme deėerleri arasındaki doėrusal korelasyonu len otokorelasyon fonksiyonuna dayanarak en uygun gecikme yapısını belirlemektedir. Ancak gecikmeler arasındaki iliřki doėrusal deėilse, Box-Jenkins metodolojisi gecikme yapısını belirlemede yetersiz kalacaktır. Bu nedenle doėrusal olmayan iřleyiře sahip olan bir yntemin gecikme sayısına doėrusal bir yntemle karar vermek doėru olmayacaktır.

Eėrioėlu ve diėerleri (2008), en iyi sinir ağı mimarisini (girdi ve gizli hcre sayısını) semek amacıyla eřitli model seim kriterlerini (AIC, BIC) ve performans llerini (RMSE, MAPE, yn doėruluėu (DA) ve modifiye edilmiř yn doėruluėu

(MDA)) birlikte hesaba katan model seçim kriteri önermişlerdir. Tüm bu değerlendirme ölçülerini bir formül içerisinde sübjektif ağırlıklandırmaya tabi tutup doğrusal bir şekilde birleştirerek, ağırlıklandırılmış bilgi kriteri (WIC) adı altında formüle etmişlerdir. İki gerçek ve bir simülasyonla türetilen zaman serisi üzerinde, en iyi sinir ağının en küçük RMSE ölçüsüne göre seçildiği klasik seçim yöntemiyle karşılaştırmasını yaparak daha küçük, tutarlı ve iyi ağların seçildiğini iddia etmişlerdir. Ardından, Aladağ ve diğerleri (2010) WIC kriterinin ağırlıklarını sübjektif olarak değil, kısmen objektif olarak bir optimizasyon yöntemiyle belirlemiş ve buna AWIC ismini vermişlerdir. İnceledikleri dört veri setinde, WIC seçim yöntemine göre test seti üzerinde daha tutarlı sonuçlara ulaşmışlardır. Bu iki seçim kriterinin ortak eleştirilecek yönü, sinir ağıyla tahminlenen zaman serisinin girdi ve gecikme hücreleri arasında bir ayrıma gitmemiş olması ve kriterlerin içerdikleri performans ölçülerinin birbirleriyle yüksek ilişki içerecek şekilde oluşturulması şeklinde ifade edilebilir.

3.3. SİNİR AĞLARIYLA ZAMAN SERİSİ TAHMİNLEMESİNDE GİRDİ VE GİZLİ HÜCRELERİN ROLÜ VE ETKİSİ

Sinir ağlarının ilgi çekici birçok özelliğine rağmen belirli bir tahminleme problemi için ağ oluşturmak kolay bir iş değildir. Ağ performansını etkileyen modelleme sorunları dikkatli bir biçimde düşünülmelidir. Sinir ağlarını klasik doğrusal AR modelleri ile kıyasladığımızda, daha fazla model belirsizliğine sahip olduğunu görürüz. Gecikme sayısına ek olarak, ileri beslemeli bir sinir ağında katman sayısı, gizli hücre sayısı, çıktı ve gizli katmanlardaki hücelere yerleştirilecek transfer fonksiyonları, eğitim algoritması, veri transformasyonu veya normalizasyonu, eğitim-doğrulama-test setleri ve performans ölçüleri gibi parametre veya faktörlere karar verilmesi gerekmektedir. Teoriksel olarak üç katmanlı bir ileri beslemeli sinir ağının herhangi bir sürekli fonksiyona yaklaşabileceği gösterilmiştir (Hornik ve diğerleri, 1989: 359; Cybenko, 1989: 303). Ayrıca, gizli katmandaki gizli hücrelerinde lojistik transfer fonksiyonuna ve çıktı katmanındaki hücrelerde ise doğrusal transfer fonksiyonuna sahip en popüler sinir ağının çok sayıda başarılı uygulamasının olduğu bilinmektedir (Zhang ve diğerleri, 1998: 47). Eğitim

algoritması olarak birçok yöntem mevcut olmakla beraber, global minimumu veren bir algoritma bulunmamaktadır. Bu çalışmada, literatürde en çok tercih edilmiş Levenberg-Marquardt algoritmasından faydalanılmıştır. Veri transformasyonu olarak veriler -1 ile +1 aralığında doğrusal olarak ölçeklendirilmiştir. Çalışmada ağ performansını değerlendirmek için ortalama karesel hata ve ortalama mutlak hata ölçüleri kullanılmıştır. Ayrıca verilerin ne kadarının doğrulama seti olarak alınacağı ve bu ayrımın sinir ağı performansı üzerindeki etkisi, bu çalışmanın incelenen faktörlerinden biri olarak alınmıştır. Böylece daha önce yapılan çalışmaların da ışığı altında, zaman serisi tahminlemesi kapsamında sinir ağı modellemesiyle ilişkilendirilmiş ve üzerinde en çok çalışma yapılmış iki anahtar belirsizliğin girdi katmanındaki hücre sayısı başka bir deyişle gecikme sayısı (p) ve gizli katmandaki hücrelerin sayısı (q) olduğu söylenebilir.

Sinir ağının optimal ağ yapısını belirlemeye yönelik burada bahsedilen ve bahsedilmeyen çok sayıda çalışma bulunmakla birlikte, önerilen metotlar çeşitli varsayımlara dayanmakta, genellikle oldukça karmaşık ve uygulanabilirliğinin zor olması yanında hiçbirisi gerçek tahminleme problemleri için optimal çözümü garanti edememektedir. Başka bir deyişle, şu ana kadar bu parametreleri belirlemek için kesin, sade ve kolay anlaşılır bir metot bulunmamaktadır. İzleyen alt bölümlerde, öncelikle gizli ve ardından girdi hücre sayısının tespitine yönelik yapılmış bazı çalışmalardan bahsedilmiştir.

3.3.1. Gizli Hücre

Sinir ağlarında gizli hücrelerin görevi, verilerdeki özellik ve desenlerin bulunmasına yardımcı olmasının yanı sıra doğrusal olmama özelliğini ağa kazandırarak girdi ve çıktı değişkenleri arasındaki ilişkilendirmeyi yerine getirmesidir. Gizli hücresi olmayan bir ağın doğrusal istatistiksel tahminleme modelleriyle eşdeğer olduğu bilinmektedir (Cheng ve Titterington, 1994: 7). Gizli hücre sayısı arttıkça hem parametre sayısı hem de doğrusal olmama seviyesi artmaktadır. Ancak gereğinden fazla sayıda gizli hücrenin bir ağda kullanılması ise eğitim setine aşırı derecede uyum sağlayan bir ağın oluşturulmasına neden olacak ve genelleme yeteneğini gösteren örnek dışı verilerdeki performansının düşük olmasına

yol açacaktır. Genellikle gizli hücre sayısı az olan ağlar genelleme yeteneğinin daha iyi olması ve aşırı uyum sağlama problemine daha az maruz kalması umuduyla tercih edilebilir. Bununla birlikte, çok az sayıda gizli hücreye sahip bir ağ ilgilenilen problemi tanımlayan fonksiyona yakınsamada yetersiz kalabilecek ve kötü bir genelleme ya da örnek dışı performansa yola açabilecektir. Bir ağda yeterli sayıda gizli hücrenin bulundurulmasıyla ağın doğrusal olmayan desenleri tespit etme yeteneğine işlerlik kazandırılmış olunur. Dolayısıyla optimale yakın gizli hücre sayısında, hem örnek dışı genelleme yeteneğinin hem de örnek içinde incelenen problemin fonksiyonuna yakınsama yeteneğinin kabul edilebilir iyi bir seviyede olması beklenir.

Optimal gizli hücre sayısını belirlemeye yönelik çok sayıda çalışma yapılmış olmasına rağmen, araştırmacılar tarafından genel kabul görmüş bir formül bulunmamaktadır. Bu yüzden, araştırmacılar en çok tercih edilen yol olarak deney yapımına başvurmaktadırlar. Bununla birlikte başparmak kuralı olarak adlandırılan bazı pratik yöntemlerden bahsedilebilir. Parmak kurallarının asıl amacı, optimal gizli hücre sayısının tespit edilmesinden öte gizli hücre sayısını sınırlandırarak aşırı uyum probleminden kaçınılmaya çalışılmasıdır. Tek gizli katmanlı ağlarda geçerli olmak üzere, n girdi hücre sayısı iken gizli hücre sayısı için bazı parmak kuralları veya sezgisel öneriler “ $2n+1$ ” (Lippmann, 1987: 4), “ $2n$ ” (Wong, 1991: 152), “ n ” (Tang ve Fishwick, 1993: 374), “ $n/2$ ” (Kang, 1991: 57) şeklindedir.

Salchenberger ve diğerleri (1992) belli başlı finansal rasyoları girdi olarak alıp yatırım bankalarının başarı ve başarısızlıklarını tahminleme probleminde, gizli hücre sayısının girdi hücre sayısının %75 ‘i olarak alındığı parmak kuralını kullanarak lojit modele ve daha fazla gizli hücre kullanan diğer sinir ağı modellerine göre daha iyi sonuçlar elde etmişlerdir.

Gizli hücre sayısını seçmede bir diğer yol geometrik piramit kuralıdır. Bu kural, hücre sayısının bir piramit şeklini izlediğini farzeder. Piramidin ucu çıktıları tabanı ise girdilerdir. Her katmandaki hücre sayısı geometrik ilerlemeyi takip eder. Böylece iki katman, n girdi ve m çıktı hücresinden oluşan bir ağın gizli katmanında $\sqrt{n \cdot m}$ tane hücre bulunacaktır. Üç katmanlı bir ağ için ise benzer kural aşağıda verildiği gibi olacaktır.

$$r = \left(\frac{n}{m}\right)^{1/3} \quad (3.1)$$

$$NHID_1 = mr^2 \quad (3.2)$$

$$NHID_2 = mr \quad (3.3)$$

Yukarıdaki formülde $NHID_i$, i katmanındaki hücre sayısını göstermektedir. Ancak bunlar sadece yaklaşım formülleridir. Çok az girdi ve çıktı hücresi olması durumunda problem daha karmaşıktır ve bu metot gerçekten gereken sayıyı olduğundan daha düşük tahmin edebilir (Hansen ve diğerleri, 1999: 174). Hansen ve diğerleri (1999), gizli hücrenin bu parmak kuralı ile belirlendiği sinir ağı modellerini sinir ağının çeşitli mimari parametrelerinin genetik algoritmalar yardımıyla belirlendiği sinir ağı modelleriyle karşılaştırmış ve genetik algoritmalar yardımıyla mimarisi belirlenen sinir ağı modelleriyle daha iyi performans değerlerine ulaştığını bildirmiştir.

Lachtermacher ve Fuller (1995: 386), H gizli hücre sayısı değerine I girdi hücre sayısı ve P eğitim deseni sayısına bağlı olarak aşağıdaki sezgisel kurala göre karar vermişlerdir:

$$\frac{1.1P}{10} \leq H(I+1) < \frac{3P}{10} \quad (3.4)$$

Dikkat edilirse, yukarıdaki kuralda $H(I+1)$ ağdaki ağırlık sayısıdır. Bu kural, 10 eğitim deseni için en az 1 en fazla 2 ağırlığın, 20 eğitim deseni için en az 3 en fazla 5 ağırlık sayısının olması şeklinde eğitim deseni sayısı arttıkça kullanılacak ağırlık sayısını da arttırılmasını gerekli kılmaktadır. Bir bakıma, ağın aşırı uyuma maruz kalmasını önlemek amacıyla serbestlik derecesi ile eğitim seti hacmi arasında bir denge kurmaya çalışmaktadır.

Jasic ve Wood (2003), gizli hücre sayısını seçmek için N gözlemden oluşan veri seti üzerinde istatistiksel modellemedeki klasik pratik kuraldan faydalanmışlardır. Ağın ağırlıkları modelin serbestlik derecesine karşılık geldiğinden ve bu serbestlik derecesinin $N^{1/2}$ sayısını aşmaması gerektiği bilgisinden yola

çıkarak, ağın ağırlık sayısına bir üst sınır getirmişlerdir. Yaptıkları döviz kuru tahminlemesi çalışmasında, öncelikle ağın girdi hücre sayısını 2 ile 10 arasındaki değerler arasından karar vererek oluşturmuşlar ve ardından bu belirlenen girdi hücre sayısına karşılık gelen gizli hücre sayısını, ağın toplam ağırlıklarının $N^{1/2}$ sayısını geçmemesi kısıtı altında oluşturmuşlardır.

Tang ve Fishwick (1993), gizli hücre sayısının sinir ağı performansı üzerindeki etkisinin farklı karakteristiğe sahip seriler için aynı olmadığını gözlemlemişlerdir. Faydalandıkları iki veri setinde gizli hücre sayısının anlamlı bir etkisini tespit edememişken, diğer iki veri setinde ise gizli hücre sayısının belli bir değerden düzenli olarak düşürülmesiyle hatanın da belli bir gizli hücre sayısına kadar monoton bir şekilde düştüğünü ve gizli hücre sayısının bu noktadan sonra düşürülmeye devam edilmesiyle hatanın arttığına tanık olmuşlardır. Dolayısıyla farklı seriler için optimal bir gizli hücre sayısının bulunabileceğine dikkat çekmişlerdir. Sharda ve Patil (1992), gizli hücre sayısının girdi hücre sayısına eşit olduğu ağların daha iyi tahminleme sonuçlarına sahip olduğunu belirtmişlerdir. McMenamin (1997), çoğu tahminleme problemi için optimal gizli hücre sayısının 2 ile 5 arasında olduğunu gözlemlemiştir. Ağdaki hücre sayıları makul bir düzeyde tutulduğu sürece elde edilecek tahmin modelinin güçlü, dirençli ve duyarlı olacağını belirtmiş ayrıca yaptığı çalışmada regresyon modellerinden daha iyi performanslara ulaşmıştır.

En iyi gizli hücre sayısına deneysel olarak karar verilecekse sıklıkla kullanılan sabit, yapıcı ve yıkıcı metotlardan faydalanılabilir. Sabit metotta, farklı gizli hücre sayılarına sahip sinir ağı modelleri eğitilerek her ağın performansı doğrulama seti üzerinde incelenir ve bu işlem makul bir sayıda rassal olarak seçilmiş başlangıç ağırlık değerleriyle tekrarlanır. Her bir gizli hücre sayısının sabit tutulduğu deneyin ardından gizli hücre sayısı bir, iki veya daha fazla sayıda arttırılarak biraz önce anlatılan işlemler tekrarlanır. Ardından doğrulama seti üzerinden hesaplanacak hata kareler toplamı gibi bir değerlendirme kriterinin, farklı gizli hücre sayılarındaki performansına bakılarak en iyi ağ seçilir. Bu yaklaşım, çok zaman almasına karşın genellikle iyi bir şekilde çalışır. Bu çalışmada, sabit metottan faydalanarak deneyler oluşturulmuştur. Yapıcı ve yıkıcı yaklaşımlar ise sabit metottaki gibi farklı gizli hücre sayısına sahip ayrı ayrı ağlar kurmak yerine, bir sinir ağının eğitim esnasında

gizli hücre sayısının değiştirilmesine imkân verirler. Yapıcı yaklaşımda, 1 gibi düşük bir gizli hücre sayısından başlanarak ağ performansı kötüleşinceye kadar gizli hücre eklemesi yapılır. Yıkıcı yaklaşımda ise aynı işlemin tersi olarak bu sefer gizli hücre silinmesi yapılır. Hangi yaklaşımın seçildiğine bakılmaksızın söylenebilecek genel kural, her zaman en küçük gizli hücre sayısı ile doğrulama setinde en iyi performansı sağlayan ağın seçilmesidir. Ayrıca farklı gizli hücre sayılarını test ederken diğer tüm parametrelerin sabit tutulması önemli bir noktadır. Eğer herhangi bir parametre gizli hücre sayısı ile beraber değiştirilirse, oluşturulan yeni ağ farklı bir hata yüzeyine sahip olacak ve bu durum optimum gizli hücre seçimini karmaşık hale getirecektir.

3.3.2. Girdi Hücresi

Bir zaman serisindeki otokorelasyon yapısının (doğrusal veya doğrusal olmayan) tespit edilmesindeki rolü açısından baktığımızda, gecikme veya girdi hücresi sayısının sinir ağı modellemesindeki en önemli parametre olduğu söylenebilir (Zhang ve diğerleri, 1998: 45; Jasic ve Wood, 2003: 749). Zaman serisi tahminleme problemi için girdi hücre sayısına karar verme, nedensel tahminleme problemiyle kıyaslandığında daha zordur ve bir zaman serisindeki alta yatan desenleri belirleme eylemini direkt olarak etkileyen bir unsurdur. Veri içerisindeki özellikleri açığa çıkarmak amacıyla az sayıda hücrenin yeterli olabileceği düşünülse de çok az veya çok fazla girdi hücre, ağın hem öğrenme hem de genelleme yeteneğini olumsuz yönde etkileyebilecektir.

Girdi hücrelerinin sinir ağıyla zaman serisi tahminlemesindeki etkisi hakkındaki çalışmalara baktığımızda: Lachtermacher ve Fuller (1995), sinir ağıyla yapılan bir adım ileri tahminlemesinde ilave olarak eklenen girdi ve gizli hücrelerin performansı düşürdüğünü bildirmişlerdir. Gereksiz bir girdi hücresinin ağı eklenmesinin, gereksiz gizli hücre eklenmesine göre ağın performansını düşürmede daha etkili olduğunu gözlemlemişlerdir. Bu yüzden, ağ mimarisi oluştururken ilgili girdi hücre sayısının belirlenmesine gizli hücre sayısına göre daha dikkat edilmesi gerektiğini belirtmişlerdir. Ancak, birden çok adım ileri tahminlemesi için sinir ağı performansının gizli ve girdi hücre sayısı arttıkça iyileştiğini gözlemlemişlerdir. Foster ve diğerleri (1992), gizli hücre sayısının arttırılmasıyla ağın ağırlık sayısının

eğitiminde kullanılan veri noktası sayısını geçmesi durumunda bile tahmin performansını arttırdığını ancak girdi hücre sayısındaki meydana gelebilecek artışların incelenen tüm durumlarda tahmin doğruluğunu düşürdüğünü gözlemlemişlerdir. Bu sonucun gizli hücrenin zaman serisindeki ilgili özellikleri bulmadaki faydası ve girdi hücrenin de aşırı uyuma katkı sağlamadaki potansiyel tehlikesini gösterdiğini söylemişlerdir. Zhang ve diğerleri (2001), 8 tane doğrusal olmayan zaman serisi denkleminde simülasyon verileri türeterek sinir ağı modellemesindeki üç ana faktör olan girdi hücresi, gizli hücre ve örnek hacminin etkisini sistematik bir şekilde araştırmaya çalışmışlardır. Elde ettikleri sonuç, bir sinir ağını zaman serisi tahminlemesi yapmak için oluştururken girdi hücre sayısının gizli hücre sayısından çok daha fazla önem taşıdığıdır.

Eğitim için kullanılan veri sayısı artmaya başladıkça gizli hücre sayısının önemini yitirdiğini ancak girdi hücre sayısının her eğitim verisi hacminde önemini yitirmediği ve performansları etkileyen en önemli faktör olduğu hem simülasyonla türetilmiş doğrusal 8 tane veri seti hem de 3 tane bilinen gerçek veri seti üzerinde deneysel olarak gösterilmiştir (Zhang, 2001: 1191). Girdi hücre sayısının çok az veya çok fazla olmasının ağı öğrenme dolayısıyla da tahminleme yeteneği üzerinde anlamlı bir etkisinin olması beklenebilir bir durumdur. Çünkü çok az girdi olması, yeterli öğrenememe sonucunu doğurabilecekken çok fazla girdi ise aşırı bir spesifikasyona neden olabilecektir. Girdi hücre sayısını arttırmak tahmin doğruluğunun artmasına neden olmayacaktır. Bunun nedenlerinden biri, diğer faktörler tarafından sağlanan bilginin zaten temel faktörler içerisinde bulunması olabilir. Yeni bir ekstra gecikme hücresinin ağına eklenmesi, spesifik gürültüleri öğrenmiş bir hücrenin analizin içine katılarak kötü bir performansın elde edilmesine yol açabilir (Yao ve Tan, 2000: 10).

Optimal girdi ve gizli hücre sayısını tespit etmek için genetik algoritmalar gibi alternatif tekniklerinde parmak kuralları haricinde literatürde kendilerine yer bulduğunu görmekteyiz (Yao, 1999: 1423; Guo ve Uhrig, 1992: 223; Schiffmann ve diğerleri, 1993: 675). Kesin olan bilgi, yukarıdaki çeşitli kuralların hiçbirisi mimarinin doğru kurulmasını garanti etmemektedir. Dolayısıyla belirsizliği ortadan kaldırmak amacıyla bu çalışmada, çoğu araştırmacının yaptığı gibi makul birim

sayısı aralığında bir deney düzenlenerek en iyi sonucu üreten girdi-gizli kombinasyonunun ne olduğu araştırılacaktır.

3.4. AŞIRI UYUM SAĞLAMA PROBLEMİ

Aşırı uyum sağlama, bir tahmin modelinin çok az serbestlik derecesine sahip olduğu durumda ortaya çıkmaktadır. Başka bir deyişle, modelin parametrelerine göre nispeten az gözlemi varsa bu durumda ağ genel desenleri öğrenmek yerine bireysel desenleri ezberlemeye başlayacaktır. Sinir ağlarında gizli katman ve hücrelere bağlanan ağırlık sayısı ve eğitim setinin hacmi, aşırı uyum sağlamanın en çok olabilirliğini belirlemektedir (Baum ve Haussler, 1989: 151). Aşırı uyum sağlama probleminin öteki istatistikî modellerle kıyaslandığında genellikle daha fazla sayıda parametrenin tahminlenmesinden ötürü sinir ağı modellerinde ortaya çıkma olasılığı daha fazladır. Tek gizli katmanlı sinir ağı modeli için $p = (n_i + 2)n_u + 1$ tane parametre bulunmaktadır. Burada n_i sabit terim hariç girdi değişken sayısını, n_u ise gizli hücre sayısını göstermektedir. Eğitim seti hacmine göre ağırlık sayısı arttıkça, ağın bireysel gözlemlerin özel durumlarını ezberleme yeteneği artacaktır. Bunun sonucunda, test seti üzerindeki genelleme yeteneğinde kayıp yaşanacak ve modelin gelecek gözlemleri doğru tahmin edebilme şansı azalacak; başka bir deyişle gerçek hayatta kullanılabilirliği kalmayacaktır. Aşırı uyum sağlama problemini ortadan kaldırmak için etkili bir yöntem bulunmamakla birlikte, literatürde bazı önerilerin varlığından söz etmek mümkündür. Mesela farklı mekanizmalara sahip ağırlık eliminasyonu veya ağ budama metotları önerilmiştir (Weigend ve diğerleri, 1990: 193; Cottrell ve diğerleri, 1995: 1355; Schittenkopf ve diğerleri, 1997: 505). Ayrıca hata teriminin küçük parametre değerlerini tercih eden bir ceza terimi içermesi şeklinde modifiye edildiği “regularization” olarak adlandırılan, alternatif tahminleme tekniğinin kullanıldığı görülmektedir (Bishop, 1995: 338). Tüm bu yöntemlerdeki temel düşünce, veriye iyi bir şekilde uyum sağlayan cimri (parsimonious) veya en basit modelin bulunmasıdır. Genellikle basit modeller veriye yeteri derecede uyum sağlarken, daha kapsamlı veya karmaşık modellere göre daha iyi genelleme yeteneğine sahiptirler.

Aşırı uyum sağlama probleminin üstesinden gelmek için sıklıkla kullanılan bir yöntem, sinir ağı modelini çalıştırmadan önce zaman serisi verisinin eğitim, doğrulama ve test seti olarak adlandırılan üç farklı gruba bölünmesidir. Bu yöntemde, çok fazla ağırlık sayısına sahip büyük hacimli ağ yapısının kullanılmasına izin verilse de eğitim, ağ sahip olduğu tüm serbestlik derecesini kullanmadan önce durdurulur. Bu prosedürle ilgili problem, ağın tüm yararlı bilgiyi elde ettiği ve modelin parametrelerinin içine gürültünün sokulmaya başladığı zamanın belirlenmesidir. Eğitimde kullanılmayan doğrulama setindeki performans, eğitim boyunca takip edilerek doğrulama setindeki hata çok yavaş düşmeye başladığında veya arttığında eğitim sonlandırılır (Weigend ve diğerleri, 1990: 193). Eğitim seti, en büyük hacmi olan settir ve verideki mevcut desenlerin öğrenilmesi amacıyla ağ tarafından kullanılır. Doğrulama seti ise genellikle eğitim setinin %10 ile %30 arasındaki hacmine karşılık gelecek şekilde, en iyi genelleme yeteneğine sahip ağın seçilmesi için oluşturulur. Yeterli seviyede eğitildiği düşünülerek seçilen ağın performansının son kontrolü test seti üzerinde yapılır. Test setinin hacmi, eğitilen ağın performansının değerlendirilmesine imkân verebilecek ve eğitim ve doğrulama setlerine yeterli miktarda gözlem bırakacak şekilde olmalıdır. Test setinin en son gözlemler bütününden oluşturulması uygulamada fayda sağlayacaktır. Dikkat edilmesi gereken çok önemli bir nokta, test setinin doğrulama seti gibi kullanılmamasıdır. Başka bir deyişle, eğitim-doğrulama-test seti ayrımının yapılmasının ardından en iyi modeli seçmede veya en iyi gecikme-gizli sayısını belirlemek gibi parametrelere karar vermede, ağın test seti üzerindeki performanslarına bakılmaması gerekmektedir. Test seti, eğitim tamamlanıp nihai parametre ve ağa karar verildikten sonra diğer veri seti ayrışımından bağımsız bir en son performans ölçütü olarak kullanılmalıdır.

Bununla birlikte, veri setinin üç gruba bölünerek sinir ağı modellemesi yapılmasının bazı dezavantajları olabilmektedir. Örneğin, verinin bölünmesi tahminlerin değişkenliğinin artmasına yol açabilir (Faraway, 1992: 213). LeBaron ve Weigend (1998) bootstrap yöntemini kullanarak farklı veri bölümünden ortaya çıkan değişkenliğin başlangıç parametrelerinin seçimi, gizli hücre sayısı gibi farklı ağ koşullarının sebep olduğu değişkenlikten önemli derecede daha fazla olduğunu göstermiştir. Ayrıca verinin nasıl üç parçaya bölüneceğine dair genel bir kural

bulunmamaktadır. En iyi modeli seçmek ve/veya eğitimi durdurmak amacıyla kullanılan doğrulama setinin, iyi bir şekilde görevini yerine getirmesi için tüm veri setinin iyi bir temsilcisi olması gerekir. Araştırmacı doğru model yapısını içeren bir doğrulama setine mi yoksa veri yapısının değiştiği bir doğrulama setine mi sahip olduğunu bilemeyebilir. Bu noktada, doğrulama setinin hacmi önem kazanmaktadır. Doğrulama seti hacminin küçük alınması, verinin sadece o döneme ait özelliklerinin dikkate alınıp genelleme yeteneğinden kayba uğranılarak en iyi modelin seçilememesine yol açacaktır. Doğrulama seti hacminin gereğinden fazla büyük oluşturulması ise hem eğitim için kullanılacak verilerin sayısının azalmasına hem de eğer veri ayrışımı eğitim-doğrulama-test sırasıyla yapılmışsa son dönemden uzaklaşarak eğitim yapılmasına neden olabilecektir. Sinir ağlarının veri sürürlü bir metot olması sebebiyle eğitim verisinin yeterli büyüklükte olmasının son derece önem taşımamasının yanında, son dönem verilerinden uzaklaşarak zaman serisi analizi yapılması da oluşturulacak muhtemel ağların performanslarının düşmesine sebep olabilir. Doğrulama setinin eğitim setini izleyen gözlemlerden oluşturulması en iyi modeli veya parametreler kombinasyonunu seçerken son dönem gözlemlerinin eski gözlemlere göre daha önemli olabilmesiyle fayda sağlayabilecektir. Ayrıca, bir sinir ağının kalitesi genellikle ağın performansının test seti üzerinde ölçülmesiyle değerlendirilir. Doğrulama setinde olduğu gibi, bu yöntem eğer test seti eğitim setinin temsilcisiyse iyi bir performans değerlendirme şekli olabilmektedir. Zaman serileri analizinde, gelecek gözlemlerin dağılışının geçmiş gözlemlerin dağılışıyla aynı olacağını garanti etmek pek mümkün değildir. Bu yüzden, araştırmacı doğru modeli mi yoksa veri yapısının bir değişimini mi test edip etmediğini bilemez. Verileri bu şekilde üç bölüme ayrılması her ne kadar aşırı uyum sağlama problemiyle başa çıkmada fayda sağlasa da bu yöntem veri sayısının fazla olmasını gerektirmektedir. Eđer az sayıda veri varsa, bu prosedür zaten az olan eğitim setini daha da düşürecek ve modelin güvenilirliğini azaltabilecektir.

3.5. ÖNERİLEN YAKLAŞIM: GİRDİ-GİZLİ-DENEME AYRIŞIMI

Bilindiği üzere, bir zaman serisi tahminlemesinde girdi hücre verinin otokorelasyon yapısını modellemeye çalışırken gizli hücre sayısı ağın doğrusal

olmama derecesini ayarlamaktadır. Girdi hücresinin gizli hücresine göre tahmin performansı üzerindeki etkisi daha önemliken (Jasic ve Wood, 2003: 749; Lachtermacher ve Fuller, 1995: 390; Zhang, 2001: 1191; Zhang ve diğerleri, 1998: 45; Zhang ve diğerleri, 2001: 381), uygun bir ağ seçiminde öncelikle girdi hücresinin tespit edilmeye çalışılması akla uygun bir yaklaşım olabilir. Girdi hücre sayısı, verinin otokorelasyon yapısını belirlediğinden yanlış bir girdi hücre sayısı ile kurulmuş bir ağın tahmin gücü yetersiz kalacaktır (Faraway ve Chatfield, 1998: 239; Foster ve diğerleri, 1992: 296; Yao ve Tan, 2000: 10).

Sinir ağlarında deneysel bir yaklaşımla ağ yapısı oluşturulacaksa, farklı girdi-gizli hücre sayısı kombinasyonları ve farklı başlangıç ağırlık değerlerinin oluşturduğu toplam ağ sayısı içerisinde, klasik seçim yöntemiyle doğrulama seti üzerinde en küçük karesel hatayı veren ağ seçilmektedir. Başka bir deyişle, farklı ağların doğrulama seti üzerinde oluşturduğu hata uzayında herhangi bir girdi ve gizli hücre sayısı tespitine giden ve bunların aralarındaki göreceli önemi hesaba katan bir seçim işlemi uygulanmamaktadır. En küçük karesel hatanın elde edildiği ağın girdi ve gizli hücre sayısının, en uygun kombinasyonu temsil ettiği varsayılmaktadır. Oysaki bu en küçük hata değerine ulaşmış ağ, doğrulama setinin kendine ait özellik ve gürültülerine çok iyi uyum sağlamış girdi ve gizli hücre sayısını seçebilir. Böyle bir ağın test seti üzerindeki genelleme yeteneği zayıf olacaktır (Schittenkopf ve diğerleri, 1997: 506). Bu olası aşırı uyum sağlama probleminin üstesinden gelmek amacıyla farklı ağların oluşturduğu hata uzayında, aramanın yönlendirilmesi yoluna gidilebilir. Her girdi hücreye karşılık gelen farklı gizli hücre ve farklı başlangıç değerlerinin oluşturduğu alt hata uzaylarının ortalama performans ölçüleri karşılaştırılabilir. Bunun anlamı, hata uzayında en iyi ortalama performansa yol açan otokorelasyon yapısının tespit edilmeye çalışılmasıdır. Ayrıca, bu yolla zaman serisi tahminlemesinde en önemli öge olan girdi hücre sayısını tek bir ağın performansına göre belirlemek yerine oluşturulan farklı gizli hücre sayısı ve farklı başlangıç ağırlık değeri sayısının çarpımı kadar sayıda ağın ortalama performansı ile karar verilecek ve yanlış gecikme yapısı seçimi daha zor olacaktır. Girdi hücre sayısının bu şekilde tespit edilmesiyle yanlış bir otokorelasyon yapısı seçiminden kaynaklanan aşırı uyumun önüne geçilebileceği umulmaktadır.

Ancak, bu girdi hücre sayısının seçiminin ardından ikinci derece öneme sahip olan gizli hücre sayısının tespit edilmesi gerekmektedir. Çünkü otokorelasyon yapısı doğru olarak seçilmiş olsa bile aşırı bir doğrusal olmama derecesine sahip ağ, gürültüleri yine ezberleyebilir veya az doğrusal olmama derecesine sahip ağ, genel deseni öğrenmekte yetersiz kalabilir. Bu iki durum da genelleme yeteneğinin düşmesine sebep olacaktır. Girdi hücre sayısı seçilirken hata uzayının arama bölgesi sınırlandırılmıştı. Şimdi, gizli hücre sayısı da belirlerken arama uzayının daha da küçültülmesi yoluna gidilebilir. Sınırlandırılmış arama bölgesinde, girdi hücre sayısı belirlenmişken bu girdi hücre sayısına karşılık gelen her gizli hücre kombinasyonu için farklı başlangıç ağırlık değerlerinden kaynaklanan farklı ağlar bulunmaktadır. Bu ağların her gizli hücre sayısı için ortalama hata performansları karşılaştırılarak en uygun gizli hücre sayısı belirlenebilir. Böylelikle hata uzayındaki arama, belirlenmiş girdi ve gizli hücre sayısının farklı başlangıç ağırlık değerleriyle oluşturduğu daha küçük bir alt uzaya sınırlandırılabilir. Artık, bu alt uzaydaki her bir sinir ağı modelinin fonksiyonel yapısı başka bir deyişle otokorelasyon yapısı ve doğrusal olmama derecesi aynıdır. Ancak doğru bir otokorelasyon ve doğrusal olmama derecesi belirlenmiş olsa bile en iyi ağın doğrulama setine göre seçilmesi yine genelleme yeteneği üzerinde bir performans eksikliğine neden olabilir. Bunun nedeni, başlangıç ağırlık değerinin doğrulama setini minimize edecek bir çekim bölgesinden seçilmiş olma ihtimalidir. Daha fazla açmak gerekirse, doğru fonksiyonel form seçilmiş olsa bile eğitim doğrulama setine göre sonlandırıldığından eğitim erken durdurulmuş yeterli öğrenme sağlanmamış veya geç durdurulmuş eğitim gereğinden fazla yapılmış olabilir. Her iki durumda da doğrulama hacmine çok iyi uyum sağlamış bir sinir ağı elde edilebilir.

Sadece doğrulama seti performansına dayanarak en iyi ağın seçilmesi ve bu ağında test seti üzerinde iyi performans sergilemesi doğrulama ve test setinin aynı veri dinamikleri tarafından yönlendirildiğini gösterir. Ancak, test seti üzerinde herhangi bir kötü performans ise iki set arasında yapısal veya modelsel farklılığın bulunduğu işaret olabilir. Bu durumda, ya test seti geçmiş verilerden farklı bir veri üretim sürecine girmiş olabilir ki bu koşulda yeni dönem verilerinin birikmesini bekleyerek bu dönemin eğitim sürecine dahil edilmesi dışında pek yapacak bir şey yoktur ya da doğrulama seti tüm veri setinin iyi bir temsilcisi olmamasından

kaynaklanan kötü bir performans mevcuttur. İkinci koşulun gerçekleşmiş olması halinde, hem eğitim hem doğrulama seti performanslarına eşanlı bakılarak tüm süreci daha iyi temsil eden bir ağ seçilmeye çalışılabilir. Böylece sadece doğrulama setine dayanarak en iyi modelin seçiminden kaynaklanabilecek olası bir hatanın önüne geçilebilir.

Eğitim seti üzerinde en küçük hata ölçüsüne dayanarak model seçilmesinin muhtemel sonucu aşırı parametre sayısına sahip ya da aşırı uyum sağlamış bir modelin seçilmesidir (Weigend ve diğerleri, 1990: 193). Eğitim setiyle kıyaslandığında daha nadir olsa da bu durum değerlendirme seti üzerinde de gerçekleşebilir. Doğrulama setinde en küçük hata ölçüsüne sahip model, doğrulama setinin kendine has özelliklerine ve yapısına çok iyi uyum sağlamış olabilir. Bu durumda aşırı parametrelili bir modelin seçimi olasıdır. Dolayısıyla da genelleme yeteneğini gösteren test seti performansı düşük olabilecektir. Bunun üstesinden gelmek amacıyla önerilen Girdi-Gizli-Deneme ayrışımı (GGD) yönteminde, gecikme ve gizli hücre sayılarının tespit edilmesinin ardından bu gecikme-gizli hücre kombinasyonundaki denemeler, doğrulama ve eğitim performansı için ayrı ayrı olmak üzere en küçük hata değerine 1 verilerek deneme sayısına kadar sıra numarasıyla sıralanır. Ayrıca, hem doğrulama hem de eğitim setinde iyi bir hata performansına sahip ağ seçmek için her bir denemenin eğitim ve doğrulama performans sıra farkının da eklendiği bir matris oluşturulur. Sıra farkı, doğrulama ve eğitim performansları arasında uçurum olmayan bir ağın seçimine imkân verecektir. Daha sonra hem eğitim hem de doğrulama setinde diğer denemelere göre göreceli olarak iyi performans göstermiş bir ağ çok kriterli karar verme yöntemi yardımıyla seçilir. Bu çalışmada TOPSIS yöntemi kullanılmıştır fakat seçim yöntemi olarak TOPSIS yöntemi yerine başka karar verme teknikleri de kullanılabilir. Girdi ve gizli hücre sayıları belirlenmişken denemenin de bu yöntemle seçilmesiyle artık nihai ağ bellidir ve test seti üzerindeki performansı değerlendirilebilir. GGD ayrışımı yönteminin ardışık üç adımının formülasyonu takip eden alt bölüm içerisinde verilmiştir.

Zhang (2001) ve Zhang ve diğerleri (2001) girdi ve gizli hücrelerinin ağ performansı üzerindeki etkisini incelediği çalışmalarının gelecek çalışmalar kısmında, sinir ağlarında girdi ve gizli hücrelerin önem seviyesini hesaba katan bir

model seçim kriteri veya model geliştirme metodolojisi ile ilgili daha çok araştırma yapılmasına gerek olduğunu ifade etmişlerdir. Her ne kadar bu çalışmanın esinlenme kaynağı bu cümle olmasa da çalışmanın bu amaca hizmet ettiği söylenebilir.

3.5.1. Önerilen Yaklaşımın Formülasyonu

GGD ayrışımı yönteminin adımlarının formülasyonu aşağıda verilmiştir:

- 1) m izin verilen maksimum gecikme sayısı ve p incelenen gecikmeyi göstermek üzere $1 \leq p \leq m$ aralığındaki $\forall p \in Z^+$ için aşağıdaki ortalama MSE değerleri hesaplanır ve en küçük ortalama MSE değerine sahip gecikme sayısı P indisi ile gösterilir.

$$\overline{MSE}_p = \frac{\sum_{q=1}^n \sum_{i=1}^k MSE_{(p,q,i)}}{k*n} \quad (3.5)$$

$$P = \text{Min}(\overline{MSE}_p) \quad (3.6)$$

Burada, n ve k izin verilen maksimum gizli hücre ve deneme sayılarını göstermektedir. q ve i ise sırasıyla incelenen gizli hücre sayısı ve deneme sayısıdır.

- 2) P gecikme sayısı belirlendikten sonra, q incelenen gizli hücre sayısını göstermek üzere iken $1 \leq q \leq n$ aralığındaki $\forall q \in Z^+$ için ortalama MSE değerleri hesaplanır ve en küçük ortalama MSE değerine sahip gizli hücre sayısı Q indisi ile gösterilir.

$$\overline{MSE}_q = \frac{\sum_{i=1}^k MSE_{(P,q,i)}}{k} \quad (3.7)$$

$$Q = \text{Min}(\overline{MSE}_q) \quad (3.8)$$

- 3) Son olarak, (P,Q) belirlenmişken k tane farklı deneme arasından hangisinin seçileceğini belirlemek amacıyla denemelerin eğitim ve doğrulama setleri üzerindeki MSE performansları: en küçük MSE değeri 1, en büyük MSE değeri k olacak şekilde sıralaması yapılır ve sıra

farkının eklenmesiyle de aşağıdaki gibi bir A karar matrisi oluşturulur. Bu matrisin TOPSIS yöntemiyle çözümü sonucunda, hangi I denemesinin seçileceği belirlenerek (P,Q,I) ayrışımı tamamlanır.

	Denemeler (i)	Eğitim MSE	Doğrulama MSE	Sıra Farkı
$A =$	1	3	2	1
	2	4	k	4-k
	3	k	3	k-3
	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	k	k-3	1	k-4

3.5.2. TOPSIS Yöntemi

TOPSIS (Technique for Order Preference by Similarity to Ideal Solution) Yoon ve Hwang tarafından 1980 yılında geliştirilmiştir ve bir başka karar verme tekniği olan ELECTRE (ELimination and Choice Expressing REality) yönteminin temel yaklaşımlarını kullanır. Karar noktalarının ideal çözüme yakınlığı ana prensibine dayanır ve çözüm süreci ELECTRE yöntemine nazaran daha kısadır. TOPSIS yöntemi 6 adımdan oluşan bir çözüm sürecini içerir. Yöntemin ilk iki adımı ELECTRE yöntemi ile ortaktır. Aşağıda TOPSIS yönteminin adımları tanımlanmıştır.

Adım 1: Karar Matrisinin (A) Oluşturulması

Karar matrisinin satırlarında üstünlükleri sıralanmak istenen karar noktaları, sütunlarında ise karar vermede kullanılacak değerlendirme faktörleri yer alır. A matrisi karar verici tarafından oluşturulan başlangıç matrisidir. Karar matrisi aşağıdaki gibi gösterilir:

$$A_{ij} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \quad (3.9)$$

A_{ij} matrisinde m karar noktası sayısını, n değerlendirme faktörü sayısını verir.

Adım 2: Standart Karar Matrisinin (R) Oluşturulması

Standart Karar Matrisi, A matrisinin elemanlarından yararlanarak ve aşağıdaki formül kullanılarak hesaplanır.

$$r_{ij} = \frac{a_{ij}}{\sqrt{\sum_{k=1}^m a_{kj}^2}} \quad (3.10)$$

R matrisi aşağıdaki gibi elde edilir:

$$R_{ij} = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2n} \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ \cdot & & & \cdot \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix} \quad (3.11)$$

Adım 3: Ağırlıklı Standart Karar Matrisinin (V) Oluşturulması

Öncelikle değerlendirme faktörlerine ilişkin ağırlık değerleri (w_i) belirlenir

$$(\sum_{i=1}^n w_i = 1).$$

Daha sonra R matrisinin her bir sütunundaki elemanlar ilgili w_i değeri ile çarpılarak V matrisi oluşturulur. V matrisi aşağıda gösterilmiştir:

$$V_{ij} = \begin{bmatrix} w_1 r_{11} & w_2 r_{12} & \dots & w_n r_{1n} \\ w_1 r_{21} & w_2 r_{22} & \dots & w_n r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_1 r_{m1} & w_2 r_{m2} & \dots & w_n r_{mn} \end{bmatrix} \quad (3.12)$$

Adım 4: İdeal (A^*) ve Negatif İdeal (A^-) Çözümlerin Oluşturulması

TOPSIS yöntemi, her bir değerlendirme faktörünün monoton artan veya azalan bir eğilime sahip olduğunu varsaymaktadır.

İdeal çözüm setinin oluşturulabilmesi için V matrisindeki ağırlıklandırılmış değerlendirme faktörlerinin yani sütun değerlerinin en büyükleri (ilgili değerlendirme faktörü minimizasyon yönlü ise en küçüğü) seçilir. İdeal çözüm setinin bulunması aşağıdaki formülde gösterilmiştir.

$$A^* = \left\{ \left(\max_i v_{ij} \mid j \in J \right), \left(\min_i v_{ij} \mid j \in J' \right) \right\} \quad (3.13)$$

(3.13) formülünden hesaplanacak set $A^* = \{v_1^*, v_2^*, \dots, v_n^*\}$ şeklinde gösterilebilir.

Negatif ideal çözüm seti ise, V matrisindeki ağırlıklandırılmış değerlendirme faktörlerinin yani sütun değerlerinin en küçükleri (ilgili değerlendirme faktörü maksimizasyon yönlü ise en büyüğü) seçilerek oluşturulur. Negatif ideal çözüm setinin bulunması aşağıdaki formülde gösterilmiştir.

$$A^- = \left\{ \left(\min_i v_{ij} \mid j \in J \right), \left(\max_i v_{ij} \mid j \in J' \right) \right\} \quad (3.14)$$

(3.14) formülünden hesaplanacak set $A^- = \{v_1^-, v_2^-, \dots, v_n^-\}$ şeklinde gösterilebilir.

Her iki formülde de J fayda (maksimizasyon), J' ise kayıp (minimizasyon) değerini göstermektedir.

Gerek ideal gerekse negatif ideal çözüm seti, değerlendirme faktörü sayısı yani m elemandan oluşmaktadır.

Adım 5: Ayırım Ölçülerinin Hesaplanması

TOPSIS yönteminde her bir karar noktasına ilişkin değerlendirme faktör değerinin İdeal ve negatif ideal çözüm setinden sapmalarının bulunabilmesi için Euclidian Uzaklık Yaklaşımından yararlanılmaktadır. Buradan elde edilen karar noktalarına ilişkin sapma değerleri ise İdeal Ayırım (S_i^*) ve Negatif İdeal Ayırım (S_i^-) Ölçüsü olarak adlandırılmaktadır. İdeal ayırım (S_i^*) ölçüsünün hesaplanması (3.15) formülünde, negatif ideal ayırım (S_i^-) ölçüsünün hesaplanması ise (3.16) formülünde gösterilmiştir.

$$S_i^* = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^*)^2} \quad (3.15)$$

$$S_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad (3.16)$$

Burada hesaplanacak S_i^* ve S_i^- sayısı doğal olarak karar noktası sayısı kadar olacaktır.

Adım 6: İdeal Çözüme Göreli Yakınlığın Hesaplanması

Her bir karar noktasının ideal çözüme göreli yakınlığının (C_i^*) hesaplanmasında ideal ve negatif ideal ayırım ölçülerinden yararlanılır. Burada kullanılan ölçüt, negatif ideal ayırım ölçüsünün toplam ayırım ölçüsü içindeki payıdır. İdeal çözüme göreli yakınlık değerinin hesaplanması aşağıdaki formülde gösterilmiştir.

$$C_i^* = \frac{S_i^-}{S_i^- + S_i^*} \quad (3.17)$$

Burada C_i^* değeri $0 \leq C_i^* \leq 1$ aralığında değer alır ve $C_i^* = 1$ ilgili karar noktasının ideal çözüme, $C_i^* = 0$ ilgili karar noktasının negatif ideal çözüme mutlak yakınlığını gösterir (Yaralıoğlu, 2004: 17)

3.5.3. Deney Tasarımı ve Veri Setleri

Sinir ağları kullanılarak zaman serisi tahminlemesi yapılması alanında çok sayıda ve çok çeşitli araştırmalar yapılmıştır. Araştırmacılar belli tip zaman serileriyle sinir ağlarının özelliklerini incelemek için simüle edilmiş zaman serilerinden sıklıkla faydalanmışlardır. Bu çalışma kapsamında, ilk olarak doğrusal ve doğrusal olmayan iki seriden türetilmiş simülasyon verileri üzerinde önerilen model seçim stratejisinin performansı incelenmeye çalışılacaktır. Simülasyon verisiyle çalışılmasının nedeni altta yatan veri üretim sürecinin ve bu sürecin gecikme sayısı gibi parametrelerinin önceden bilinmesidir. Böylece, önerilen seçim stratejisinin zaman serisi modellemesindeki en önemli unsur olan gecikme yapısına ne kadar yaklaşabildiğinin başka bir deyişle gerçek gecikme sayısını klasik model seçim yöntemine göre ne kadar doğrulukla belirleyebildiğinin tespiti yapılabilecektir.

Önerilen Gecikme-Gizli-Deneme ayrışımı yönteminin klasik model seçimiyle performansının karşılaştırılmasının yanı sıra, doğrulama seti hacmi ve gürültü seviyesinin YSA 'da model seçim üzerindeki etkisini incelemek amacıyla faktöriyel tasarımından faydalanılarak bir simülasyon deneyi oluşturulmuştur. Bu amaçla Eşitlik (3.18) ve Eşitlik (3.19) 'de fonksiyonel formu verilmiş doğrusal ve doğrusal olmayan iki modelden türetilmiş 300 birimlik zaman serilerinin son 50 verileri test verisi olarak alınmıştır. Doğrusal ve doğrusal olmayan iki model alınmasının sebebi, önerilen model seçim stratejisinin çalışabilirliğini hem doğrusal hem de doğrusal olmayan zaman serisi üzerinde ayrı ayrı incelenmek istenmesidir. Tüm veriden test verisini düşükten sonra kalan 250 birimlik verinin sırasıyla yüzde 10, 20 ve 30 gözleminin alınmasıyla doğrulama seti hacimlerinin seviyeleri oluşturulmuştur. Doğrulama seti seviyelerine, yapılan çalışmalarda genellikle doğrulama hacmini belirlemek için alınan yüzdesel alt sınır olan 10 ile üst sınır olan 30 aralığı temel alınarak karar verilmiştir (Kaastra ve Boyd, 1996: 223). Dolayısıyla test verisinden önce gelen doğrulama seti verisi sırasıyla 25, 50 ve 75 hacimli olmak üzere üç farklı seviyede oluşturularak model seçmedeki etkisi incelenmiştir. Deneydeki bir diğer faktör olan gürültü seviyesinin iki model seçim stratejisine ve tahminleme doğruluğuna etkisini görmek için ise her bir modeldeki hata terimleri ortalaması 0 ve standart sapması sırasıyla 1, 2 ve 3 olacak şekilde normal dağılımdan türetilmiştir.

Her bir farklı standart sapma değeri sırasıyla deneyin 1., 2., ve 3. gürültü seviyelerine karşılık gelmiştir. Farklı doğrulama seti hacmi ve gürültü seviyelerinde, iki seçim yönteminin performanslarının karşılaştırılmasıyla bu faktörlerde ürettikleri sonuçlar incelenerek potansiyel güçleri ve benzerlik-farklılıkları ortaya konulabilecektir. Örneğin, Gecikme-Gizli-Deneme ayrışımının doğrulama seti hacmine karşı direnç gösterip göstermediği veya farklı gürültülerde performansının aynı olup olmadığı gibi önemli sorulara cevap aranmış olacaktır.

Doğrusal Otoregresif Model (AR2):

$$y_t = 0.67y_{t-1} - 0.41y_{t-2} + \varepsilon_t \quad (3.18)$$

Doğrusal Olmayan Otoregresif Model (GAR):


$$y_t = 0.7y_{t-1} - 0.01y_{t-1}^2 + \varepsilon_t \quad (3.19)$$

Yukarıdaki modeller kullanılarak her bir gürültü ve doğrulama seti seviyesinde hata terimleri için farklı rassal başlangıç değerlerinin alınmasıyla 50 ‘şer tane zaman serisi oluşturulmuştur. Böylece, her bir seviye kombinasyonunda aynı otokorelasyon yapısından türetilmiş ancak farklı zaman serilerinin kullanılmasıyla deney tekrarlanmıştır. Oluşturulan deney tasarımının her bir seviye kombinasyonunun 50 ‘şer kez tekrarlanmasının nedeni elde edilen sonuçların belli bir standardın mı yoksa sadece rassal sürecin bir temsilcisi mi olduğunun öğrenilmek istenmesidir. Bu durum aşağıdaki Tablo 1 aracılığıyla özetlenmiştir. Tablodan her bir model için 450 farklı zaman serisinin türetildiği anlaşılmaktadır. Tasarımdaki her hücrede, aynı desenden türetilmiş 50 zaman serisine ait klasik ve GGD ayrışım seçim yöntemlerinin test seti üzerindeki 50 ‘şer tane hata ölçüsü bulunacaktır. Bu hata ölçülerinin ortalama performansları, söz konusu karşılaştırmayı oluşturacaktır. Örnek sağlaması açısından, 2.gürültü seviyesinde yukarıda fonksiyonel formları verilen doğrusal ve doğrusal olmayan modelden türetilmiş verilerin zaman serisi grafikleri sırasıyla Şekil 8 ve Şekil 9 ‘da verilmiştir.


Tablo 1: Simülasyon Verisi İçin Oluşturulan Deneyin Tasarım Şeması

	1.Gürültü	2.Gürültü	3.Gürültü
25 Doğrulama Seti	50 zaman serisi		
50 Doğrulama Seti			
75 Doğrulama Seti			

Şekil 8: 2.Gürültü Seviyesinde AR2 Modeli



Şekil 9: 2.Gürültü Seviyesinde GAR Modeli




Doğrusal ve doğrusal olmayan modellerden türetilen 450 farklı zaman serisinin her birini modellemek amacıyla ayrı ayrı sinir ağı modelleri oluşturulmuştur. Doğrusal zaman serisi problemleri çoğunlukla 1 veya 2 otoregresif terim, nadiren 3 veya daha fazla terim içerirler (Makridakis ve diğerleri, 1998: 103). Ancak doğrusal olmayan zaman serisi problemlerinde, genellikle kullanılan otoregresif terim sayısı ile ilgili bilgiye rastlanmamaktadır. Bu yüzden, çoğu sinir ağı çalışmasında başvurulduğu gibi göreceli büyük sayıda girdi hücre sayısına bu çalışmada izin verilmiştir. Teoride muhtemel gizli hücre sayısının bir üst limiti bulunmamaktadır. Ayrıca, daha önceki çalışmalar sinir ağı tahminleme performansının girdi hücre sayısına olduğu kadar gizli hücre sayısına duyarlı olmadığını göstermektedir (Lachtermacher ve Fuller, 1995: 390; Zhang ve diğerleri, 2001: 381). Buna dayanarak, maksimum gizli hücre sayısı maksimum girdi hücre sayısına denk olacak şekilde ayarlanmıştır. Her bir sinir ağı modelinde girdi ve gizli hücre sayıları 1 'den başlatılarak ardışık olarak 10 hücreye kadar çıkartılmıştır. Toplamda 100 farklı modelden oluşan bu girdi-gizli kombinasyonlarının her biri farklı başlangıç ağırlık değerleriyle 30 'er kez tekrarlanarak yerel minimuma takılı kalmaktan kaçınılmaya çalışılmıştır. Başka bir ifadeyle her bir zaman serisini modellemek için 3000 tane sinir ağı oluşturulmuştur. Çalışmanın amacı olan model seçimi de burada ortaya çıkmaktadır. Her bir zaman serisi için kurulan bu 3000 modelden hangisinin seçileceği problemine cevap aranmaya çalışılmaktadır. Bu amaca yönelik olarak, önerilen model seçim stratejisinin performansı her gürültü-doğrulama kombinasyonundaki farklı 50 zaman serisinde klasik seçim yöntemi olan doğrulama setindeki en küçük hata performansına sahip model ile test seti üzerinde karşılaştırılabilir. Ayrıca simülasyon deneyinin toplamında oluşturulan sinir ağı sayısı, iki simülasyon modelinden türetilen farklı 450 'şer tane zaman serisi bulunduğu ve her bir zaman serisini sinir ağıyla modellemek için 3000 sinir ağı oluşturulduğundan toplamda 2.700.000 ($2 \times 450 \times 3000$) tanedir.

Simülasyon verisiyle bilinen gecikme yapılarına GGD ayrışımının ne kadar yaklaşabildiğinin gözlenmesinin ardından, bu çalışmada literatürde incelenmiş üç tane gerçek veri seti kullanılarak performans değerlendirilmesi yoluna da gidilmiştir. İlk veri seti, 1821-1934 yılları arasında Kuzey Kanada 'nın Mackenzie Nehri çevresinde bir yılda kapana yakalanan vaşak sayısından oluşmaktadır (Lynx serisi).


Şekil 10 ‘da bu veri setinin grafiği verilmiştir. Doğrusal olmayan yapıya sahip olan Lynx verisi, doğrusal ve doğrusal olmayan metotların performansını kıyaslamak amacıyla çoğu araştırmacı tarafından kullanılmıştır (Subba Rao ve Gabr, 1984: 93; Priestley, 1988: 81; Wong ve Li, 2000: 109; Zhang, 2003: 169; Stone ve He, 2007: 382). Modelleme yapılmadan önce, Priestley (1988) ve diğerlerinin yaptığı gibi serinin on tabanında logaritması alınmıştır. Toplamda 114 gözlemden oluşan serinin son 14 gözlemi test seti olarak ayrılmıştır. Eğitim setinden sonra gelen doğrulama hacmi ise 20, 30 ve 40 olacak şekilde üç seviye de oluşturularak yine her bir doğrulama seti hacminin etkisi incelenecek şekilde deney tasarlanmıştır. İkinci veri seti, 1700 ile 1987 yılları arasındaki yıllık güneş lekesi sayısından oluşmaktadır (Sunspot serisi). Şekil 11 ‘de bu veri seti gösterilmiştir. Sunspot serisi çoğu araştırmacı tarafından çeşitli tahmin metotlarının performansını değerlendirmek amacıyla kullanılmıştır (Subba Rao ve Sabr, 1984: 85; Priestley, 1988: 69; De Groot ve Wurtz, 1991: 177; Hipel ve McLeod, 1994: 121; Zhang, 2003: 168). Bu veri setinin test seti iki parça olarak alınmıştır. İlk test seti son 67 verinin ilk 35 gözlemden, ikinci test seti ise son 67 gözlemin tümünden oluşturulmuştur. Böylece test setinin iki seviyesindeki performansların incelenmesi olanaklı olacak ve daha önce bu şekilde ayırım yapılarak oluşturulmuş ARIMA modeliyle karşılaştırma yapılabilecektir. Bu seri için doğrulama hacmi ise 25, 45 ve 65 olacak şekilde üç seviyede alınmıştır. İlk iki veri setinin doğrusal olmayan ve normal olmayan yapıya sahip olduğu ve doğrusal olmayan modelleme prosedürlerinin doğruluğunu değerlendirmek için kullanıldığı bilinmektedir (Ghiassi ve Saidane, 2005: 407). Son veri seti, Box ve Jenkins ‘in orjinal çalışmalarında (1970) yararlandıkları 17/05/1961 ve 2/11/1962 tarihleri arasındaki 369 günlük IBM hisse senedi kapanış fiyatlarından oluşmaktadır. Bu IBM serisi, Şekil 12 ‘de verilmiştir. IBM veri setinin son 10 gözlemi test seti olarak ayrılmıştır. Doğrulama hacmi ise 35, 70 ve 105 olacak şekilde üç seviyede alınarak deney tasarlanmıştır. Bu serinin kullanılmasıyla hem ekonomik bir seri üzerinde de seçim yöntemlerinin performansını karşılaştırma imkânı bulunabilecek hem de Box ve Jenkins ‘in belirlemiş olduğu ARIMA modeliyle performans kıyaslamasına gidilebilecektir. Eğer bir seri durağan değilse, sinir ağıyla modellemeden önce durağan hale getirilerek modelleme yapılmasıyla sinir ağı tahminlerinin doğruluğunun artacağına yönelik bulgular mevcuttur (Nelson

ve diğerleri, 1999: 359; Zhang ve Qi, 2005: 501; Jain ve Kumar, 2007: 585). Dolayısıyla IBM verisi durağan bir yapıya sahip olmadığından farkı alınarak durağanlaştırılmış ve farklar üzerine sinir ağı modelleri kurulmuştur. Tüm üç veri setine de Hyndman's Time Series Data Library (Hyndman, 2012) sitesinden ulaşılabilir.


Şekil 10: Kanada Vaşak Serisi



Şekil 11: Güneş Lekesi Serisi



Şekil 12: IBM Hisse Senedi



Gerçek veri setleriyle yapılan sinir ağı tasarımı simülasyon verisiyle yapılan deneyle benzer şekilde oluşturulmuştur. Girdi ve gizli hücre sayıları 1 ‘den başlatılarak ardışık olarak 10 hücreye kadar çıkartılmıştır. Doğrulama seti hacminin etkisini incelemek amacıyla, yine doğrulama setlerinin az önce ayrıntıları verildiği gibi üç seviyede oluşturulduğu deneyler düzenlenmiştir. Oluşturulan deneyin kapsamının yol açtığı zaman kısıtı nedeniyle simülasyon deneyinde deneme sayısı bir faktör olarak incelenmemiştir. Bu işlem gerçek veri setleri üzerinde, gürültü seviyesi faktörü yerine deneme sayısı faktörünün alınmasıyla gerçekleştirilmiştir. Farklı başlangıç ağırlık değerlerinden kaynaklanan her bir girdi-gizli kombinasyonu için sırayla 10, 30 ve 50 ‘şer denemeli sinir ağı tasarımları oluşturulmuştur. Böylece deneme sayılarının bir faktör olarak, her iki seçim yönteminde bir etkisinin olup olmadığının araştırılması olanaklı hale gelmiştir. Yapılan sinir ağı modelleme çalışmaları incelendiğinde, deneme sayısı olarak 10, 30 ve 50 denemenin yaygın olarak araştırmacıların isteğine göre yapıldığı görülmektedir. Bu çalışmayla bu keyfi olarak belirlenen parametrenin önemli bir unsur olup olmadığı da deneysel şekilde incelenebilecektir. Her gerçek veri setinde uygulanan bu tasarımın şeması, Tablo 2 olarak aşağıda verilmiştir. Ayrıca, klasik ve GGD ayrışımı seçim yöntemlerinin birbirlerine istatistiksel olarak üstünlüğü olup olmadığını belirleyebilmek için her deney faktör seviyesi kombinasyonu 50 kez tekrarlanmıştır. Bu planlanan tasarımı gerçekleştirebilmek amacıyla her gerçek veri seti için 1.350.000 ($9 \times 50 \times 3000$) adet olmak üzere toplamda 4.050.000 ($3 \times 1.350.000$) tane sinir ağı modeli kurulmuştur.

Takip eden paragraflarda, simülasyon ve gerçek veri setlerine ilişkin deneylerin ortak parametre değerlerine dair bilgiler verilmektedir.

Tablo 2: Gerçek Veriler İçin Oluşturulan Deneyin Tasarım Şeması

	10 Deneme	30 Deneme	50 Deneme
Doğrulama Hacmi 1	50 sinir ağı deneyi		
Doğrulama Hacmi 2			
Doğrulama Hacmi 3			

Bu çalışmada, tek gizli katmana sahip ileri beslemeli sinir ağı modeli kullanılmıştır. Dikkat edilmesi gereken bir nokta, sadece bir dönem sonrası (one-step-ahead) tahminleri yapılmıştır. Bir dönem sonrası tahminlerinin incelenecek olması sebebiyle çıktı katmanı doğal olarak bir hücreden oluşturulmuştur. Tüm gizli hücrelerde aktivasyon fonksiyonu olarak sinir ağıyla zaman serisi tahminlemesi için en popüler seçim olan lojistik fonksiyondan, çıktı hücresinin aktivasyon fonksiyonu ise doğrusal aktivasyon fonksiyonundan yararlanılmıştır. Elde edilen hataya göre, hücreler arasındaki bağlantı ağırlıklarını değiştirerek ağın öğrenmesini sağlamada geri yayılım algoritmasıyla uyum içinde çalışabilen Levenberg-Marquardt optimizasyon algoritmasından faydalanılmıştır. Ayrıca veriler girdi hücresine sokulmadan önce, analizin Matlab ‘de yapılmasından ötürü Matlab ‘in veri ön işleme fonksiyonlarından biri olan mapminmax fonksiyonu kullanılarak veriler -1 ile 1 arasında ölçeklendirmeye tabi tutulmuşlardır. Aşağıda bu ölçeklendirmenin formülasyonu verilmiştir. Böylece girdi değerleri arasındaki büyüklük farklılığından doğan etkinin minimize edilmesi ve öğrenme algoritmasının doğruluğunun arttırılmasına çalışılmıştır.

$$y_i = y_{min} + (y_{mak} - y_{min}) \times \frac{(x_i - x_{min})}{(x_{mak} - x_{min})} \quad (3.20)$$

Yukarıdaki formülasyonda y_i ölçeklendirilmiş değeri, y_{mak} ve y_{min} ise sırasıyla ölçeklenecek değerin maksimum ve minimum değerlerini göstermektedir.

Burada sırasıyla 1 ve -1 'dir. x_i gözlem değerini ve x_{mak} ve x_{min} tüm gözlemlerin maksimum ve minimum değerini göstermektedir.

Deneyin sonucunda oluşturulan modellerin test seti üzerinde karşılaştırmasını yapmak için iki klasik doğruluk ölçüsü olan MSE ve MAE kullanılmıştır. Bu iki kriterin tahmin metotlarını her zaman eşit bir şekilde sıralamadıkları ve birbiriyle çelişen sonuçlar verebilecekleri bilinmektedir. Böylece bu iki kriterden faydalanarak elde edilen sonuçların, herhangi bir hata ölçüm istatistiğinin seçimine bağımlı olup olmadığının gösterilmesi amaçlanmıştır.

Sinir ağlarıyla yapılan tahminleme çalışmalarını incelediğimizde çok azının ulaştıklarını iddia ettikleri sonuçları istatistiksel testlerle desteklediklerini görmekteyiz (Kang, 1991: 59; Gorr ve diğerleri, 1994: 27; Hu ve diğerleri, 1999: 207; Walczak, 2001: 209). Ancak ortalama tahmin hatası varyansının sıklıkla görece yüksek olması, karşılaştırmalı tahmin sonuçlarını yorumlamada istatistiksel testlerin önemini ortaya çıkarmaktadır. İstatistiksel performans karşılaştırma testlerinin yapılmasıyla elde edilen tahminlerin güvenilirliği hakkında daha objektif bilgiye ulaşılabilir. Ortalama doğruluklar arasındaki fark göreceli olarak büyük gözükse bile sadece ortalama doğruluk ölçüsüne dayanarak iki farklı yöntemin performansları arasında ayırma gitmek güvenilir olmayabilecektir. Dolayısıyla bu çalışmada yapılan her performans karşılaştırılmasının istatistiki testlerle desteklenerek yorumlanmıştır.

3.5.4. Deneylere Ait Sonuçlar

Bu bölüm içerisinde, ilk olarak simülasyon verilerine ve ardından gerçek veri setlerine ilişkin sonuçlara yer verilecektir. Bu işlem yerine getirilirken sadece klasik seçim yöntemiyle Girdi-Gizli-Deneme ayrışımına dayanan seçimin performans kıyaslaması yapılmayacaktır. Aynı zamanda, GGD ayrışımının her bir alt bileşeninin ardışık kullanılmasıyla ortaya çıkan seçim sonuçları da incelenecektir. Böylece, GGD ayrışımıyla model seçimindeki üç adımın ardışık şekilde bir bütünü oluşturarak model seçmede fayda sağladığını görmek amaçlanmıştır. Öncelikle sadece girdi ayrışımı yapılarak elde edilen sonuçlar, ardından hem girdi hem gizli hücre ayrışımı yapılarak elde edilen sonuçlar ve son olarak da girdi-gizli ve TOPSIS yöntemi yardımıyla deneme ayrışımı yapılarak elde edilen sonuçlar klasik seçim yöntemiyle

karşılaştırma yapmak amacıyla verilmiştir. Örneğin, sadece girdi ayrışımı yapılmasının model seçmede yeterli olabileceği gizli hücre ayrışımına gerek olmadığı düşünülebilir. Özellikle gizli hücrenin tahminleme performansı üzerinde etkisinin bulunmadığını veya girdi hücrelerinin gizli hücreye göre çok daha önemli olduğunu iddia eden çalışmalar mevcutken bu düşünceye olan inançta artış beklenmesi doğaldır. Bu iddia, sadece girdi ayrışımı yapılarak doğrulama seti üzerindeki en küçük hata değerine sahip denemenin seçilmesi ile hem girdi hem gizli ayrışımı yaparak yine doğrulama seti üzerindeki en küçük hata değerine sahip denemeden elde edilen performansların karşılaştırılmasıyla test edilmiştir. Diğer taraftan girdi ve gizli uzayı belirlenmişken bu uzaydan doğrulama seti üzerinden en küçük hata değerine sahip denemenin seçilmesinin yeterli olduğu, topsis yöntemi yardımıyla denemeler arasından hem eğitim hem doğrulama seti üzerinde göreceli olarak iyi bir performans gösteren denemenin seçilmesinin gerçekte önemli olmadığı düşünülebilir. Bu iddia da sadece girdi-gizli ayrışımı yapılarak ve doğrulama setindeki en küçük hata değerine sahip denemenin seçilerek elde edilen performans değerlerinin GGD ayrışımı yapılarak elde edilen performans değerleriyle karşılaştırması yapılarak test edilmiştir. Model seçim stratejisindeki üç bileşenin ardışık olarak sistemi oluşturmaları sebebiyle, bu ardışıklıktaki her bir bileşen sırasıyla sisteme eklenerek elde edilen performans sonuçlarının karşılaştırılmasıyla her bir bileşenin sistem performansı üzerindeki etkisi araştırılmıştır. Dolayısıyla her bir bileşenin eklenmesiyle daha iyi performans değerlerine ulaşılabileceği ve her birinin gerekli olduğu iddiası incelenmiştir. Bu ardışıklığın dışındaki, mesela önce gizli ayrışımı ardından girdi ve sonra deneme ayrışımı gibi diğer kombinasyonlar çok gerçekçi bulunmadığından test edilmesine gerek duyulmamıştır. Ayrıca bu çalışmada, gerçek veriler için daha önce yapılan çalışmalarda tespit edilmiş ARIMA modellerinin test seti tahmin doğrulukları klasik ve GGD ayrışımı seçim stratejilerinin tahmin doğruluklarıyla da kıyaslanmıştır.

Takip eden son iki alt bölümde ise yapılan deneysel tasarım sürecindeki iki faktör olan doğrulama hacmi ve deneme sayısının iki seçim stratejisi üzerindeki etkisi incelenmiştir. Doğrulama hacminin sınır ağı performansını etkilemedeki gücü biliniyorken (Faraway, 1992: 220; LeBaron ve Weigend, 1998: 213), doğrulama hacmine karşı daha dirençli bir seçim stratejisi oldukça değerli olacaktır. Bu sayede,

özellikle eldeki veri az ise daha düşük hacimli doğrulama seti kullanılarak eğitim setine daha çok veri ayrılabilmesi sağlanabilecektir. Ayrıca optimale yakın bir doğrulama seti hacmi deney öncesinde bilinmediğinden, daha dirençli bir seçim stratejisiyle doğrulama seti hacminin ne olması gerektiğine dair karar daha kolay ve güvenli bir şekilde verilebilecektir. Özellikle finansal serilerle tahminleme yapılırken son dönemin gelecekte gerçekleşecek gözlemler üzerinde daha etkili olduğu bilindiğinden (Walczak, 2001: 203), daha küçük doğrulama seti hacmiyle daha çok son döneme ait gözlem eğitim setine eklenebilir ve daha iyi tahmin sonuçlarına ulaşılabilir. Tarafımızca deneme sayısı miktarının bir deney faktörü olarak alındığı çalışmaya rastlanmamıştır. Sadece bir çalışmada, deneme sayısının arttırılmasının aşırı uyuma yakalanma olasılığını arttırabileceğinden bahsedilmiştir (Nakamura, 205: 375). Buna dayanarak, deneme sayısı gerçek veriler üzerinde bir deney faktörü olarak alınmış ve klasik seçim yönteminde bir etkisinin olup olmadığı araştırılmıştır. Ayrıca GGD ayrışımı stratejisi, deneme ayrışımı yaparken hem eğitim hem doğrulama setinde iyi performans gösteren bir ağ arandığından, bu iki koşulun tam olarak sağlanabilmesi için daha çok deneme sayısına gereksinim duyabilir. Dolayısıyla, deneme sayısı üç faktör seviyesinde oluşturularak son alt bölümde bu iddianın da incelenmesi yoluna gidilmiştir.

3.5.4.1. Simülasyon Verilerine İlişkin Sonuçlar

Hangi seçim stratejisinin daha iyi tahmin doğruluğunu verdiğini göstermek amacıyla MSE değerlendirme kriteri temel alınarak en iyi ağlar seçilmiştir. Tahminler istatistiksel olarak bağımsız olmadıklarından ve her zaman normal dağılmadıklarından tahminlerin MSE ve MAE ölçülerini karşılaştırmak için eşleştirilmiş t-testi kullanılmıştır. Örnek hacmi makul ölçüde büyük olduğunda; bu test verinin dağılımına, varyansın homojen olmamasına ve istatistiksel bağımlılığa karşı dirençlidir (Iman ve Conover, 1983: 358).

3.5.4.1.1. AR2 Veri Seti

AR2 simülasyon verilerinin sadece 1.gürültü seviyesi ve 3 doğrulama seti seviyesindeki sonuçlarına ait tablo ve grafiklerine bu bölüm içerisinde yer verilmiştir. Diğer gürültü ve doğrulama seviyelerindeki sonuçları ile doğrusal olmayan otoregresif modelin her bir gürültü ve doğrulama seviyelerindeki sonuç ve grafiklerine, benzer sonuçların elde edilmesi sebebiyle Ekler bölümü içerisinde yer verilmiştir. Ancak deneyin toplamında elde edilen sonuçların yorumlanması ve tartışılması yine bu bölümde bulunmaktadır.

Tablo 3 ve Tablo 4 ‘de AR2 modeli, 1.Gürültü seviyesi ve 25 Doğrulama hacminde sırasıyla Klasik seçim (K), Girdi ayrışımı (G), Girdi-Gizli ayrışımı (G-G) ve GGD ayrışımı yöntemlerinin seçtiği ağların test seti üzerindeki MSE ve MAE ölçülerine göre tanımlayıcı istatistik değerleri verilmiştir. Bu değerler daha önce belirtildiği gibi, her bir faktör kombinasyonundaki 50 tane zaman serisi üzerine kurulan sinir ağlarının her birinde kullanılan seçim yöntemlerinin ürettiği ölçülerdir. Tablo 3 ‘ün ortalama değerine baktığımızda (Ort), G ayrışımının G-G ayrışımına göre daha küçük ortalama değer ürettiği görülmektedir. Bunun anlamı, gizli ayrışımının girdi ayrışımından sonra performans üzerinde bir katkı sağlamadığı olabilir. Ancak aynı tabloda kırpılmış ortalama (Kırp Ort) değerlerini karşılaştırdığımızda, uç değerlerin bu sonuca neden olduğu görülür. Aslında, gizli hücre ayrışımı deneyin bu faktör seviyelerinde performans üzerinde olumlu bir etki yaratmıştır. Hemen belirtmelidir ki burada kullanılan kırpılmış ortalama, veriler sıralanmışken alttan ve üstten yüzde beş gözlemin atılması sonucu hesaplanmıştır.

Tablo 3: AR2 Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen MSE Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,697	0,229	1,446	1,621	1,376	5,84	37,70	0,000
G	1,374	0,055	1,357	0,389	1,307	0,67	0,70	0,192
G-G	1,416	0,193	1,229	1,366	1,231	6,39	43,54	0,000
G-G-D	1,136	0,048	1,105	0,338	1,101	1,59	4,53	0,000

Tablo 4: AR2 Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen MAE Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	0,965	0,0258	0,953	0,182	0,936	0,98	1,10	0,018
G	0,930	0,0185	0,925	0,131	0,925	0,53	0,36	0,213
G-G	0,888	0,0195	0,878	0,138	0,885	1,17	3,57	0,002
G-G-D	0,840	0,0150	0,836	0,106	0,860	0,48	0,46	0,404

Tanımlayıcı istatistik tablolarında, elde edilen tahmin performans ölçülerinin dağılımına ilişkin istatistiklerin de bulunduğu görülmektedir. Bu tahmin değerlendirme ölçülerinin dağılımına ilişkin çeşitli istatistiklere tarafımızca daha önce başka bir çalışmada rastlanmadığından, ileride bu alanda çalışacaklara fayda sağlayabileceği düşünülerek yer verilmiştir. Ayrıca, sonraki alt bölümlerde faydalanılan parametrik olmayan testlerin kullanılma nedenine cevap olma niteliği taşımaktadır. Normallik varsayımını test etmek için mevcut çok sayıda test arasından Shapiro-Wilk sınaması seçilmiştir. Bunun nedeni, diğer normallik testlerine göre daha güçlü olduğunu destekleyen çalışmaların mevcut olmasıdır (Razali ve Wah, 2011; 21). Tablo 3 ve 4 ‘den görülen, MAE hata ölçüsünün normallik varsayımına MSE hata ölçüsüne göre daha fazla uyum sağladığıdır. Az önce yapılan değerlendirmelerin AR2 modeli, 1.Gürültü seviyesi ve diğer doğrulama hacimlerine ait benzer tablolarda da geçerli olduğu görülebilir. Hata ölçülerine ait tanımlayıcı istatistik tablolarından, GGD ayrışımının her ardışık adımının daha doğru modellerin seçimine yönelik olumlu katkı yaptığı sonucuna varılabilir. Bunun anlamı, her adımın nihai ağı seçmede gerekli olduğudur. Yalnız 75 doğrulama hacmine sahip deneyin tablolarında (Tablo 9 ve Tablo 10), doğrulama seti hacmi en büyükken G-G ve G-G-D ayrışimleri arasında bir ortalama performans farklılığının bulunmadığına yönelik delile rastlanmıştır. Bu ve diğer durumlara ait sonuç ve yorumlar eşleştirilmiş t-testine dayanarak bu alt bölüm içerisinde verilecektir.


Tablo 5, 8, 11 ‘de aynı gürültü seviyesi farklı doğrulama seti hacimlerinde Klasik, Girdi ayrışımı ve Girdi-Gizli ayrışım seçim yöntemlerinin ortalama gecikme (OrtGecikme), ortalama gizli (OrtGizli), gecikme sayısının standart sapması (StdGecikme) ve gizli sayısının standart sapması (StdGizli) değerleri verilmiştir. Ayrıca, AR2 simülasyon verisinin gerçek gecikme sayısı bilindiğinden her bir seçim yönteminin toplam 50 zaman serisi içinde gecikme uzayını doğru bulma oranları (GUDBO) tablolara eklenmiştir. Böylece, klasik seçim yöntemiyle GGD ayrışımının

gerçek gecikme sayısını ne kadar doğrulukla tespit ettikleri görülebilecektir. Bu tablolardan, klasik seçim yönteminin en düşük doğrulama seti hacminde gerçek uzayı nerdeyse hiç tespit edemediği (0,02) ancak önerilen yaklaşımın bu seviyede bile yüzde 38 doğrulukla tespit ettiği görülmektedir. Doğrulama seti hacmi arttıkça, her iki yönteminde gerçek gecikme yapısını daha doğru bulması beklenen bir durumdur. Ancak en yüksek doğrulama seti hacminde hala iki yöntemin gerçek gecikme yapısını doğru bulma oranları arasında ciddi fark vardır (Tablo 11). Bu durum, tablolardan takip edileceği üzere ortalama gecikme sayılarına da yansımaktadır. Doğrulama hacmi arttıkça yöntemlerin ortalama gecikme sayısı gerçek gecikme sayısına yaklaşmaktadır. Ek olarak tablolardan ortalama gizli hücre sayıları incelendiğinde, önerilen seçim stratejisinin hem gecikme hem de gizli hücre sayısı bakımından daha basit sinir ağı modelleri seçtiği görülmektedir. Bu durum, daha basit modellerin test seti üzerindeki daha iyi performansların kaynağı olduğu çıkarımının yapılmasına sebep olmaktadır. Son olarak, önerilen yaklaşım girdi ayrışımıyla gecikme sayısını düşürmüştür ancak sadece girdi ayrışımıyla gizli hücre sayısı bakımından basit modellerin elde edilemediği, gizli ayrışımının da basit modellerin elde edilmesi bakımından önemli bir işlevi olduğu görülmüştür.

Tablo 5: AR2 Modeli, 1.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,02	6,920	2,221	6,620	2,522
Girdi Ayrışımı	0,38	3,640	2,058	7,060	2,307
Girdi-Gizli Ayrışımı	0,38	3,640	2,058	4,460	2,837


Şekil 13: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 14: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 15: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 16: AR2 Verileri, 1. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Klasik ve önerilen seçim yönteminin 1.Gürültü seviyesi ve 25 doğrulama seti hacminde, buldukları girdi hücre sayılarına ilişkin frekans grafikleri Şekil 13 ve 14 ‘de verilmiştir. Ayrıca aynı faktör seviyelerinde bulunmuş gizli hücre sayılarına ait grafikleri de Şekil 15 ve 16 ‘dadır. Görüleceği gibi, bu faktör seviyesinde klasik yöntem nadiren gerçek gecikme sayılarını yakalarken önerilen yaklaşım çoğunlukla tespit edebilmiştir. Klasik yöntem hem gecikme hem de gizli hücre sayısı bakımından daha karmaşık modelleri seçmiştir. Aynı gürültü seviyesi farklı doğrulama seti hacimlerinde her iki seçim yöntemine ait girdi ve gizli hücre sayısı grafikleri, Şekil 17-24 arasında verilmiştir. Grafiklerden anlaşılacağı üzere, doğrulama hacmi arttıkça her iki yöntemin de daha doğru ve basit modeller seçme şansı artmaktadır. Ancak hala en büyük doğrulama hacminde bile, her iki açıdan da önerilen yaklaşımın üstünlüğü devam etmektedir.

Tablo 6: AR2 Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,306	0,052	1,277	0,371	1,198	0,95	0,14	0,001
G	1,850	0,502	1,235	3,550	1,127	6,37	42,66	0,000
G-G	1,596	0,490	1,104	3,466	1,102	7,00	49,33	0,000
G-G-D	1,041	0,033	1,026	0,235	1,019	0,83	0,89	0,028

Tablo 7: AR2 Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	0,901	0,019	0,895	0,132	0,877	0,66	-0,10	0,072
G	0,891	0,025	0,873	0,174	0,847	1,56	2,58	0,000
G-G	0,852	0,0201	0,840	0,142	0,833	1,90	6,96	0,000
G-G-D	0,818	0,015	0,815	0,103	0,806	0,42	0,07	0,354


Tablo 8: AR2 Modeli, 1.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,10	6,500	2,765	5,780	2,306
Girdi Ayrışımı	0,50	2,520	1,374	6,480	2,589
Girdi-Gizli Ayrışımı	0,50	2,520	1,374	3,260	2,717


Şekil 17: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 18: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 19: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 20: AR2 Verileri, 1. Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Tablo 9: AR2 Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,256	0,039	1,250	0,273	1,229	0,29	-0,33	0,735
G	1,171	0,040	1,159	0,286	1,142	1,01	2,62	0,024
G-G	1,036	0,025	1,039	0,177	1,018	-0,22	0,03	0,866
G-G-D	1,039	0,025	1,043	0,177	1,076	-0,31	-0,05	0,771

Tablo 10: AR2 Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	0,883	0,013	0,882	0,092	0,891	-0,04	-0,97	0,147
G	0,851	0,013	0,849	0,093	0,859	0,35	0,69	0,548
G-G	0,813	0,010	0,815	0,072	0,808	-0,49	0,74	0,263
G-G-D	0,814	0,010	0,815	0,075	0,818	-0,26	0,36	0,772


Tablo 11: AR2 Modeli, 1.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi Ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,16	5,780	2,597	5,900	2,636
Girdi Ayrışımı	0,60	2,600	1,161	5,880	2,715
Girdi-Gizli Ayrışımı	0,60	2,600	1,161	2,420	1,819


Şekil 21: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 22: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 23: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı




Şekil 24: AR2 Verileri, 1. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı




Klasik seçim yönteminin doğru gecikme yapısını bulamamasının nedeni olarak, doğrulama setinin kendine ait özelliklerine uyum sağlamış modeli seçmesi olduğu söylenebilir. GGD ayrışımı ise doğrulama seti üzerine kurulan uzayda ortalama performansları temel aldığından, gerçek gecikme yapısını daha iyi yakaladığı Tablo 5-8-11 'de ortaya konmuştur. Ancak özellikle bu simülasyon verisinde, test seti ile doğrulama seti arasında yapısal bir farklılık yokken neden doğrulama setinde en iyi performansa yol açan gecikme her zaman test setinde de en iyi performansa yol açmamaktadır? Başka bir deyişle, test seti ile doğrulama seti aynı veri üretim sürecinden türetilmişken önerilen seçim stratejisinin neden gecikme uzayını doğru bulma oranı 1 değildir? Aslında bu soru beraberinde “Doğrulama seti eldeki zaman serisinin iyi bir temsilcisi değil mi?” sorusunu da akla getirmektedir. Son sorudan başlayarak cevap aranması ilk sorunun da kısmen cevabı olacaktır. Bu amaçla, öncelikle türetilen veri AR2 modelinden elde edildiğinden sadece kısmi otokorelasyon grafiklerine bakalım. Şekil 25, AR2 modelinden türetilen bir zaman serisinin kısmi otokorelasyon grafiği iken, özellikle farklı doğrulama hacimlerinin bu kısmi otokorelasyon yapısıyla aynı olup olmadığını incelemek için Şekil 26-28 incelenebilir. Bu şekiller sırasıyla en büyük doğrulama hacminden en küçük hacme doğru elde edilen kısmi otokorelasyon yapılarını göstermektedir. Bu şekillerden doğrulama seti hacmi büyük olanın serinin tümüne en yakın yapıya sahip olduğunu, hacim küçüldükçe bozulmanın arttığı ve nihayetinde en küçük hacmin serinin tümüyle aynı yapıya sahip olmadığı anlaşılmaktadır. Bir başka deyişle, en küçük

hacimli doğrulama setinden alınan bu örnek serinin iyi bir temsilcisi değildir. Dolayısıyla da doğru gecikme uzayını tespit etmesi beklenemez. 25 doğrulama seti hacmine sahip deneyde doğru gecikme uzayını bulma oranının en düşük çıkmasının da nedeni budur. Doğrulama hacminin arttırılmasıyla bunun üstesinden gelinebilir. Nitekim daha önce verilen tablolardaki sonuçlar da bunu destekler niteliktedir. Ancak unutulmamalıdır ki doğrulama hacmini arttırmak, eldeki veri sayısı kısıtlıyken ve son dönem verilerinin gelecek gözlemler üzerinde daha etkin olduğu durumlarda pek mümkün olmamaktadır. Tüm bunlara rağmen, önerilen yaklaşımın küçük doğrulama hacimlerinde bile klasik seçim yönteminden daha iyi çalıştığı görülmektedir (Tablo 5). Ayrıca, Şekil 29 ve 30 'da aynı veri üretim sürecinden türetilmiş farklı zaman serilerinin 50 birimlik doğrulama seti hacimlerinde türettikleri kısmi otokorelasyon grafikleri verilmiştir. Görüleceği üzere, aynı veri hacimlerinde farklı kısmi otokorelasyon yapıları ortaya çıkmıştır. Bunun nedeni, gürültülerin doğrulama verileri üzerinde etkin olarak yanlış gecikme yapısının seçilmesine yol açmasıdır. Başka bir ifadeyle, doğrulama seti hacmi tüm gürültüleri bertaraf edip ana seriye doğru şekilde yakınsayacak kadar büyük değildir.


Şekil 25: AR2 Modelinden Türetilen Bir Simülasyon Verisinin Kısmi Otokorelasyon Grafığı




Şekil 26: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 75 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği




Şekil 27: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği




Şekil 28: AR2 Modelinden Türetilen Bir Simülasyon Verisinin 25 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği



Şekil 29: AR2 Modelinden Türetilen İkinci Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği



Şekil 30: AR2 Modelinden Türetilen Üçüncü Simülasyon Verisinin 50 Hacimli Doğrulama Setinin Kısmi Otokorelasyon Grafiği



Tanımlayıcı istatistik tablolarından, klasik ve GGD ayrışımıyla seçim yöntemleri arasında istatistiksel olarak anlamlı bir ortalama performans farklılığının olup olmadığı anlaşılmamaktadır. Bu amaç için, oluşturulan deneyin tüm faktör seviyeleri ve her iki değerlendirme kriteri üzerinde eşleştirilmiş t-testi yapılmıştır. Öncelikle Tablo 12 ‘de klasik ve GGD ayrışımı arasındaki test sonuçları verilmiştir. Bu tabloda, ortalama fark (Ort Fark) ve anlamlılık düzeyleri (P-Değeri) bulunmaktadır. Tablo 13 ve 14, önerilen seçim stratejisinin her bir adımının yani gecikme, gizli, deneme ayrışımının gerekli olup olmadığı iddiasının istatistiksel olarak test edilmesine yönelik oluşturulmuştur. Tablo 12, 13 ve 14 ‘de, ortalama farkı pozitif ve anlamlılık düzeyi yüzde 0,05 ‘in altında olan test sonuçları koyu renk ile gösterilmiştir. Tablo 15 ‘de ise Tablo 12, 13 ve 14 ‘de yapılan eşleştirilmiş test

sonuçlarının tablo kodlaması bulunmaktadır. Bu tabloda, ortalama farkı pozitif ve anlamlılık düzeyi yüzde 0,05 'in altında olan test sonuçları artı (+) işaretiyle kodlanmıştır. Bunun anlamı, önerilen stratejinin istatistiksel olarak daha iyi bir ortalama performansa sahip olduğudur. Ortalama fark pozitif ancak anlamlılık düzeyi 0,05 'in üstünde ise test sonucu farksızlık anlamına gelen yuvarlak (o) işaretiyle kodlanmıştır. Başka bir deyişle, iki seçim yöntemi arasında istatistiksel olarak anlamlı olacak bir ortalama performans farklılığı bulunmamaktadır. Benzer yorum, ortalama fark negatif ancak anlamlılık düzeyi 0,05 'in üstündeyken de geçerlidir. Son olarak, eğer performans karşılaştırmasında ortalama fark negatif ve anlamlılık düzeyi 0,05 'in altında ise eksi (-) işaretiyle tabloda kodlanmıştır. Bunun anlamı, önerilen stratejinin test seti üzerinde daha kötü bir ortalama performansa yol açtığıdır.

Tablo 15, kodlama yardımıyla tüm test sonuçlarının bir tabloda görünebilmesini ve yorumlama kolaylığı sağlamaktadır. AR2 veri seti için, Tablo 15 'den şu yorumlar çıkarılabilir: Önerilen seçim stratejisi hem klasik hem de kendi alt adımlarına karşı istatistiksel olarak hiç anlamlı bir ortalama performans düşüklüğü sergilememiştir. Yani – işareti tabloda bulunmamaktadır. En çok pozitif işarete, en küçük doğrulama hacminde ulaşılmıştır. En büyük doğrulama hacminde, GG ayrışımı ile GGD ayrışımı arasındaki performans farklılığı azalmıştır. Bunun anlamı, doğrulama hacmi eğitim setindeki desenleri de temsil edecek kadar büyümüştür ve sadece doğrulama seti performansına bakmanın küçük doğrulama hacim seviyelerine göre daha yeterli hale geldiğidir. Gürültü seviyesi arttıkça benzer performanslar ortaya çıkmaya devam etmiştir. Önerilen yöntemin her bir ardışık adımı bir öncekine göre performansı daha geliştirmiştir. Bu, GG ayrışımının G ayrışımından daha çok o işareti üretmesinden ve GGD ayrışımının da GG ayrışımına göre daha çok + işareti üretmesinden anlaşılmaktadır. Böylece sadece girdi ayrışımı yapılmasının yetersiz olduğu, gizli ayrışımının da performans üzerinde olumlu etkiye yol açtığı söylenebilir. Yani, gizli hücrelerin sinir ağı performansında anlamlı bir etkisi bulunmaktadır. Ayrıca, hem eğitim hem de doğrulama setinde iyi performans gösteren bir ağ seçimi de ulaşılan performans üzerinde etkili olmuştur. Son olarak, değerlendirme kriteri olarak MAE 'nin kullanılması önerilen seçim stratejisinin daha çok sayıda istatistiksel olarak anlamlı pozitif ortalama performans üretmesine neden olmaktadır.

Tablo 12: AR2 Modeli Klasik ve GGD Ayırışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	0,561	0,125	1,172	0,215	2,623	0,294
	P-Değeri	(0,008)	(0,000)	(0,000)	(0,000)	(0,002)	(0,000)
Doğrulama2	Ort Fark	0,265	0,083	1,475	0,167	16,89	0,287
	P-Değeri	(0,000)	(0,000)	(0,060)	(0,000)	(0,140)	(0,014)
Doğrulama3	Ort Fark	0,216	0,069	0,902	0,133	1,911	0,162
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,007)	(0,000)

^aFarklılık = K-GGD: pozitif değerler GGD ayırışımıyla seçimin avantajını göstermektedir.

Tablo 13: AR2 Veri Seti G ve GGD Ayırışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	0,238	0,089	1,060	0,146	2,395	0,199
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,036)	(0,000)
Doğrulama2	Ort Fark	0,809	0,073	1,526	0,121	1,302	0,143
	P-Değeri	(0,056)	(0,000)	(0,064)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	0,132	0,037	0,652	0,083	0,842	0,077
	P-Değeri	(0,000)	(0,000)	(0,005)	(0,000)	(0,030)	(0,002)

^aFarklılık = G-GGD: pozitif değerler GGD ayırışımıyla seçimin avantajını göstermektedir.

Tablo 14: AR2 Veri Seti GG ve GGD Ayırışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	0,280	0,047	0,763	0,087	0,378	0,070
	P-Değeri	(0,072)	(0,001)	(0,016)	(0,000)	(0,281)	(0,008)
Doğrulama2	Ort Fark	0,555	0,035	0,878	0,065	0,478	0,035
	P-Değeri	(0,131)	(0,017)	(0,180)	(0,011)	(0,008)	(0,011)
Doğrulama3	Ort Fark	-0,003	-0,001	0,266	0,044	0,159	0,024
	P-Değeri	(0,393)	(0,382)	(0,000)	(0,000)	(0,105)	(0,079)

^aFarklılık = GG-GGD: pozitif değerler GGD ayırışımıyla seçimin avantajını göstermektedir.

Tablo 15: AR2 Veri Seti İçin Tablo Kodlama Sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	o	+	+	+	o	+
Doğrulama2	K	+	+	o	+	o	+
	G	o	+	o	+	+	+
	GG	o	+	o	+	+	+
Doğrulama3	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	o	o	+	+	o	o

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

3.5.4.1.2. GAR Veri Seti

GAR modeline ilişkin deneyin 1.gürültü seviyesi ve üç doğrulama seti hacmindeki GUDBO, ortalama gecikme, gecikme sayısının standart sapması, ortalama gizli ve gizli sayısının standart sapması Tablo 16, 17 ve 18 ‘de verilmiştir. Tablo 16, 17 ve 18 ‘den görüleceği üzere, AR2 deneyi ile de benzer sonuçlar elde edilmiştir. En küçük doğrulama seti seviyesinde klasik yöntem neredeyse doğru gecikme uzayını hiç tespit edememişken, önerilen strateji bu küçük doğrulama hacminde bile başarı sağlamıştır. Her iki yönteminde doğrulama hacmi arttıkça doğru uzayı bulma şansı artmış ancak aralarındaki fark büyük ölçüde değişmemiştir. Ayrıca doğrulama hacmi arttıkça daha basit modellerin özellikle girdi-gizli ayrışımıyla seçildiği görülmektedir. İlerleyen bölümlerde doğrulama hacminin performans üzerindeki etkisi incelenecektir. Şuan görülen, doğrulama hacmi arttıkça basit modellerin seçildiğidir. Dolayısıyla doğrulama hacminin etkisi araştırılırken bir bakıma daha basit modellerin test seti performansı üzerindeki etkisi de dolaylı olarak incelenmiş olacaktır.

Tablo 16: GAR Modeli ve 1.Gürültü Seviyesinde 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,02	6,340	2,512	6,320	2,583
Girdi Ayrışımı	0,40	3,040	2,515	6,900	2,426
Girdi-Gizli Ayrışımı	0,40	3,040	2,515	5,940	3,013

Tablo 17: GAR Modeli ve 1.Gürültü Seviyesinde 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,04	5,780	2,831	6,260	2,717
Girdi Ayrışımı	0,48	2,080	1,259	6,120	2,723
Girdi-Gizli Ayrışımı	0,48	2,080	1,259	4,020	2,818

Tablo 18: GAR Modeli ve 1.Gürültü Seviyesinde 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,12	5,100	2,816	5,480	2,468
Girdi Ayrışımı	0,56	1,720	1,051	6,240	2,818
Girdi-Gizli Ayrışımı	0,56	1,720	1,051	3,040	2,539

Tablo 19, 20 ve 21 ‘de GAR modeli için klasik ve GGD ayrışımıyla seçim yönteminin alt adımlarının, GGD ayrışımıyla karşılaştırılmasına yönelik olarak eşleştirilmiş t-testiyle yapılan ortalama performans değerlendirmesine ilişkin sonuçlar bulunmaktadır. Tablo 22 ‘de ise daha önce açıklanan şekilde oluşturulmuş tablo kodlaması verilmiştir. Tablo 22 ‘den şu yorumlar yapılabilir: Önerilen seçim stratejisi hem klasik yönteme göre hem de kendi alt adımlarına karşı istatistiksel olarak anlamlı bir ortalama performans düşüklüğü sergilememiştir. En çok pozitif işarete, yine en küçük doğrulama hacminde ulaşılmıştır. Küçük doğrulama hacimlerinde iyi bir şekilde çalışması istenen bir özelliktir. En büyük doğrulama hacminde, GG ayrışımı ile GGD ayrışımı arasındaki performans farklılığı azalmıştır. Gürültü seviyesi arttıkça benzer performanslar ortaya çıkmaya devam etmiştir. Önerilen yaklaşım, klasik yönteme ve her bir alt adıma karşı üstünlük sağlamıştır. Gizli hücre ayrışımının başka deyişle gizli hücrenin hesaba katılmasının ulaşılan performans üzerinde anlamlı bir etkisi olmuştur. Hem eğitim hem de doğrulama setinde iyi performans gösteren bir ağ seçimi, diğer bir ifadeyle deneme ayrışımı da özellikle doğrulama seti hacminin ilk iki seviyesinde, elde edilen sonuca olumlu katkı sağladığı görülmektedir. Son olarak, değerlendirme kriteri olarak MAE ‘nin kullanılmasının önerilen seçim stratejisinin daha çok sayıda istatistiksel olarak anlamlı pozitif ortalama performans üretmesine yol açabileceği anlaşılmaktadır.

Tablo 19: GAR Modeli Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	2,692	0,228	2,564	0,335	8,667	0,631
	P-Değeri	(0,100)	(0,000)	(0,002)	(0,000)	(0,002)	(0,000)
Doğrulama2	Ort Fark	0,285	0,098	1,611	0,210	3,282	0,272
	P-Değeri	(0,001)	(0,000)	(0,001)	(0,000)	(0,001)	(0,000)
Doğrulama3	Ort Fark	0,135	0,062	0,628	0,098	0,955	0,144
	P-Değeri	(0,008)	(0,000)	(0,001)	(0,000)	(0,000)	(0,000)

^aFarklılık = K-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 20: GAR Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	1,746	0,133	2,501	0,228	13,733	0,490
	P-Değeri	(0,119)	(0,003)	(0,021)	(0,002)	(0,025)	(0,000)
Doğrulama2	Ort Fark	0,150	0,044	0,709	0,106	2,930	0,187
	P-Değeri	(0,041)	(0,005)	(0,053)	(0,000)	(0,015)	(0,000)
Doğrulama3	Ort Fark	0,637	0,068	0,260	0,055	0,463	0,079
	P-Değeri	(0,080)	(0,003)	(0,022)	(0,000)	(0,038)	(0,004)

^aFarklılık = G-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 21: GAR Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	0,260	0,081	1,769	0,141	4,917	0,229
	P-Değeri	(0,002)	(0,000)	(0,046)	(0,002)	(0,006)	(0,000)
Doğrulama2	Ort Fark	0,044	0,020	0,422	0,054	2,723	0,165
	P-Değeri	(0,167)	(0,024)	(0,089)	(0,006)	(0,012)	(0,000)
Doğrulama3	Ort Fark	-0,004	0,014	0,408	0,046	-0,094	(0,007)
	P-Değeri	(0,467)	(0,083)	(0,025)	(0,006)	(0,332)	(0,375)

^aFarklılık = GG-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 22: GAR Veri Seti İçin Tablo Kodlama Sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Gürültü1		Gürültü2		Gürültü3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	o	+	+	+	+	+
	G	o	+	+	+	+	+
	GG	+	+	+	+	+	+
Doğrulama2	K	+	+	+	+	+	+
	G	+	+	o	+	+	+
	GG	o	+	o	+	+	+
Doğrulama3	K	+	+	+	+	+	+
	G	o	+	+	+	+	+
	GG	o	o	+	+	o	o

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

Bu bölüm içerisinde, özellikle gerçek gecikme yapısına önerilen seçim stratejisinin nasıl yakınsadığının araştırılması amacıyla doğrusal ve doğrusal olmayan simülasyon verileri üzerinde yapılan iki deneyde benzer sonuçlar elde edilmiştir. Sonraki bölümde, literatürde incelenmiş gerçek veriler üzerinde tasarlanan deneye ait sonuçlar verilecek ve önerilen seçim stratejisinin gerçek verilerdeki davranışı incelenecektir. Ayrıca bu veri setleri üzerinde daha önceden kurulmuş ARIMA modelleriyle karşılaştırmalar yapma imkânı bulunacaktır.

3.5.4.2. Gerçek Verilere İlişkin Sonuçlar

Önerilen seçim stratejisi incelenen iki simülasyon veri seti üzerinde oldukça tatmin edici sonuçlar vermiştir. Gerçek veri setleri üzerinde nasıl bir performans göstereceği sorusuna ise bu kısım içerisinde cevap aranmaya çalışılacaktır. Bu amaç için, Bölüm 3.5.3 ‘de ayrıntıları verilen üç veri seti incelenecektir. Elde edilen sonuçların irdelenmesine geçmeden önce, hatırlanmalıdır ki gerçek verilere ait deney tasarımı gürültü seviyesi faktörü yerini deneme sayısı faktörüne bırakmıştır.

3.5.4.2.1. Kanada Vaşak Serisi (Lynx)

Lynx verisine ait yapılan istatistiksel değerlendirmelerin sonuçları Tablo 23-26 ‘da verilmiştir. Tablo 23 ‘de klasik seçim yönteminin GGD ayrışımı yöntemiyle karşılaştırması amacına yönelik olarak yapılmış eşleştirilmiş t-testi sonuçları

bulunmaktadır. Tablo 24 ve 25, önerilen stratejinin performansının kendi alt adımlarıyla karşılaştırılmasına ait test sonuçlarını içermektedir. Bu tablolardan, karşılaştırılan iki seçim stratejisi arasındaki ortalama farklılığın hangi olasılık değerlerinde anlamlı olduğu bulunabilir. Tablo 26, bu üç tablonun 0,05 anlamlılık düzeyinde özetlenmiş halidir. Bu tablodan, önerilen stratejinin klasik seçime göre çoğunlukla anlamlı bir performans üstünlüğü gösterdiği anlaşılmaktadır. Ancak, özellikle girdi-gizli ayrışımı seçim stratejisiyle benzer bir performans sergilediği görülmektedir. Girdi ayrışımına karşı ise üçüncü doğrulama seviyesinde kesin bir üstünlük sağlanmıştır. Toplamda üç kez de kendi alt adımlarından istatistiksel olarak anlamlı bir performans düşüklüğü sergilemiştir. Simülasyon verileriyle yapılan analizden farklı olarak en çok pozitif işaret en büyük doğrulama hacminde ortaya çıkmıştır. Farklı deneme seviyelerinde ortaya çıkan pozitif işaret sayılarına baktığımızda, en az 1.deneme seviyesinin pozitif işaret sayısına sahip olduğu görülmektedir. Ayrıca iki performans düşüklüğü de bu deneme seviyesinde elde edilmiştir. Her ne kadar ilerleyen bölümde, deneme seviyesinin performans üzerinde etkili olup olmadığı hem klasik hem de önerilen yaklaşım incelenecek olsa da deneme seviyesinin önerilen yaklaşımın performansına etki ettiğine dair delil bulunmaktadır. Simülasyon verilerine ait sonuçlara benzer olarak, değerlendirme kriteri olarak MAE ‘nin kullanılması önerilen seçim stratejisinin daha çok sayıda istatistiksel bakımdan anlamlı pozitif ortalama performans üretmesine sebep olduğu yönünde işarete rastlanmıştır.

Tablo 23: Lynx Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a P-Değeri	0,262 (0,000)	0,071 (0,000)	0,037 (0,000)	0,080 (0,000)	0,036 (0,000)	0,084 (0,000)
Doğrulama2	Ort Fark P-Değeri	-0,000 (0,185)	0,000 (0,448)	0,004 (0,006)	0,016 (0,000)	0,005 (0,013)	0,015 (0,002)
Doğrulama3	Ort Fark P-Değeri	0,004 (0,000)	0,013 (0,000)	0,002 (0,009)	0,009 (0,000)	0,004 (0,000)	0,015 (0,000)

^aFarklılık = K-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 24: Lynx Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	-0,002	-0,006	-0,000	0,002	0,000	0,003
	P-Değeri	(0,011)	(0,012)	(0,147)	(0,131)	(0,323)	(0,146)
Doğrulama2	Ort Fark	-0,000	-0,000	0,000	0,006	0,000	0,004
	P-Değeri	(0,056)	(0,365)	(0,245)	(0,019)	(0,365)	(0,065)
Doğrulama3	Ort Fark	0,002	0,007	0,001	0,007	0,001	0,006
	P-Değeri	(0,001)	(0,000)	(0,039)	(0,000)	(0,023)	(0,001)

^aFarklılık = G-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 25: Lynx Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	-0,001	-0,001	-0,002	-0,001	-0,000	-0,000
	P-Değeri	(0,054)	(0,297)	(0,000)	(0,176)	(0,185)	(0,362)
Doğrulama2	Ort Fark	-0,000	-0,002	0,000	0,006	0,000	0,004
	P-Değeri	(0,098)	(0,208)	(0,138)	(0,014)	(0,379)	(0,041)
Doğrulama3	Ort Fark	-0,000	0,000	0,000	0,004	0,000	0,004
	P-Değeri	(0,318)	(0,441)	(0,168)	(0,001)	(0,250)	(0,017)

^aFarklılık = GG-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 26: Lynx Veri Seti İçin Tablo Kodlama Sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	+	+	+	+	+	+
	G	-	-	o	o	o	o
	GG	o	o	-	o	o	o
Doğrulama2	K	o	o	+	+	+	+
	G	o	o	o	+	o	o
	GG	o	o	o	+	o	+
Doğrulama3	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	o	o	o	+	o	+

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

3.5.4.2.2. Güneş Lekesi Serisi (Sunspot)

Sunspot serisi üzerinde yapılan deneyde, daha önce yapılan çalışmalarla benzerlik taşıması açısından test seti ilk olarak 67 veriden oluşturulmuş ve tablolarda “Sunspot uzun veri seti” olarak isimlendirilmiştir. Aynı veri seti üzerinde yapılan ikinci bir deneyde ise test seti bu sefer ilk 35 veriden oluşturulmuş ve bu test seti

üzerinde elde edilen sonuçlara ilişkin tablolar “Sunspot kısa veri seti” olarak isimlendirilmiştir. Öncelikle aşağıda, Sunspot uzun veri setine ait eşleştirilmiş t-testi sonuçları Tablo 27, 28 ve 29 ‘da verilmiştir. Bu tabloların Sunspot kısa veri seti için elde edilmiş karşılıkları Tablo 31, 32 ve 33 ‘tedir. Her iki veri setine ait eşleştirilmiş t-testlerinin 0,05 anlamlılık düzeyinde özetlenmiş tablolarına sırasıyla Tablo 30 ve 34 ‘den ulaşılabilir. Tablo 30 ve 34 ‘den görüleceği üzere, önerilen seçim stratejisi hem klasik hem de kendi alt adımlarına karşı istatistiksel olarak anlamlı bir ortalama performans düşüklüğü sergilememiştir. Kısa veri seti için 1.doğrulama hacmi seviyesinde, bazı farksızlıklara rastlanmış olsa da uzun veri setinin tüm doğrulama hacmi seviyelerinde pozitif anlamlı bir fark elde edilmiştir. Deneme sayısı faktörü açısından bakıldığında, kısa veri seti için 1.deneme seviyesinde daha az pozitif anlamlı fark ortaya çıkmıştır. Bu durum, önerilen stratejinin daha iyi performans gösterebilmesi için deneme sayısının 10 gibi az sayıda alınmaması gerektiğine işaret olabilir. Önerilen seçim stratejisinin alt adımlarına karşı her iki veri seti için açık bir üstünlük sağladığı görülmektedir. Son olarak, yine değerlendirme kriteri olarak MAE ‘nin kullanılmasıyla önerilen yaklaşım MSE kriterine göre daha çok sayıda istatistiksel açıdan anlamlı pozitif ortalama performans üretmektedir.

Tablo 27: Sunspot Uzun Veri Seti Klasik ve GGD Ayırımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	476,75	3,660	516,71	5,154	523,18	4,684
	P-Değeri	(0,013)	(0,000)	(0,000)	(0,000)	(0,003)	(0,000)
Doğrulama2	Ort Fark	437,57	5,426	431,73	5,282	647,20	6,882
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	107,60	1,544	73,166	1,124	45,024	0,845
	P-Değeri	(0,000)	(0,000)	(0,001)	(0,001)	(0,039)	(0,008)

^aFarklılık = K-GGD: pozitif değerler GGD ayırımıyla seçimin avantajını göstermektedir.

Tablo 28: Sunspot Uzun Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	201,28	2,431	237,58	3,146	318,06	3,746
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	251,62	3,330	316,89	3,569	358,09	4,175
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	71,218	0,936	89,341	1,071	35,859	0,939
	P-Değeri	(0,000)	(0,000)	(0,013)	(0,001)	(0,074)	(0,003)

^aFarklılık = G-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 29: Sunspot Uzun Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş T Testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	188,48	2,360	142,41	1,902	220,02	2,965
	P-Değeri	(0,000)	(0,000)	(0,002)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	211,20	2,657	368,34	3,953	384,93	4,719
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	72,103	0,849	81,241	0,706	20,036	0,632
	P-Değeri	(0,001)	(0,002)	(0,026)	(0,032)	(0,164)	(0,013)

^aFarklılık = GG-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 30: Sunspot Uzun Veri Seti İçin Tablo Kodlama Sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	+	+	+	+	+	+
Doğrulama2	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	+	+	+	+	+	+
Doğrulama3	K	+	+	+	+	+	+
	G	+	+	+	+	o	+
	GG	+	+	+	+	o	+

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

Tablo 31: Sunspot Kısa Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	6,352	0,914	167,25	2,936	125,80	2,535
	P-Değeri	(0,452)	(0,037)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	233,34	3,562	263,02	4,297	238,52	3,873
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	35,942	0,838	62,058	1,419	44,831	1,298
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)

^aFarklılık = K-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 32: Sunspot Kısa Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	-0,333	0,592	341,02	2,558	30,279	1,458
	P-Değeri	(0,497)	(0,100)	(0,062)	(0,000)	(0,140)	(0,000)
Doğrulama2	Ort Fark	122,77	2,468	225,22	3,658	176,49	2,992
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	23,756	0,488	35,509	0,732	43,397	0,972
	P-Değeri	(0,000)	(0,006)	(0,000)	(0,000)	(0,000)	(0,000)

^aFarklılık = G-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 33: Sunspot Kısa Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	26,726	0,605	524,74	2,660	18,346	1,062
	P-Değeri	(0,337)	(0,078)	(0,045)	(0,000)	(0,259)	(0,003)
Doğrulama2	Ort Fark	71,733	1,324	117,11	2,110	177,33	2,914
	P-Değeri	(0,001)	(0,001)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ort Fark	26,790	0,616	282,40	1,031	39,029	0,645
	P-Değeri	(0,000)	(0,000)	(0,128)	(0,007)	(0,006)	(0,001)

^aFarklılık = GG-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 34: Sunspot Kısa Veri Seti İçin Tablo Kodlama Sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	o	+	+	+	+	+
	G	o	o	o	+	o	+
	GG	o	o	+	+	o	+
Doğrulama2	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	+	+	+	+	+	+
Doğrulama3	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	+	+	o	+	+	+

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

3.5.4.2.3. IBM Verisi

IBM verisine ait eşleştirilmiş t-testine ilişkin istatistiki değerler Tablo 35, 36 ve 37 'de verilmiştir. Bu tablolardan, sırasıyla klasik yöntemle ve önerilen yaklaşımın alt adımlarıyla yapılan karşılaştırmalara ulaşılabilir. Yapılan testlerin 0,05 anlamlılık düzeyinde özetlenmiş tablosu Tablo 38 'dedir. Bu tablodan, önerilen seçim stratejisinin hem klasik hem de alt adımlarına karşı genel bir üstünlüğü olduğu görülmektedir. Özellikle simülasyon verileriyle elde edilen sonuçlara paralel olarak, doğrulama seti hacmi düşük iken önerilen strateji hep pozitif anlamlı fark üretmiştir. En büyük doğrulama seti hacmi seviyesinde, girdi-gizli yaklaşımıyla aralarındaki fark kapanmış hatta üç tane negatif anlamlı fark ortaya çıkmıştır. İkinci doğrulama hacmi seviyesi bir bakıma klasik seçim yöntemi için en uygun hacim olmuş ve önerilen yaklaşımla tamamen benzer performans göstermiştir. Deneme sayısı faktörü açısından bakıldığında, daha önceki deney sonuçları gibi en az pozitif anlamlı fark 1.deneme seviyesinde elde edilmiştir. Son olarak değerlendirme kriterlerinin pozitif anlamlı fark üretme sayılarına baktığımızda, diğer deneylerden farklı olarak değerlendirme kriteri için MSE veya MAE 'nin kullanılması arasında büyük bir farklılık olmadığı görülmektedir.

Tablo 35: IBM Veri Seti Klasik ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	10,307	0,489	8,694	0,503	18,395	0,851
	P-Değeri	(0,001)	(0,002)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	1,350	0,058	2,887	0,140	-0,566	-0,061
	P-Değeri	(0,186)	(0,262)	(0,079)	(0,105)	(0,366)	(0,291)
Doğrulama3	Ort Fark	5,246	0,079	7,183	0,210	4,826	0,018
	P-Değeri	(0,002)	(0,162)	(0,001)	(0,015)	(0,013)	(0,439)

^aFarklılık = K-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 36: IBM Veri Seti G ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	10,939	0,711	17,225	1,079	17,333	1,057
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	0,874	0,102	3,362	0,307	5,815	0,499
	P-Değeri	(0,143)	(0,035)	(0,006)	(0,001)	(0,000)	(0,000)
Doğrulama3	Ort Fark	3,540	0,113	2,868	0,033	2,196	0,045
	P-Değeri	(0,002)	(0,045)	(0,032)	(0,332)	(0,061)	(0,294)

^aFarklılık = G-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 37: IBM Veri Seti GG ve GGD Ayrışımı Seçim Yöntemlerinin Tahminleme Performansının Eşleştirilmiş t-testiyle Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ort Fark ^a	3,826	0,263	11,576	0,729	15,188	0,966
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ort Fark	-0,209	0,007	1,788	0,170	3,132	0,259
	P-Değeri	(0,323)	(0,410)	(0,013)	(0,001)	(0,000)	(0,000)
Doğrulama3	Ort Fark	-1,686	-0,075	-0,957	-0,052	-3,078	-0,165
	P-Değeri	(0,039)	(0,075)	(0,209)	(0,150)	(0,001)	(0,002)

^aFarklılık = GG-GGD: pozitif değerler GGD ayrışımıyla seçimin avantajını göstermektedir.

Tablo 38: IBM veri seti için tablo kodlama sonucu

Doğrulama Hacmi Seviyesi	Yöntem	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	K	+	+	+	+	+	+
	G	+	+	+	+	+	+
	GG	+	+	+	+	+	+
Doğrulama2	K	o	o	o	o	o	o
	G	o	+	+	+	+	+
	GG	o	o	+	+	+	+
Doğrulama3	K	+	o	+	+	+	o
	G	+	+	+	o	o	o
	GG	-	o	o	o	-	-

Not: + pozitif anlamlı farkı, - negatif anlamlı farkı, o farksızlık durumunu göstermektedir.

3.5.4.3. ARIMA Yöntemiyle Karşılaştırma

Önerilen seçim stratejisinin performansının klasik seçim stratejisi ve kendi alt adımlarıyla bilinen gerçek veri setleri üzerinde kıyaslanmasının ardından, şimdi bu veri setleri için oluşturulmuş ARIMA modeliyle karşılaştırılmasına gidilecektir. Her veri seti için, öncelikle klasik seçimle elde edilen sinir ağlarının her iki değerlendirme kriterine göre elde edilen değerleri ARIMA yöntemiyle elde edilen değerleriyle ve ardından ise aynı veri seti üzerinde GGD ayrışımı seçim yönteminin ürettiği sinir ağı tahminleri ARIMA yönteminin tahminleriyle istatistiksel olarak karşılaştırılmıştır. Bu karşılaştırmalar için bir anakütle ortalamasının sınanmasına imkân veren z-testinden faydalanılmıştır. Her ne kadar sinir ağları tarafından üretilen MSE ve MAE ölçülerinin dağılımının normal olmadığı görülmüş olsa bile, bu testin eğer örneklem büyükse (Otuz veya daha çok gözlemleri örneklem) geçerliliğini koruduğu bilinmektedir (Newbold, 2000: 376). Yapılan testte hipotezler aşağıdaki gibi kurulmuştur.

H_0 : ARIMA yönteminin ürettiği hata ölçüsünün populasyon ortalamasıdır.

H_1 : Sinir ağının ürettiği hata ölçüleri ortalamasının populasyon ortalamasından küçüktür.

Lynx veri seti için 12.dereceden bir AR alt modelinin en sade ARIMA modeli olduğu ve çoğu araştırmacılar tarafından da kullanıldığı bilinmektedir (Subba Rao ve Gabr, 1984: 93; Priestley, 1988: 81; Zhang, 2003: 169). Bu ARIMA modeli test seti üzerinde MSE için 0,020486 ve MAE için ise 0,112255 değerlerinin bulunmasına yol

açmıştır. Bu varsayılan populasyon ortalamaları temel alınarak, Tablo 39 ‘da klasik seçim yöntemiyle yapılan karşılaştırmaya ait sonuçlar verilmiştir. Tabloda deneyin her faktör seviyesi ve her değerlendirme ölçüsüne karşılık gelen, sinir ağlarıyla elde edilmiş ortalama değeri ve test sonucuna ilişkin olasılık değeri bulunmaktadır. Test sonucunda, eğer H_0 hipotezi reddedilmiş ise yani sinir ağıyla yapılan tahminlerin hata ölçüsü ortalaması istatistiksel olarak ARIMA modelinin hata ölçüsünden küçükse tabloda bu alanları göstermek için koyu renk kullanımına gidilmiştir. Dolayısıyla Tablo 39 ‘dan görüleceği üzere, 1.doğrulama hacmi seviyesi hariç klasik seçim yöntemiyle elde edilen sinir ağları ARIMA modelinden her iki değerlendirme kriterine göre de daha küçük hata değerlerine ulaşmıştır. Başka bir deyişle, bu veri seti için eğer yeterli büyüklükte veriyle doğrulama seti oluşturulursa klasik seçim yöntemiyle ARIMA modelinden daha iyi bir performansa ulaşılabilir. Şimdi, aynı tablonun GGD ayrışımı için hazırlanmış hali olan Tablo 40 ‘a bakılırsa, deneyin tüm faktör seviyesi kombinasyonlarında ARIMA modelinden daha iyi sonuçların elde edildiği görülmektedir. Aynı veri seti için klasik seçim yöntemiyle en küçük doğrulama hacminde daha küçük hata değerlerine ulaşılammış hatta ARIMA modelinden daha kötü performans ölçülerine ulaşılmışken, GGD ayrışımı seçim yöntemiyle bu doğrulama hacminde bile ARIMA modelinden daha iyi bir performans ortaya konmuştur. Buradan çıkarılacak sonuç, doğrulama hacmine karşı GGD ayrışımı seçim yönteminin daha dirençli olduğudur.

Tablo 39: Lynx Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama P-Değeri	0,0386 (0,999)	0,1531 (0,999)	0,0489 (0,999)	0,1586 (0,999)	0,0483 (0,999)	0,1631 (0,999)
Doğrulama2	Ortalama P-Değeri	0,0118 (0,000)	0,0815 (0,000)	0,0158 (0,002)	0,0917 (0,000)	0,0167 (0,034)	0,0927 (0,000)
Doğrulama3	Ortalama P-Değeri	0,0152 (0,000)	0,0881 (0,000)	0,0125 (0,000)	0,0819 (0,000)	0,0147 (0,000)	0,0880 (0,000)

Tablo 40: Lynx Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	0,0124	0,0818	0,0118	0,0783	0,0118	0,0790
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ortalama	0,0123	0,0812	0,0117	0,0762	0,0119	0,0776
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ortalama	0,0110	0,0754	0,0109	0,0727	0,0107	0,0728
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)

Sunspot veri seti için 9.dereceden bir AR alt modelinin tüm ARIMA modelleri arasından en sade olduğu ve birçok araştırmacı tarafından da kullanıldığı bilinmektedir (Subba Rao ve Sabr, 1984: 85; Priestley, 1988: 69; Hipel ve McLeod, 1994: 121; Zhang, 2003: 168). Hatırlanmalıdır ki bu veri seti için, test seti uzun ve kısa olmak üzere iki parça olarak alınmıştır. Bu ARIMA modeli uzun test seti üzerinde, MSE için 306,082 ve MAE için ise 13,033 değerlerinin bulunmasına yol açmıştır. Kısa test seti üzerinde ise ARIMA modeliyle MSE için 216,965 ve MAE için 11,319 bulunmuştur. Bu varsayılan populasyon ortalamalarına dayanarak, Tablo 41 ve 42 ‘de uzun test seti için yapılan teste ait sonuçlar verilmiştir. Görüleceği gibi, hem klasik hem de GGD ayrışımı seçimiyle elde edilen sinir ağlarının ortalama performansı ARIMA modelinin performansından daha iyi değildir. Ancak dikkat edilirse, GGD ayrışımı seçimiyle klasik seçime göre daha düşük ortalama performans sergileyen ağlar seçilmiştir. Bu durum, daha önce klasik ve GGD ayrışımı seçim yöntemlerinin performansına yönelik yapılan testin sonuçlarına Tablo 27 ‘den bakılarak doğrulanabilir. Tablo 43 ve 44 ise kısa test setine yönelik olarak yapılan testin sonuçlarını içermektedir. Bu tablolardan, klasik seçim yöntemiyle elde edilen sinir ağlarının genel anlamda ARIMA modelinden daha iyi hata ölçülerine ulaşamadığı anlaşılmaktadır. Sadece iki kez daha iyi performansa ulaşılmıştır. Doğrulama hacmi arttıkça daha iyi sinir ağlarının seçildiği görülmektedir. Tablo 44 ‘den ise GGD ayrışım seçim yöntemiyle genel anlamda ARIMA modeline göre daha iyi tahmin değerleri üreten ağların seçildiği görülmektedir. Ayrıca, bu veri setinde en küçük doğrulama hacmi seviyesinin GGD ayrışımıyla seçim yöntemi için bile yetersiz olduğu anlaşılmaktadır.

Tablo 41: Sunspot Uzun Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	955,79	19,455	999,72	20,976	991,35	20,199
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama2	Ortalama	912,84	21,003	907,73	21,252	1117,36	22,589
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama3	Ortalama	498,69	15,824	485,71	15,716	486,11	15,511
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)

Tablo 42: Sunspot Uzun Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	479,04	15,795	483,01	15,822	468,16	15,515
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama2	Ortalama	475,26	15,577	475,99	15,970	470,16	15,707
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama3	Ortalama	391,09	14,280	412,55	14,592	441,09	14,666
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)

Tablo 43: Sunspot Kısa Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	318,41	12,719	390,97	13,589	388,85	13,503
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama2	Ortalama	444,39	14,393	464,51	15,033	435,16	14,553
	P-Değeri	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)	(0,999)
Doğrulama3	Ortalama	209,08	10,546	233,28	10,992	214,68	10,861
	P-Değeri	(0,166)	(0,000)	(0,890)	(0,068)	(0,376)	(0,004)

Tablo 44: Sunspot Kısa Veri Seti GGD Ayrışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	312,06	11,805	223,71	10,652	263,05	10,968
	P-Değeri	(0,980)	(0,964)	(0,711)	(0,000)	(0,984)	(0,056)
Doğrulama2	Ortalama	211,05	10,830	201,48	10,736	196,63	10,680
	P-Değeri	(0,289)	(0,004)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ortalama	173,14	9,707	171,22	9,573	169,85	9,563
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)

Araştırmacılar tarafından kolaylıkla ulaşılabilen IBM verisi için Box ve Jenkins ‘in orjinal çalışmalarında (1970) tespit ettiği mevsimsel ARIMA modeli

(0,1,1) (0,0,1)⁶ şeklindedir. Bu ARIMA modeliyle test seti üzerinde MSE için 78,5795 ve MAE için ise 7,6739 değerleri bulunmuştur. Bu varsayılan populasyon ortalamalarına dayanarak, Tablo 45 ve 46 ‘da yapılan teste ait sonuçlar verilmiştir. Tablo 45 ‘den klasik seçim yöntemiyle doğrulama hacminin 1. ve 3. seviyesinde ARIMA modelinden daha iyi sonuçlar elde edilememiştir. Ancak, 2.doğrulama hacmi seviyesinde performansın arttığı ve ARIMA modelinin kısmen geçildiği görülmektedir. GGD ayrışımı seçimiyle ise büyük çoğunlukla ARIMA modelinden daha iyi hata ölçüsü değerlerine ulaşılmıştır. Yalnız en büyük doğrulama hacmi seviyesinde, MAE kriterine göre daha iyi sonuçlara ulaşılamamıştır. Diğer veri setleriyle şimdiye kadar yapılan analizlerde, en düşük performansların 1.doğrulama hacmi seviyesinde ortaya çıktığı gözlemlenmişken IBM veri setinde GGD ayrışımıyla en iyi ortalama performanslar bu faktör seviyesinde elde edilmiştir. Bunun nedeni olarak, IBM verisinin finansal bir veri olmasından ötürü son dönemden daha fazla etkilenebileceği ve son döneme ait verilerin küçük doğrulama hacminin kullanılmasıyla eğitime alınarak, son dönemi öğrenmiş ağların daha iyi performans göstermesi olduğu söylenebilir. Ancak bu durum klasik seçimde ortaya çıkmamaktadır. Nedeni için ise klasik seçimin doğrulama hacmine daha dirençsiz oluşuyla iyi ağları seçememesi olduğu ileri sürülebilir.

Tablo 45: IBM Veri Seti Klasik Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	81,598	7,995	79,591	7,996	89,052	8,333
	P-Değeri	(0,825)	(0,976)	(0,659)	(0,993)	(0,985)	(0,999)
Doğrulama2	Ortalama	72,573	7,571	74,019	7,652	70,345	7,436
	P-Değeri	(0,000)	(0,126)	(0,010)	(0,419)	(0,000)	(0,017)
Doğrulama3	Ortalama	80,160	7,736	82,333	7,884	80,661	7,734
	P-Değeri	(0,819)	(0,794)	(0,962)	(0,995)	(0,878)	(0,740)

Tablo 46: IBM Veri Seti GGD Ayırışımı Seçim Yöntemi Tahminleme Performansının ARIMA Modeliyle z-testi Aracılığıyla Karşılaştırılması

Doğrulama Hacmi Seviyesi	İstatistik	Deneme1		Deneme2		Deneme3	
		MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1	Ortalama	71,291	7,505	70,897	7,493	70,657	7,482
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama2	Ortalama	71,223	7,513	71,132	7,511	70,911	7,497
	P-Değeri	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)	(0,000)
Doğrulama3	Ortalama	74,913	7,657	75,149	7,675	75,836	7,717
	P-Değeri	(0,000)	(0,348)	(0,000)	(0,506)	(0,001)	(0,829)

Bu bölüm içerisinde, gerçek veriler üzerinde GGD ayırışımıyla seçim yönteminin hem klasik seçim yöntemi hem de kendi alt adımlarıyla karşılaştırması yapılmıştır. Ayrıca, bu veri setleri için kurulmuş ARIMA modelleriyle kıyaslama yapma imkânı bulunmuştur. Sonraki bölümde, klasik ve önerilen seçim stratejisinin doğrulama seti hacmine karşı dirençliliğini ölçmek için yapılan analize değinilecektir.

3.5.4.4. Doğrulama Hacmi Etkisi

Daha önce yapılan analizlerde, GGD ayırışımıyla seçim yönteminin doğrulama hacmi seviyesine karşı daha dirençli olduğu yönünde bulgulara rastlanmıştır. Bu bölüm içerisinde, bu iddiayı test etme amacına yönelik olarak oluşturulan deneylerden faydalanarak bir araştırma yürütülecektir. Doğrulama hacmine karşı direnç, doğrulama hacminden önerilen seçim stratejisinin daha az etkilenmesi anlamına geldiğinden doğrulama hacminin neden olduğu değişkenlik kaynağının azaltılmasını olanaklı kılacaktır. Tablo 47 ‘de yapılacak olan testin şematik gösterimi verilmiştir. Klasik ve GGD ayırışımı seçim yönteminin aynı gürültü seviyesinde ve farklı doğrulama hacimlerinde ürettikleri sinir ağı performansları bir grup olarak alınmıştır. Örneğin, 1.gürültü seviyesinde klasik seçimle her bir doğrulama seti için bir grup oluşturulacağından toplamda üç grup vardır ve bu gruplar arasında bir performans farklılığı olup olmadığı araştırılacaktır. Bu durum tabloda elips ile gösterilmiştir. Aynı işlem GGD ayırışımı için ve farklı gürültü seviyeleri üzerinde de yapılacaktır. Böylece eğer gruplar arasında bir farklılık olmadığını söyleyen H_0 hipotezi red edilemezse klasik veya GGD ayırışımı seçim

yönteminin, o gürültü seviyesindeki doğrulama hacimlerine karşı dirençli olduğu söylenebilecektir.

Tablo 47: Doğrulama Seti Hacminin Etkisinin İncelenmesi İçin Yapılan Kruskal-Wallis H-Test Planı

	Gürültü1		Gürültü2		Gürültü3	
	K	GGD	K	GGD	K	GGD
Doğrulama1	Grup1	Grup1	Grup1	Grup1	Grup1	Grup1
Doğrulama2	Grup2	Grup2	Grup2	Grup2	Grup2	Grup2
Doğrulama3	Grup3	Grup3	Grup3	Grup3	Grup3	Grup3

Performans kıyaslamasının yapılacağı MSE ve MAE ölçülerine ait dağılım incelenmiş, Shapiro-Wilk testi sonuçlarına dayanarak bazı faktör seviye kombinasyonlarında doğrusal olmama durumu tespit edilmiştir. Değişkenliğe ilişkin parametrik testlerin normallik varsayımının çiğnenmesi durumunda geçerliliklerini yitirdikleri bilindiğinden, bu bölüm ve sonraki bölüm içerisinde parametrik olmayan testlerden faydalanılmıştır. Bu amaca yönelik olarak, tek yönlü varyans analizinin (ANOVA) parametrik olmayan eş değeri olan Kruskal-Wallis H-Testi, ikiden fazla bağımsız veya ilişkisiz örneği karşılaştırmak amacıyla kullanılabilir. Kruskal-Wallis H-testinin anlamlı sonuç üretmesi, örneklerden en azından birinin diğer örneklerden farklı olduğu anlamına yol açmaktadır. Ancak test, farklılığın nereden kaynaklandığını ve kaç örnek çiftinin birbirinden farklı olduğunu tespit etmez. Örnek çiftleri arasındaki belirli farklılıkları ortaya koymak için, araştırmacı örnek çiftlerini karşılaştırma yoluna gidebilir. Mann-Whitney U-testi örnek çiftlerini karşılaştırma amacı için kullanılabilir. Mann-Whitney U-testi, bağımsız veya ilişkisiz iki örneği karşılaştırmada faydalanabilecek parametrik olmayan bir istatistiksel prosedürdür. Bu testin parametrik eşdeğeri bağımsız örneklerde t-testidir. Aşağıdaki analizde, Tablo 47 ‘de gösterilen tasarıma göre öncelikle Kruskal-Wallis testi yapılacak ve bu test sonucunda anlamlı bir farklılık bulunursa hangi ve kaç grubun birbirinden farklı olduğunu tespit etmek amacıyla Mann-Whitney testinden faydalanılacaktır.

3.5.4.4.1. AR2 Veri Seti

Tablo 48 ‘de, AR2 veri seti için klasik ve GGD ayrışımı seçim yöntemleriyle farklı doğrulama hacimleri üzerinde yapılmış Kruskal-Wallis test sonuçları verilmiştir. Anlamlılık eşik değeri olan 0,05 olasılık değerinin altındaki test sonuçları koyu renkle ifade edilmiştir. Buna göre, her iki değerlendirme ölçüsüne ait toplam 12 Kruskal-Wallis testinden sadece 2 ‘sinde anlamlı sonuca ulaşılmıştır. Tabloda Kruskal-Wallis H değeri ve ona karşılık gelen olasılık değeri verilmiştir. Kruskal-Wallis H değeri büyüdükçe incelenen örneklerin birbirinden farklı olma derecesi arttığından, bunlara karşılık gelen olasılık değerleri de küçülecektir. Tablo 48 ‘de klasik seçim yöntemine ait Kruskal-Wallis H değerlerinin sürekli olarak GGD ayrışımına ait Kruskal-Wallis H değerlerinden yüksek olduğu görülmektedir. Bunun anlamı, klasik seçim yöntemi farklı doğrulama hacimlerinde GGD ayrışımı seçim yöntemine göre kendi içinde daha çok performans farklılığı gösteren ağları seçmesidir. Başka bir deyişle, klasik seçim yöntemi doğrulama hacmine karşı daha dirençsizdir. Ayrıca, MSE ve MAE ölçüleri arasında bu teste ilişkin olarak bir performans farklılığı olmadığı görülmektedir. Genel olarak, benzer sonuçlar üretmektedirler. Aynı yorumu farklı gürültü seviyeleri için de yapmak mümkündür.

Tablo 48: AR2 Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H	5,544	2,549	6,438	1,503	5,473	2,242
	P-Değeri	(0,063)	(0,280)	(0,040)	(0,472)	(0,065)	(0,326)
MAE	Kruskal Wallis H	5,391	1,559	7,294	2,407	5,013	1,788
	P-Değeri	(0,067)	(0,459)	(0,026)	(0,300)	(0,082)	(0,409)

Farklı doğrulama hacimlerinden iki seçim yönteminin etkilenip etkilenmediğinin araştırılmasına yönelik AR2 veri seti üzerinde yapılan Kruskal-Wallis test sonucunda, 2.gürültü seviyesinde klasik seçimle hem MSE hem de MAE ölçüsüne göre bir farklılık tespit edilmiştir. Kruskal-Wallis testi sadece ikiden fazla sayıda örnek arasında farklılık olup olmadığını belirlediğinden, Mann-Whitney testiyle yapılan ikili karşılaştırmalara ait sonuçlar Tablo 49 ve 50 ‘de verilmiştir. Tablolar karşılaştırma yapılacak grupları, Mann-Whitney U istatistiğini,

karşılaştırılan iki örneğin farklı olma derecesini gösteren sıralama toplamı farkını ve bunlara ait olasılık değerini içermektedir. Çoklu örnek çifti karşılaştırmaları yaparken birinci tip hata yükselme eğilimi gösterir. Bu yüzden başlangıç risk seviyesi α 'nın ayarlanması gerekir. Birinci tip hatanın yükselmesini önleyici Bonferroni prosedürüyle Mann-Whitney U-testi, tekil örnek çiftlerini karşılaştırmada yararlı bir metottur (Corder ve Foreman, 2009: 101). Bonferroni prosedürü aşağıdaki formülasyon aracılığıyla α değerini düzenler.

$$\alpha_B = \frac{\alpha}{k} \quad (3.21)$$

Burada, α_B düzenlenmiş risk düzeyi, α orjinal risk düzeyi ve k karşılaştırması yapılacak çift sayısıdır.

Bizim örneğimizde, $\alpha = 0,05$ düzeyinde ve $k = 3$ olduğundan birinci tip hata $1 - (1 - 0,05)^3 = 0,14$ 'e yükselecekti. Bunu gidermek için, Bonferroni prosedürüyle düzeltilmiş risk düzeyi $\alpha_B = \frac{0,05}{3} = 0,0167$ haline getirilmiştir. Dolayısıyla, Tablo 49 ve 50 'deki olasılık değerleri bu düzeltilmiş risk seviyesiyle kıyaslanarak kararlar verilmiştir. Yine anlamlı olan test sonuçları koyu renk ile temsil edilmiştir. Ayrıca Mann-Whitney testinde H_0 hipotezi, iki doğrulama hacminde elde edilen sinir ağlarının performans sıralamaları arasında önemli bir fark yoktur şeklindedir. Alternatif hipotez ise bir doğrulama hacminde elde edilen sinir ağlarının performans sıralamaları, diğerinden sistematik olarak büyük (veya küçük) şeklindedir. Anlaşılabacağı üzere, tablolarda tek taraflı olasılık değeri verilmiştir.

Tablo 49 ve 50 'den en büyük ve en küçük doğrulama hacimlerinde klasik seçim yöntemiyle seçilen ağların performansı arasında anlamlı bir farklılık olduğu anlaşılmaktadır. En büyük doğrulama hacminde klasik seçim yöntemiyle daha iyi performansa sahip ağlar seçilmektedir. Sıralama toplamı farkı sütunu eğer çiftler arasında anlamlı bir fark varsa, hangi örneğin daha iyi performansa sahip olduğunu göstermektedir. Performanslar küçükten büyüğe doğru sıralandığından ve küçük sıra numaraları eldeki problem için daha istenir olduğundan, sıralama toplamı daha küçük olanın performans üstünlüğü vardır. Ayrıca tablolardan dikkat edilirse, Mann-Whitney U istatistiği küçüldükçe karşılaştırma yapılan çiftler arasındaki farklılık seviyesi büyümekte ve olasılık değeri daha anlamlı hale gelmektedir.

Tablo 49: AR2 Veri Seti, Gürültü2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1047	2728 – 2322	0,081
Doğrulama2-Doğrulama3	1063	2712 – 2338	0,098
Doğrulama1-Doğrulama3	894	2881 – 2169	0,007

Tablo 50: AR2 Veri Seti, Gürültü2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1006	2769 – 2281	0,046
Doğrulama2-Doğrulama3	1049	2726 – 2324	0,083
Doğrulama1-Doğrulama3	887	2888 – 2162	0,006

3.5.4.4.2.GAR Veri Seti

GAR veri seti için Kruskal-Wallis test sonuçlarına dayanarak Tablo 51 oluşturulmuştur. Söz konusu tablo incelendiğinde, klasik seçim yöntemiyle farklı doğrulama hacimlerinde seçilen sinir ağlarının, her gürültü seviyesinde ve her değerlendirme kriterine göre istatistiksel olarak birbirine eşit performans göstermedikleri anlaşılmaktadır. En azından bir doğrulama seviyesindeki ağlar, diğer doğrulama seviyesindeki ağlardan performans olarak farklılık göstermektedir. GGD ayrışımıyla seçilen ağlar, her gürültü seviyesi ve her değerlendirme kriteri için birbirinden farklılık sergilememiştir. Başka bir deyişle, GAR veri seti için önerilen yaklaşımın doğrulama seti hacmine karşı açık bir dirençliliği bulunmaktadır. Ayrıca, MSE ve MAE ölçüleri arasında bu teste ilişkin olarak bir performans farklılığı olmadığı ve farklı gürültü seviyeleri için benzer sonuçların üretildiği anlaşılmaktadır.

Tablo 51: GAR Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Gürültü1		Gürültü2		Gürültü3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H	6,486	1,389	15,077	2,048	27,591	5,954
	P-Değeri	(0,039)	(0,499)	(0,001)	(0,359)	(0,000)	(0,051)
MAE	Kruskal Wallis H	7,147	0,761	11,788	0,815	28,647	5,103
	P-Değeri	(0,028)	(0,683)	(0,003)	(0,665)	(0,000)	(0,078)

Klasik seçim yöntemine ait anlamlı 6 tane Kruskal-Wallis test sonucunun ikili karşılaştırmaları Tablo 52 ile 57 arasında aşağıda verilmiştir. Tablolardan, klasik seçim yöntemiyle 1.gürültü seviyesinde sadece en büyük ve en küçük doğrulama hacimlerindeki sinir ağları arasında farklılık olduğu gözükmemektedir. En büyük ve en küçük doğrulama hacimlerindeki performans farklılığı diğer gürültü seviyelerinde de olmakla beraber, 2.gürültü seviyesinde ilaveten en büyük ve ortancı doğrulama hacimleri arasında, 3.gürültü seviyesinde ise en küçük ve ortancı doğrulama hacimleri arasında istatistiksel performans farklılığı bulunmaktadır. Sıra toplamı farkı sütunlarından, klasik yöntem için doğrulama hacmi arttıkça tüm gürültü seviyelerinde daha iyi performans gösteren ağların seçildiği yorumunu yapmak mümkündür. Klasik seçim yöntemi üzerinde yürütülen tüm bu ikili karşılaştırma sonuçlarının özetlenmesi amacıyla Tablo 58 oluşturulmuştur. Yapılan ikili karşılaştırma eğer anlamlı sonuç veriyse + işaretiyle, anlamsız sonuç veriyse – işaretiyle temsil edilmiştir. Böylece, bu tablolardan hangi doğrulama hacimleri arasında ve toplamda kaç tane farklılığın olduğu bilgisine ulaşılabilir.

Tablo 52: GAR Veri Seti, Gürültü1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	962	2813 – 2237	0,023
Doğrulama2-Doğrulama3	1204	2571 – 2479	0,376
Doğrulama1-Doğrulama3	905	2870 – 2180	0,009

Tablo 53: GAR Veri Seti, Gürültü1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	947	2828 – 2222	0,019
Doğrulama2-Doğrulama3	1198	2577 – 2473	0,360
Doğrulama1-Doğrulama3	889	2886 – 2146	0,007

Tablo 54: GAR Veri Seti, Gürültü2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1144	2631 – 2419	0,232
Doğrulama2-Doğrulama3	817	2958 – 2092	0,002
Doğrulama1-Doğrulama3	725	3050 – 2000	0,000

Tablo 55: GAR Veri Seti, Gürültü2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1113	2662 – 2388	0,173
Doğrulama2-Doğrulama3	878	2897 – 2153	0,005
Doğrulama1-Doğrulama3	787	2988 – 2062	0,000

Tablo 56: GAR Veri Seti, Gürültü3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	759	3016 – 2034	0,000
Doğrulama2-Doğrulama3	965	2810 – 2240	0,024
Doğrulama1-Doğrulama3	511	3264 – 1786	0,000

Tablo 57: GAR Veri Seti, Gürültü3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	717	3058 – 1992	0,000
Doğrulama2-Doğrulama3	1012	2763 – 2287	0,050
Doğrulama1-Doğrulama3	505	3270 – 1780	0,000

Tablo 58: GAR Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Gürültü1		Gürültü2		Gürültü3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	-	-	-	-	+	+
Doğrulama2-Doğrulama3	-	-	+	+	-	-
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

3.5.4.4.3.Lynx Veri Seti

Simülasyon verilerinde doğrulama hacminin iki seçim yöntemine etkisinin incelenmesinin ardından, şimdi gerçek veri setleri üzerinde bu etki incelenecektir. Aynı tasarım uygulanmakla beraber, gürültü seviyesi yerini gerçek veriler için deneme sayısı faktörüne bırakmıştır. Lynx verisine ait Kruskal-Wallis test sonuçlarına Tablo 59 ‘dan ulaşılabilir. Tablo 59 ‘dan görüleceği üzere, yürütülen deneyin tüm noktalarında hem klasik hem de GGD ayrışımı seçim yöntemi, doğrulama hacmi seviyesinden ciddi şekilde etkilenmektedir. Tüm deneme seviyeleri ve hata ölçüsünde, doğrulama hacmine bağlı olarak performans farklılığı ortaya çıkmıştır. Ancak, Kruskal-Wallis H değeri büyüdükçe incelenen örneklerin birbirinden farklı olma derecesi arttığı bilgisinden yola çıkarak, Tablo 59 ‘dan GGD ayrışımı seçim yönteminin klasik yöntemle göre daha az farklılığa sahip sinir ağıları seçtiği söylenebilir. Ayrıca, MSE ve MAE ölçüleri arasında bu teste ilişkin olarak bir performans farklılığı olmadığı ve farklı deneme seviyeleri için benzer sonuçların üretildiği anlaşılmaktadır. Bu tablodaki tüm anlamlı test sonuçları için yapılan ikili karşılaştırmalara Ekler içerisinde ulaşılabilir. Klasik ve GGD ayrışımı üzerinde yürütülen tüm bu ikili karşılaştırma sonuçlarının özetlenmesi amacıyla Tablo 60 ve 61 oluşturulmuştur.

Tablo 59: Lynx Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Deneme1		Deneme2		Deneme3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	68,087 (0,000)	16,429 (0,000)	71,591 (0,000)	6,790 (0,034)	74,108 (0,000)	13,265 (0,001)
MAE	Kruskal Wallis H P-Değeri	74,620 (0,000)	16,817 (0,000)	78,505 (0,000)	14,862 (0,001)	72,997 (0,000)	19,333 (0,000)

Tablo 60 ‘dan, ikinci ve üçüncü doğrulama hacmi seviyesinde klasik yöntemle benzer performans gösteren sinir ağlarının seçildiği görülmektedir. En küçük doğrulama hacminde, sinir ağlarının performansı diğer hacimdekilere göre daha kötüdür. Bunu hem diğer doğrulama hacimleriyle arasında fark olduğunu gösteren aşağıdaki tablodan hem de Ekler içerisindeki sıralama toplamı farkı sütunlarından görmek mümkündür. Tablo 61 ‘den ise en küçük ve en büyük

doğrulama hacimlerine ait sinir ağıları arasında keskin bir performans farklılığı olduğu anlaşılmaktadır. Her iki tablodan çıkan ortak sonuç, doğrulama hacmi arttıkça daha iyi performans gösteren ağların seçildiğidir. Ayrıca, MSE ve MAE ölçüleri ve farklı deneme seviyeleri için benzer sonuçların ortaya çıktığı görülmektedir.

Tablo 60: Lynx Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	+	+	+	+	+	+
Doğrulama2-Doğrulama3	-	-	-	-	-	-
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Tablo 61: Lynx Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	-	-	-	+	-	-
Doğrulama2-Doğrulama3	+	+	-	-	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

3.5.4.4.Sunspot Veri Seti

Sunspot Uzun ve Kısa veri setine ait Kruskal-Wallis test sonuçlarına Tablo 62 ve 65 ‘den ulaşılabilir. Bu iki tablodan görüleceği üzere, hem klasik hem de GGD ayrışımı seçim yöntemi doğrulama hacminden etkilenmekte ve farklı performans gösteren ağların seçimine yol açmaktadırlar. Ancak yine bu iki tablodan Kruskal-Wallis H değerleri incelendiğinde, GGD ayrışımı seçim yönteminin klasik yöntemle göre daha az farklılığa sahip ağları seçtiği yorumu yapılabilir. Ayrıca, MSE ve MAE ölçüleri ve farklı deneme seviyeleri için bu teste ilişkin olarak benzer sonuçlar ortaya çıkmaktadır. Bu tablo sonuçlarına göre yapılan ikili karşılaştırmaların özeti Tablo 63-64 ve 66-67 ‘de verilmiştir. Bu tablolardan, klasik seçim yönteminin daha çok anlamlı sonuç ürettiği anlaşılmaktadır. Ekler içerisinde yapılan ikili

karşılaştırmaların ayrıntılarına ulaşılabilmekle beraber her iki seçim yöntemi için, doğrulama hacmi arttıkça daha iyi performans gösteren ağların seçildiği çıkarımı yapılabilir.

Tablo 62: Sunspot Uzun Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Deneme1		Deneme2		Deneme3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	49,050 (0,000)	28,834 (0,000)	56,259 (0,000)	22,286 (0,000)	55,554 (0,000)	9,666 (0,008)
MAE	Kruskal Wallis H P-Değeri	48,297 (0,000)	31,240 (0,000)	57,198 (0,000)	28,240 (0,000)	56,668 (0,000)	19,493 (0,000)

Tablo 63: Sunspot Uzun Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	+	+	-	-	+	+
Doğrulama2-Doğrulama3	+	+	+	+	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Tablo 64: Sunspot Uzun Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	-	-	-	-	-	-
Doğrulama2-Doğrulama3	+	+	+	+	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Tablo 65: Sunspot Kısa Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Deneme1		Deneme2		Deneme3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	50,585 (0,000)	52,860 (0,000)	57,757 (0,000)	37,610 (0,000)	67,499 (0,000)	35,936 (0,008)
MAE	Kruskal Wallis H P-Değeri	54,859 (0,000)	50,983 (0,000)	56,348 (0,000)	38,948 (0,000)	58,379 (0,000)	40,305 (0,000)

Tablo 66: Sunspot Kısa Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	+	+	+	+	+	+
Doğrulama2-Doğrulama3	+	+	+	+	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Tablo 67: Sunspot Kısa Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	+	+	-	-	+	-
Doğrulama2-Doğrulama3	+	+	+	+	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

3.5.4.4.5.IBM Veri Seti

IBM verisine ilişkin Kruskal-Wallis test sonuçları Tablo 68 ‘de verilmiştir. Tablodan, hem klasik hem de GGD ayrışımı seçim yönteminin doğrulama hacminden etkilendiği görülmektedir. Ancak diğer veri setlerinden farklı olarak, Kruskal-Wallis H değerleri GGD ayrışımı için daha büyüktür. Daha önce bu veri setiyle yapılan analizlerden, klasik seçim yöntemi için ikinci doğrulama hacminin en iyi performansları verdiği ve birinci ve üçüncü doğrulama hacminin ise benzer ağırları seçtiği bulgularına ulaşılmıştır. GGD ayrışımı için ise doğrulama hacmi arttıkça daha kötü performansların gerçekleştiği bilinmektedir. Bunun nedeni olarak, IBM verisinin finansal bir veri seti olmasından ötürü son dönemden daha çok etkilenmiş olabileceğidir. Halbuki klasik yöntem en küçük doğrulama hacminde, bu özellikten faydalanılmasını sağlayacak sinir ağırlarını seçememiştir. Dolayısıyla, IBM verisi için GGD ayrışımı seçim yöntemiyle daha yüksek Kruskal-Wallis H değerlerinin ortaya çıkması şaşırtıcı değildir. Tablo 69 ve 70 ise yapılan ikili karşılaştırmalara ilişkin sonuçları özetlemiştir. Yine Ekler içerisinde ayrıntılara ulaşılabilir. Bu tablolarda,

GGD ayrışımının daha çok sayıda anlamlı sonuç üretmesi az önce yapılan açıklamaları desteklemektedir.

Tablo 68: IBM Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Doğrulama Hacimlerine Karşı Dirençliliğinin Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Deneme1		Deneme2		Deneme3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	14,469 (0,001)	17,590 (0,000)	11,526 (0,003)	18,896 (0,000)	21,387 (0,000)	29,151 (0,000)
MAE	Kruskal Wallis H P-Değeri	6,611 (0,037)	18,724 (0,000)	6,281 (0,043)	11,573 (0,003)	15,902 (0,000)	23,036 (0,000)

Tablo 69: IBM Veri Seti Üzerinde Klasik Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	+	+	-	-	-	-
Doğrulama2-Doğrulama3	+	-	+	+	-	-
Doğrulama1-Doğrulama3	-	-	-	-	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Tablo 70: IBM Veri Seti Üzerinde GGD Ayrışımı Seçim Yöntemi İçin Doğrulama Etkisini İncelemek Amacıyla Yapılan İkili Karşılaştırmaların Özeti.

Karşılaştırma Noktaları	Deneme1		Deneme2		Deneme3	
	MSE	MAE	MSE	MAE	MSE	MAE
Doğrulama1-Doğrulama2	-	-	-	-	-	+
Doğrulama2-Doğrulama3	+	+	+	+	+	+
Doğrulama1-Doğrulama3	+	+	+	+	+	+

Not: + H_0 hipotezi ret , - H_0 hipotezi reddedilemez.

Bu bölümde yapılan incelemelerin ardından genel bir değerlendirme olarak, özellikle simülasyon verileri üzerinde önerilen seçim stratejisinin klasik yönteme karşı daha açık bir dirençlilik sergilediği görülmüştür. Lynx ve Sunspot verilerinde ise istatistiksel bakımdan bir dirençlilik tespit edilememişse de Kruskal-Wallis H değerlerini göz önüne alarak farklı doğrulama hacimlerinde klasik yönteme göre, nispeten daha yakın performanslar ortaya koyduğu söylenebilir. IBM veri setinde, Kruskal-Wallis H değerlerine göre klasik yöntem daha dirençliymiş gibi gözükmeyle beraber, bunun en büyük ve en küçük doğrulama haciminde klasik yöntemin benzer

şekilde kötü ağırları seçmesinden kaynaklandığı yorumu yapılabilir. Bu veri setinde, GGD ayrışımı daha küçük doğrulama hacimleriyle daha çok verinin modellemeye katılmasıyla daha iyi performans gösteren ağırları seçmiştir. Ayrıca, MSE ve MAE ölçüleri arasında doğrulama hacmine karşı direnç yönünden benzer performans sergilenmiştir. Aynı yorum, simülasyon verilerindeki gürültü seviyeleri ve gerçek verilerdeki deneme sayısı faktörü için de yapılabilir. İzleyen bölümde, deneme sayısının iki seçim yöntemi üzerinde bir etkisinin olup olmadığına yönelik bir araştırma yürütülecektir.

3.5.4.5. Deneme Sayısının Etkisi

Aynı girdi-gizli kombinasyonundan oluşturulmuş bir ağı diğer parametreler sabit tutulmak kaydıyla, her bir farklı başlangıç ağırlık değeriyle eğitilmesine deneme denmektedir. Literatürü incelediğimizde deneme sayısı olarak 10, 30 ve 50 ‘şer denemeli sinir ağı tasarımlarının daha sıklıkla oluşturulduğu görülmektedir. Bununla birlikte, deneme sayısının ağı performansını etkileyen bir faktör olarak incelendiği bir çalışmaya rastlanmamıştır. Bu çalışmada önerilen yöntemin girdi ve gizli hücre uzayını tespit etmesinin ardından hem eğitim hem de doğrulama setinde iyi bir performans gösteren ağı arıyor olmasından ötürü, deneme sayısının etkili bir faktör olup olmadığı konusunda şüpheler uyanmaktadır. Dolayısıyla deneme sayısının hem klasik yöntem üzerinde bir etkisinin olup olmadığının araştırmasına gidilerek, hem daha önce incelemesine rastlamadığımız bir alanda sorgulama yapılacak hem de önerilen yaklaşımın deneme sayısına bağlı olup olmadığı şüphesi bu bölüm içerisinde incelenecektir. Bu amaca yönelik olarak, Tablo 71 ‘deki deney planı yürütülecektir. Her bir doğrulama setinde farklı başlangıç ağırlık değeri sayısının oluşturduğu Deneme1, Deneme2 ve Deneme3 bir grup olarak alınacak ve bu gruplardaki sinir ağı performanslarının birbirlerinden farklı olup olmadığı test edilecektir. Bu işlem hem klasik hem de GGD ayrışımıyla seçim yöntemi için yürütülecektir. Aşağıdaki tabloda, her bir testin yapılacağı alan elips ile temsil edilmiştir. Bu testlerin yapılması amacıyla normallik varsayımının çiğnenmesinden yüzünden yine parametrik olmayan istatistiksel testlerden faydalanılacaktır.

Öncelikle Kruskal-Wallis H testi yapılacak ve eğer gruplar arasında farklılıklar bulunursa Mann-Whitney U testiyle ikili karşılaştırmalar yapma yoluna gidilecektir.

Tablo 71: Doğrulama Seti Hacminin Etkisinin İncelenmesi İçin Yapılan Kruskal-Wallis Test Planı

	Doğrulama1		Doğrulama2		Doğrulama3	
	K	GGD	K	GGD	K	GGD
Deneme1	Grup1	Grup1	Grup1	Grup1	Grup1	Grup1
Deneme2	Grup2	Grup2	Grup2	Grup2	Grup2	Grup2
Deneme3	Grup3	Grup3	Grup3	Grup3	Grup3	Grup3

Tablo 72 ile 75 arasında, çalışmada kullanılan gerçek veriler üzerinde az önce anlatılan deney tasarımının uygulanmasıyla elde edilen Kruskal-Wallis testine ait sonuçlar verilmiştir. Tablolardan görüleceği üzere, klasik seçim yönteminin farklı doğrulama hacimleri ve farklı veri setleri üzerinde yürütülen incelemesinde, deneme sayısından istatistiksel olarak etkilenmediği görülmüştür. Başka bir deyişle, klasik seçim yöntemi uygulanırken elde edilen sinir ağı performansları için deneme sayısı önemli bir faktör değildir. Dolayısıyla harcanan bilgisayar zamanı açısından ele alındığında, klasik seçim yöntemiyle 10 denemeli sinir ağı deneyinin oluşturulmasının akla daha yatkın olduğu söylenebilir. Aynı tablolardan, GGD ayrışımı için benzer yorumu yapmak mümkün değildir. Lynx ve Sunspot Kısa veri setinde farklı deneme sayılarıyla farklı performans gösteren ağların seçilebileceği anlaşılmaktadır. Kruskal-Wallis testiyle anlamlı sonuç elde edilen durumların her biri için ikili karşılaştırmalar yapılmış ve bunlara ait tablolar, Tablo 76 ile 79 arasında verilmiştir. Bu tabloların tümünde, en az deneme sayısı olan 10 denemenin anlamlı bir düşük performans üretme kaynağı olduğu görülmektedir. Diğer bir ifadeyle, önerilen yaklaşımı uygularken 10 denemenin kullanılmasının performans düşüklüğüne yol açabileceği anlaşılmaktadır. Bu sonuç, GGD ayrışımının adımları hesaba katıldığında beklenebilir bir sonuçtur. 30 ve 50 denemeler arasında bir farklılık görülmemekle birlikte, 30 denemenin tercih edilmesi oluşturulan sinir ağı deneyinin daha kısa sürede tamamlanması açısından fayda sağlayacaktır.

Tablo 72: Lynx Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Doğrulama1		Doğrulama2		Doğrulama3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	2,090 (0,351)	2,337 (0,311)	3,464 (0,177)	3,380 (0,185)	2,181 (0,336)	1,027 (0,598)
MAE	Kruskal Wallis H P-Değeri	0,840 (0,657)	2,715 (0,257)	2,146 (0,342)	8,874 (0,012)	3,020 (0,221)	8,012 (0,018)

Tablo 73: Sunspot Uzun Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Doğrulama1		Doğrulama2		Doğrulama3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	2,829 (0,243)	0,984 (0,611)	4,799 (0,091)	0,392 (0,822)	0,166 (0,921)	3,664 (0,160)
MAE	Kruskal Wallis H P-Değeri	3,451 (0,178)	1,052 (0,591)	3,683 (0,159)	2,585 (0,275)	0,361 (0,835)	2,608 (0,271)

Tablo 74: Sunspot Kısa Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Doğrulama1		Doğrulama2		Doğrulama3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	3,694 (0,158)	10,572 (0,005)	2,235 (0,327)	1,352 (0,509)	1,414 (0,493)	0,809 (0,667)
MAE	Kruskal Wallis H P-Değeri	2,203 (0,332)	13,799 (0,001)	1,858 (0,395)	0,116 (0,944)	1,937 (0,380)	0,926 (0,629)

Tablo 75: IBM Veri Seti Üzerinde K ve GGD Ayrışımı Seçim Yöntemlerinin Farklı Deneme Sayılarına Karşı Performansının Kruskal-Wallis Testiyle İncelenmesi

Hata Kriteri	İstatistik	Doğrulama1		Doğrulama2		Doğrulama3	
		K	GGD	K	GGD	K	GGD
MSE	Kruskal Wallis H P-Değeri	2,213 (0,331)	3,299 (0,192)	0,644 (0,725)	0,233 (0,890)	0,600 (0,741)	0,775 (0,679)
MAE	Kruskal Wallis H P-Değeri	2,038 (0,361)	2,725 (0,256)	0,365 (0,833)	0,283 (0,868)	1,295 (0,523)	0,486 (0,784)

Tablo 76: Lynx Veri Seti, Doğrulama2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Deneme1-Deneme2	828	2947 – 2103	0,002
Deneme2-Deneme3	1032	2307 – 2743	0,066
Deneme1-Deneme3	1018	2757 – 2293	0,055

Tablo 77: Lynx Veri Seti, Doğrulama3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Deneme1-Deneme2	912	2863 – 2187	0,010
Deneme2-Deneme3	1200	2575 – 2475	0,365
Deneme1-Deneme3	882	2893 – 2157	0,005

Tablo 78: Sunspot Kısa Veri Seti, Doğrulama1, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Deneme1-Deneme2	764	3011 – 2039	0,000
Deneme2-Deneme3	1042	2317 – 2733	0,076
Deneme1-Deneme3	1018	2757 – 2293	0,055

Tablo 79: Sunspot Kısa Veri Seti, Doğrulama1, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Deneme1-Deneme2	713	3062 – 1988	0,000
Deneme2-Deneme3	1090	2365 – 2685	0,135
Deneme1-Deneme3	903	2872 – 2178	0,009

3.5.5. Önerilen Yaklaşımın Avantajları

GGD Ayrışım seçim stratejisinin başarılı sonuçlar vermesinin sebeplerinin sırasıyla şunlar olduğunu söyleyebiliriz:

- 1) Öncelikle en iyi modeli seçerken tüm uzayda arama yapmak yerine en iyi gecikme yapısına sahip modeller arasından arama yapılarak arama uzayının küçültülerek daha efektif arama yapılması.
- 2) En iyi gecikme yapısına karar verdikten sonra ise seçilecek modelin doğrusal olmama derecesine karar verecek gizli hücrelerin belirlenmesi amacıyla bir önceki adımda belirlenmiş gecikme yapısı üzerinden gizli hücre sayısına karar verilmesi.
- 3) Gecikme ve Gizli hücre sayısına ya da başka bir deyişle gecikme ve gizli uzayına karar verdikten sonra bu uzayda farklı başlangıç ağırlık değerleriyle tekrarlanmış ağlardan hangisinin seçileceği sorusuna, doğrulama setinde en iyi performansı gösteren modelin alınması yerine hem doğrulama hem de

eđitim setinde g receli olarak iyi bir performans g steren ađ alınarak, yalnızca dođrulama setinde veya hem dođrulama hem de eđitim setinde  ok iyi uyum g steren ađın se ilmesinden ka ınılması.

SONUÇ

Yapılan çalışmada, sinir ağıyla zaman serisi tahminlemesi için oluşturulan farklı ağlardan hangisinin geleceği tahminlemek amacıyla seçileceği problemine alternatif bir strateji (GGD ayrışımı) önerilmeye çalışılmıştır. Bu amaca yönelik olarak, hem simülasyonla türetilmiş hem de gerçek zaman serilerinden faydalanılmıştır. Simülasyon verileri kullanılarak altta yatan veri üretim sürecinin bilindiği durumda, önerilen seçim stratejisinin bu süreci doğru bir şekilde yansıtan bir sinir ağı modeli seçip seçmediği araştırılmıştır. Gerçek verilerle çalışarak da farklı karakteristiğe sahip ve içerisinde bilinmeyen yapıda düzensizlik ve gürültü içeren seriler üzerinde, performansının incelenmesine olanak bulunmuştur. Her iki veri seti türü için, GGD ayrışımı seçim stratejisinin klasik seçim yöntemiyle ve kendi alt adımlarıyla tahminleme performans kıyaslamaları yapılmıştır. Böylece klasik seçim stratejisi yerine kullanılıp kullanılmayacağı ve her alt adımın ulaşılan performans üzerinde olumlu bir etkisinin olup olmadığı sorularına cevaplar aranmıştır. Ayrıca, gerçek veri setleri üzerinde daha önce yapılan çalışmalarda oluşturulmuş ARIMA modelleriyle hem klasik hem de GGD ayrışımı seçim yöntemleri bazında karşılaştırmalar düzenlenmiştir. ARIMA ve sinir ağı yöntemlerinin birbirine üstünlüğüne ilişkin yapılan çalışmalarda çelişen sonuçlara ulaşıldığı bilindiğinden, sinir ağının problemli olan bir alanında yapılan düzenlemeyle bu kıyaslamada üstünlüğün daha çok sinir ağı lehine olabilme umudu incelenmiştir. İlaveten çalışma kapsamında, doğrulama hacmi ve deneme sayısının iki farklı seçim stratejisinin sinir ağı tahmin performansı üzerindeki etkisi araştırılmıştır. Doğrulama hacmine karşı hangi seçim stratejisinin daha dirençli olduğunun öğrenilmesi amaçlanmıştır. Sinir ağı çalışmalarında pek önemsenmeyen bir faktör olan ve kaç farklı başlangıç ağırlık değeriyle ağın başlatılmış olduğunu gösteren deneme sayısının, her iki seçim stratejisi için de önemli bir faktör olup olmadığı ve ne kadarlık bir deneme sayılarının yeterli olabileceği araştırılmıştır.

Öncelikle simülasyon deneyine ait sonuçları tartışmak gerekirse, GGD ayrışımı seçim yöntemi hem AR2 hem de GAR modeli için tüm deney faktör kombinasyonları hesaba katılıp klasik seçim yöntemi ve kendi alt adımlarıyla kıyaslandığında, çoğunlukla daha iyi bir performansın ortaya çıkmasına yol açmıştır.

Kendi alt adımlarıyla yapılan karşılaştırmalardan, girdi hücresi ayrışımı yapmanın yeterli olmadığı, gizli hücre ayrışımına gidilmesiyle de sinir ağı performansının geliştiği görülmüştür. Dolayısıyla bu sonuç, gizli hücrenin sinir ağı tahminlemede gerekli ve önemli bir bileşen olduğunu ortaya koymuştur. Tahmin doğruluğunu daha da arttırmak için sadece doğrulama setinde en küçük hataya bakmanın yetersiz olduğu, hem doğrulama hem de eğitim seti performansını hesaba katan deneme ayrışımının gerekli olduğu anlaşılmıştır. Böylece önerilen stratejinin her bir parçasının model seçmede ulaşılan performanstan sorumlu olduğu ve bir bütün olarak daha iyi çalıştığı resmi gösterilmiştir. Simülasyon verileri aracılığıyla doğrulama hacmi artarken her iki seçim yönteminin de gerçek gecikme sayısını doğru bulma şansı arttığı görülmüştür. Buna rağmen, GGD ayrışımı yöntemi her doğrulama hacmi seviyesinde klasik seçim yöntemine göre ciddi oranda farkla gerçek gecikme sayısını doğru olarak belirlemiştir. Ayrıca gizli hücre sayısı bakımından da daha basit sinir ağı modellerini seçmiştir. Dolayısıyla GGD ayrışımının klasik seçim yönteme kıyasla daha basit modelleri seçmesinin, test seti üzerindeki daha iyi performanslarının bir nedeni olduğunu söylemek mümkündür. İki simülasyon verisinde de en küçük doğrulama hacmi söz konusuysa istatistiksel açıdan en çok pozitif anlamlı farka ulaşılmıştır. En büyük doğrulama hacminde doğrulama setinin seriyi temsil etme kabiliyeti arttığından, GG ve GGD ayrışımı arasındaki performans farklılığı azalmıştır. Simülasyon verilerinde deneyin bir faktörü olan gürültü seviyesi elde edilen sonuçları etkilememiştir. Değerlendirme ölçüsü olarak MAE 'nin kullanılmasıyla GGD ayrışımı seçim stratejisinin daha çok sayıda pozitif anlamlı fark ürettiği görülmüştür.

Gerçek verilere ilişkin yapılan deneyin sonuçları incelenince, Lynx verisi için GGD ayrışımı seçim stratejisi klasik seçimle kıyaslandığında daha kötü bir performans göstermemekle beraber büyük çoğunlukla anlamlı bir performans üstünlüğü ortaya koymuştur. Kendi alt adımlarıyla karşılaştırıldığında ise GG ayrışımıyla benzer bir performans sergilediği anlaşılmıştır. Her iki değerlendirme ölçüsü ve deney faktör seviye kombinasyonları hesaba katıldığında, kendi iki alt adımıyla toplamda 36 karşılaştırma noktasının sadece üçünde istatistiksel bakımdan daha düşük performans sergilemiştir. Ayrıca simülasyon verilerinden farklı olarak, en çok pozitif anlamlı fark en büyük doğrulama hacminde elde edilmiştir.

Simülasyon verilerine benzer olarak ise değerlendirme kriteri için MAE ‘nin kullanılması, GGD ayrışımı seçim stratejisinin daha çok sayıda pozitif anlamlı fark üretmesine yol açmıştır.

Sunspot verisi test setinin uzun ve kısa olarak şeklinde alınmasıyla yapılan analizde, her iki test seti üzerinde de GGD ayrışımı seçim stratejisi klasik seçim ve kendi alt adımlarına karşı açık bir üstünlük kurmuş ve anlamlı bir ortalama performans düşüklüğüne rastlanmamıştır. Simülasyon ve Lynx verilerinden farklı olarak, herhangi bir doğrulama hacmi seviyesinde GG ayrışımıyla benzer bir performans ortaya koymamış hatta mutlak bir üstünlük sergilemiş olduğu yorumunu yapmak mümkündür. Kısa test setinin en küçük doğrulama hacmi seviyesinde, bazı performans farklılıkları ortaya çıkmıştır. Bu veri seti için de değerlendirme kriteri olarak MAE ‘nin kullanılmasıyla, GGD ayrışımı seçim stratejisi MSE kriterine göre daha çok sayıda pozitif anlamlı fark üretmiştir.

IBM verisi ele alındığında, GGD ayrışımı seçim stratejisi hem klasik seçime hem kendi alt adımlarına genel anlamda bir üstünlük kurmuştur. Klasik seçime karşı performans düşüklüğü göstermemekle beraber kendi alt adımlarıyla kıyaslandığında, toplamda 36 karşılaştırma noktasının sadece üçünde istatistiksel anlamda düşük performans göstermiştir. Bu üç performans düşüklüğü de en büyük doğrulama hacminde GG ayrışımına karşı ortaya çıkmıştır. Ancak doğrulama hacminin etkisine yönelik yapılan incelemeden bilinmektedir ki IBM verisi için, GGD ayrışımı seçim stratejisinin mutlak üstünlüğünün sağlandığı en küçük doğrulama hacmi seviyesinde ortaya çıkan hata değerleri, öteki doğrulama hacimlerindeki kendi performansından ve diğer performanslardan daha iyidir. Bunun nedeni, serinin finansal seri olmasından ötürü en küçük doğrulama hacminde son döneme ait daha çok verinin eğitime katılması ve daha iyi performans sergileyen ağların ortaya çıkması olduğu düşünülmektedir. Ancak diğer seçim yöntemlerinin bu doğrulama hacmi seviyesindeki iyi ağları seçemedikleri, en küçük doğrulama hacminde GGD ayrışımının mutlak üstünlüğünden anlaşılmaktadır. Ayrıca ikinci doğrulama hacim seviyesinin klasik seçim için en uygun hacim olduğu görülmüş ve bu seviyede GGD ayrışımıyla tamamen benzer performans ortaya konmuştur. Diğer tüm veri setlerinden farklı olması açısından, değerlendirme kriteri olarak MSE ‘nin veya MAE

'nin kullanılması arasında GGD ayrışımı seçim yöntemi için büyük bir farklılık bulunmamaktadır.

Gerçek veri setleri üzerinde ARIMA yöntemiyle yapılan karşılaştırmaları incelediğimizde, Lynx verisi için klasik seçim yöntemi en küçük doğrulama hacmi hariç ARIMA modelinin ürettiği hata değerinden daha iyi olan sinir ağı modelleri seçmiştir. Bu veri seti için eğer doğrulama hacmi yeterli büyüklükte oluşturulursa, klasik seçimin ARIMA modelinden daha iyi tahmin ürettiği sonucuna varılmıştır. GGD ayrışımı stratejisiyle yapılan seçim işlemi sonucunda, tüm doğrulama hacimlerinde ARIMA modelinden istatistiksel olarak anlamlı bir ortalama hata düşüklüğüne ulaşılmıştır. Başka bir deyişle, GGD ayrışım stratejisi ile en küçük doğrulama hacminde bile ARIMA modeline karşı tam bir üstünlük kurulmuştur. Sunspot uzun test seti üzerinde ARIMA modeliyle elde edilen hata değerleri hem klasik seçim yönteminin hem de GGD ayrışım stratejisinin seçtiği sinir ağlarının hata değerlerinden istatistiksel açıdan daha düşüktür. Bu test setinde iki seçim yöntemi de ARIMA modelini geçememiştir. Ancak GGD ayrışımı seçimiyle klasik seçim yöntemine göre daha iyi performans sergileyen ağlar seçilmiştir. Sunspot kısa test setine ait ARIMA modelinin hata değerlerinin klasik seçim yönteminin hata değerlerinden çoğunlukla daha iyi olduğu sonucu gözlemlenmiştir. En büyük doğrulama hacminde performansları arasındaki fark kapanmaya başlamış hatta iki karşılaştırma noktasında klasik seçim anlamlı daha düşük hata değerleri vermiştir. GGD ayrışım stratejisi ise en küçük doğrulama hacmi hariç ARIMA modeline kesin bir üstünlük sağlamıştır. Oluşturulan deneyin 18 karşılaştırma noktasının 13 tanesinde ARIMA modelini geçmiştir. Son olarak IBM verisine ait ARIMA modeliyle iki seçim yönteminin karşılaştırmalarını incelediğimizde, klasik seçim yöntemi sadece ikinci doğrulama hacmi seviyesinde ARIMA modelini geçebilme imkanı bulmuştur. Toplamda 18 karşılaştırma noktasının sadece 4 tanesinde klasik seçimin üstünlüğü vardır. GGD ayrışımıyla seçim stratejisi ise sadece en büyük doğrulama hacminin 3 karşılaştırma noktasında ARIMA modelinden daha iyi performans gösterememiştir. Öteki doğrulama hacimlerinde ise kesin bir üstünlük sağlanmıştır. Diğer veri setlerinde en düşük performanslar en küçük doğrulama hacminde elde edilmişken, daha önce belirtildiği gibi bu serinin finansal olmasından ötürü en iyi performansların en küçük doğrulama hacminde çıkması beklenebilir bir

durumdur. Ancak klasik seçim yöntemi bu performansları sağlayan ağları seçememişken, GGD ayrışımı en küçük doğrulama hacminde daha iyi sinir ağlarını seçebilmiştir.

Doğrulama hacminin etkisini görmek üzere simülasyon verileri üzerinde yapılan incelemede, GAR veri setinde GGD ayrışım stratejisinin doğrulama hacminden etkilenmediği görülmüşken klasik seçim yöntemi her doğrulama hacminde farklı performans gösteren ağlar seçmiştir. Klasik seçim yönteminin doğrulama hacmi arttıkça daha iyi performans gösteren ağları seçtiği görülmüştür. GGD ayrışımının doğrulama hacmine karşı dirençliliği AR2 veri setinde de devam etmiştir ve her doğrulama hacminde benzer performansa ulaşan ağları seçmiştir. AR2 veri setinde sadece ikinci gürültü seviyesinde, klasik seçim doğrulama hacmine karşı istatistiksel olarak dirençsizlik göstermiştir. Ancak diğer gürültü seviyelerinde Kruskal-Wallis H değerleri bazında GGD ayrışımı yöntemiyle kıyaslama yapıldığında, doğrulama hacminden daha çok etkilendiği anlaşılmıştır. Ayrıca her iki veri seti için MSE veya MAE ölçüleri temel alınarak yapılan incelemede, aynı sonuçlara ulaşıldığı gözlemlenmiştir.

Doğrulama hacminin gerçek veri setleri üzerindeki tahminleme performansına olan etkisine yönelik yapılan analizde, Lynx veri seti için klasik ve GGD ayrışım seçim yöntemlerinin her ikisinin de doğrulama hacminden etkilendiği sonucuna varılmıştır. Mann-Whitney U testi sonucunda, her iki yönteminde doğrulama hacmi arttıkça daha iyi tahminleme yeteneğine sahip ağları seçtikleri görülmüştür. Ancak Kruskal-Wallis H değerleri bazında her iki yöntem kıyaslandığında, GGD ayrışımı seçim stratejisinin doğrulama hacmi arttıkça klasik seçime göre daha az performans farklılığına sahip ağları seçtiği yorumunu yapmak mümkündür. Sunspot uzun ve kısa veri setlerine ait yapılan incelemede Lynx veri seti için ulaşılan sonuçlarla aynı sonuçlar elde edilmiştir. Her iki seçim yöntemi de doğrulama hacminden etkilenmekle beraber Kruskal-Wallis H değerleri hesaba katılırsa, GGD ayrışımı yönteminin performans farklılığı daha az olan ağları seçtiği söylenebilir. Yine doğrulama hacmi arttıkça her iki yöntemin daha iyi ağları seçtikleri görülmüştür. IBM verisinde doğrulama hacminin etkisini incelemek üzere yapılan analizin sonucu, diğer gerçek veri setlerinin sonuçlarından farklılık göstermiştir. Yine her iki seçim yönteminin de doğrulama hacminden etkilendikleri

bulgusu elde edilmiştir. Ancak, bu sefer Kruskal-Wallis H değerleri GGD ayrışımı için daha büyük çıkmıştır. IBM verisinin finansal veri olmasından ötürü son dönemden daha fazla etkilenmesi ve doğrulama hacmi küçüldükçe daha iyi ağların ortaya çıkması olasıdır. Dolayısıyla seçim yöntemi daha etkin bir yöntemse, doğrulama hacmi küçüldükçe daha iyi performans gösteren ağları seçmesi beklenebilir. GGD ayrışım stratejisinin bu beklentiye göre hareket ettiği görülmüş ve doğrulama hacminden Kruskal-Wallis H değerleri göz önüne alındığında daha çok etkilenmiştir. Ancak klasik seçim yöntemi özellikle en küçük doğrulama hacminde en büyük hacimle benzer şekilde hareket etmiş en iyi ağları seçememiştir. Sadece ikinci doğrulama hacminde en iyi performans gösteren ağlara sahip olabilmıştır. Son olarak, tüm gerçek veri setleri için MSE ve MAE ölçüleri arasında doğrulama hacmine karşı direnç yönünden bir performans farklılığı görülmemiştir.

Bu çalışmanın amaçlarından biri olan deneme sayısının her iki seçim yöntemi bazında etkisinin olup olmadığına yönelik yapılan analizde, klasik seçim yönteminin deneme sayısından etkilenmediği sonucuna varılmıştır. Bu sonuç farklı doğrulama hacim seviyelerinde de geçerliliğini korumuştur. Dolayısıyla klasik seçim yöntemi için deneme sayısının ulaşılan tahmin performansı üzerinde önemli olmadığı, ancak harcanan bilgisayar zamanı açısından bakılırsa ise bu çalışmada en küçük deneme sayısı olan 10 denemenin makul olduğu yorumu yapılabilir. Aynı yorumu, GGD ayrışımı için yapmak mümkün değildir. GGD ayrışımının hem eğitim hem doğrulama setinde iyi bir performans gösteren ağ arama özelliği, klasik seçim yöntemine göre daha çok deneme sayısına ihtiyaç duyabileceği beklentisini ortaya çıkarabilir. Bu beklentiyi karşılayacak şekilde, farklı deneme sayılarıyla farklı performans gösterebilen ağların seçilebileceği görülmüştür. Yapılan analiz sonucunda, en az deneme sayısı olan 10 denemenin bu farklılığın kaynağı olduğu ortaya çıkmıştır. GGD ayrışımı için 30 ve 50 ‘şer denemeli deneylerde bir performans farklılığı olmadığı anlaşılmıştır. Ancak yine harcanan zaman hesaba katıldığında, GGD ayrışımı için 30 denemeli bir sinir ağı deneyinin makul olacağı sonucuna varılmıştır.

Aşağıda gelecek çalışmalar kapsamında ele alınabilecek muhtemel çalışma konularına yer verilmiştir:

- Hata teriminin varyansı şeklinde temsil edilen gürültü seviyesi normal dağılımdan türetilerek belirlenmiştir. Ancak farklı olasılık dağılımlarından farklı gürültü tipleri oluşturulup daha gerçekçi durumlar yaratılarak, model seçiminde sinir ağının vereceği tepkinin ölçümü yapılabilir.
- Farklı alanlardan daha çok sayıda gerçek veriler üzerinde analizin yapılmaya çalışılması ile muhtemel potansiyel gücün sınırları belirlenerek, ne gibi farklı durumlarda nasıl sonuçların elde edildiğine bakılabilir.
- Çok daha farklı karakteristiğe sahip seriler kullanılarak önerilen model seçim stratejisinin performansı incelenebilir ve ortaya çıkabilecek olası sorunların nasıl giderilebileceğine dair öneriler verilebilir.
- Model seçimi için oluşturulan ağ sonuç uzayının oldukça büyük olması ve birbirine benzer performanslara sahip çok sayıda ağın bulunması sebebiyle, daha küçük sonuç uzaylarında daha etkin arama yapacak ve performans kaybına uğramadan çalışabilecek şekilde önerilen strateji geliştirilmesine yönelik çalışmalar yapılabilir.
- Bu tezde tek bir zaman serisinin analizine yönelik olarak model seçim stratejisi üzerinde durulmuştur. Gelecek araştırmalar için çok değişkenli sinir ağı tahmin modeli varken dolayısıyla birden fazla zaman serisinin olması durumunda nasıl bir seçim stratejisinin izleneceği hakkında çalışmalar yapılabilir.

Son bir değerlendirme yapmak gerekirse, GGD ayrışımının tüm veri setleri ele alındığında ve incelenen tüm deney faktör kombinasyonlarında, klasik seçimden daha kötü bir performans göstermemiştir. Büyük bir çoğunlukla klasik seçim yöntemine göre tahminleme gücü daha yüksek ağırları seçmiştir. Kendi alt adımlarına karşı da açık bir üstünlük kurmuş ve her adımın gerekli olduğu gösterilmiştir. Tahminleme probleminde sinir ağlarıyla uygun gecikme sayısının çoğunlukla tespit edilebileceği görülmüştür. Bunun anlamı, sinir ağlarından hem doğrusal hem de doğrusal olmayan zaman serilerinin otokorelasyon yapısı gibi çeşitli özelliklerini incelemede alternatif bir araç olarak faydalanılabileceğidir. GGD ayrışım stratejisiyle seçilen sinir ağı modellerinin ürettiği tahmin hataları varyansının çoğu durumda daha düşük olduğu gözlemlenmiştir. Böylece uygulama açısından bakıldığında tahminlerin varyansının düşük olması karar vericinin tahminlerin doğruluğuna olan inancını ve güvenini artıracak önemli bir unsur olacaktır. Sinir ağlarının problemlili

bir alanı olan model seçimine yönelik yapılabilecek bir iyileştirmeye ARIMA yöntemiyle olan kıyaslamalarda daha öne geçebileceği yönünde bulgulara ulaşılmıştır. Aşırı uyum sağlama probleminin üstesinden gelmek için sıklıkla kullanılan yöntemlerden biri olan veri setinin üç bölüme ayrılması ve eğitimin doğrulama seti performansına göre durdurulması yönteminin dezavantajlarından biri özellikle küçük örneklerde veri kaybı yaşanmasıdır. Ayrıca doğrulama seti için yeterince örnek verisi ayrılmalıdır ki buradan seçilen nihai modelin genelleme yeteneği iyi olabilsin. Önerilen model seçim stratejisi küçük hacimli doğrulama setine sahip olunması durumuna klasik seçime göre dirençlilik göstererek daha iyi modellerin seçilmesine imkân vermektedir. Genel anlamda doğrulama hacminden daha az etkilendiği yönündeki bulgulara dayanarak, uygulamada avantaj sağlayabileceği düşünülmektedir.

KAYNAKÇA

Adams, J. A. ve Wert, Y. (2005). Logistic and Neural Network Models for Predicting A Hospital Admission. *Journal of Applied Statistics*. 32(8): 861-869.

Aladağ, C.H., Eğrioğlu, E., Günay, S. ve Basaran, M.A. (2010). Improving Weighted Information Criterion by Using Optimization. *Journal of Computational and Applied Mathematics*. 233(10): 2683-2687.

Anders, U. ve Korn, O. (1999). Model Selection in Neural Networks. *Neural Networks* 12(2): 309-323.

Balkin, S. D. ve Ord, J. K. (2000). Automatic Neural Network Modeling for Univariate Time Series. *International Journal of Forecasting*. 16 (4): 509-515.

Baum, E.B. ve Haussler, D. (1989). What Size Net Gives Valid Generalization?. *Neural Computation*. 1(1): 151-160.

Beale, M.H., Hagan, M.T. ve Demuth, H.B. (2012). *Neural Network Toolbox User's Guide*. Natick: The Matworks Inc.

Bishop, C.M. (1995). *Neural Networks for Pattern Recognition*. Oxford: Oxford University Press.

Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*. 31(3): 307-327.

Box, G. ve G. Jenkins. (1970). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.

Brace, M.C., Schmidt, J. ve Hadlin, M. (1991). Comparison of The Forecasting Accuracy of Neural Networks with Other Established Techniques. *Proceedings of*

the First Forum on Application of Neural Networks to Power Systems (ss. 31-35). Seattle, WA. 23-26 Temmuz 1991.

Brockwell, R.J. ve Davis, R.A. (1991). *Time Series: Theory and Methods*. New York: Springer.

Brouwer, R.K. ve Pedrycz, W. (2003). Training A Feed-Forward Network with Incomplete Data Due to Missing Input Variables. *Applied Soft Computing*. 3(1): 23-36.

BuHamra, S., Smaoui, N. ve Gabr, M. (2003). The Box-Jenkins Analysis and Neural Networks: Prediction and Time Series Modelling. *Applied Mathematical Modelling*. 27(10): 805-815.

Callen, J.L., Kwan, C.C.Y., Yip, P.C.Y. ve Yuan, Y. (1996). Neural Network Forecasting of Quarterly Accounting Earnings. *International Journal of Forecasting*. 12(4): 475-482.

Chen, A.S. ve Leung, M.T. (2005). Performance Evaluation of Neural Network Architectures: The Case of Predicting Foreign Exchange Correlations. *Journal of Forecasting*. 24(6): 403-420.

Chen, T. ve Chen, H., 1995. Universal Approximation to Nonlinear Operators by Neural Networks with Arbitrary Activation Functions and Its Application to Dynamical Systems. *IEEE Transactions on Neural Networks*. 6(4): 911-917.

Cheng, B. ve Titterington, D.M. (1994). Neural Networks: A Review From A Statistical Perspective. *Statistical Science*. 9(1): 2-30.

Choudhury, A., Nair, P.B. ve Keane, A.J. (2006). Constructing A Speculative Kernel Machine for Pattern Classification. *Neural Networks*. 19(1): 84-89.

Corder, G.W. ve Foreman, D.I. (2009). *Nonparametric statistics for Non-statisticians*. New Jersey: John Wiley & Sons.

Cottrell, M., Girard, B., Girard, Y., Mangeas, M. ve Muller, C. (1995). Neural Modeling for Time Series: A Statistical Stepwise Method for Weight Elimination. *IEEE Transactions on Neural Networks*. 6(6): 1355-1364.

Courrieu, P. (2006). Density Codes and Shape Spaces. *Neural Networks*. 19(4): 429-445.

Curram, S.P. ve Mingers, J. (1994). Neural Networks, Decision Tree Induction and Discriminant Analysis: An Empirical Comparison. *The Journal of the Operational Research Society*. 45(4): 440-450.

Cybenko, G. (1989). Approximation by Superpositions of A Sigmoidal Function. *Mathematical Control, Signals and Systems*. 2(4): 303-314.

De Gooijer, J.G. ve Kumar, K. (1992). Some Recent Developments in Non-Linear Time Series Modelling, Testing, And Forecasting. *International Journal Forecasting*. 8(2): 135-156.

De Groot, C. ve Wurtz, D. (1991). Analysis of Univariate Time Series with Connectionist Nets: A Case Study Of Two Classical Examples. *Neurocomputing*. 3(4): 177-192.

Denton, J.W. (1995). How Good Are Neural Networks for Causal Forecasting?. *Journal of Business Forecasting Methods and Systems*. 14(2): 17-20.

Diebold, F.X. ve Nason, J.A. (1990). Nonparametric Exchange Rate Prediction?. *Journal of International Economics*. 28(3-4): 315-332.

Donaldson, R.G. ve Kamstra, M. (1997). An Artificial Neural Network-GARCH Model for International Stock Return Volatility. *Journal of Empirical Finance*. 4(1): 17-46.

Eğrioğlu, E., Aladağ, C.H. ve Günay, S. (2008). A New Model Selection Strategy in Artificial Neural Network. *Applied Mathematics and Computation*. 195(2): 591-597.

Engle, R.F. (1982). Autoregressive Conditional Heteroskedasticity with Estimates of The Variance of UK Inflation. *Econometrica*. 50 (4): 987-1007.

Faraway, J.J. (1992). On The Cost of Data Analysis. *Journal of Computational and Graphical Statistics*, 1(3): 213-229.

Faraway, J. ve Chatfield, C. (1998). Time Series Forecasting with Neural Networks: A Comparative Study Using The Airline Data. *Applied Statistics*. 47(2): 231-250.

Fausett, L. (1993). *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*. New Jersey: Pearson.

Foster, W.R., Collopy, F. ve Ungar, L.H. (1992). Neural Network Forecasting of Short, Noisy Time Series. *Computers and Chemical Engineering*. 16(4): 293-297.

Galizia, C.G. ve Szyszka, P. (2008). Olfactory Coding in The Insect Brain: Molecular Receptive Ranges, Spatial and Temporal Coding. *Entomologia Experimentalis et Applicata*. 128(1): 81-92.

Garson, G.D. (1997). *Neural Networks: An Introductory Guide for Social Scientists*. London: Sage.

Ghiassi, M. ve Saidane, H. (2005). A Dynamic Architecture for Artificial Neural Networks. *Neurocomputing*. 63: 397-413.

Gorr, W.L., Nagin, D. ve Szczypula, J. (1994). Comparative Study of Artificial Neural Network and Statistical Models for Predicting Student Grade Point Averages. *International Journal of Forecasting*. 10(1): 17-34.

Guo, Z. ve Uhrig, R. E. (1992). Using Genetic Algorithms to Select Inputs for Neural Networks. *Proceedings of the Workshop on Combinations of Genetic Algorithms and Neural Networks* (ss. 223-234), Baltimore, MD. 6 Haziran 1992.

Gupta, A. ve Lam, M.S. (1996). Estimating Missing Values Using Neural Networks. *The Journal of the Operational Research Society*. 47(2): 229-238.

Gurney, K. (1997). *An Introduction to Neural Networks*. London: UCL.

Hagan, M.T., Demuth, H.B. ve Beale, M. (1996). *Neural Network Design*. Boston: PWS.

Hakeem, M.A., Kamil, M. ve Arman, I. (2008). Prediction of Temperature Profiles Using Artificial Neural Networks in A Vertical Thermosiphon Reboiler. *Applied Thermal Engineering*. 28(13): 1572-1579.

Hansen, J.V., McDonald, J.B. ve Nelson, R.D. (1999). Time Series Prediction with Genetic-Algorithm Designed Neural Networks: An Empirical Comparison with Modern Statistical Models. *Computational Intelligence* 15(3): 171-184.

Hecht-Nielsen, R. (1989). Theory of The Backpropagation Neural Network. *Proceedings of the International Conference on Neural Networks* (ss. 593-605), Washington, DC, USA. 18-22 Haziran 1989.

Hecht-Nielsen, R. (1989). *Neurocomputing*. Reading, MA: Addison Wesley.

- Heravi, S., Osborn, D.R. ve Birchenhall, C.R. (2004). Linear Versus Neural Network Forecasting for European Industrial Production Series. *International Journal of Forecasting*. 20(3): 435-446.
- Hill, T., O'Connor, M. ve Remus, W. (1996). Neural Network Models for Time Series Forecasting. *Management Science*. 42(7): 1082-1092.
- Hinton, G.E. (1989). Connectionist Learning Procedures. *Artificial Intelligence*. 40(1-3): 185-234.
- Hipel, K.W. ve McLeod, A.I. (1994). *Time Series Modelling of Water Resources and Environmental Systems*. Amsterdam: Elsevier.
- Hopfield, J.J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of the Sciences of the U.S.A.* 79(8): 2554-2558.
- Hornik, K., Stinchcombe, M. ve White, H. (1989). Multilayer Feedforward Networks Are Universal Approximators. *Neural Networks*. 2(5): 359-366.
- Hu M.Y., Zhang, G.P., Jiang, C.X. ve Patuwo, B.E. (1999). A Cross-Validation Analysis of Neural Network Out-Of-Sample Performance in Exchange Rate Forecasting. *Decision Sciences*. 30(1): 197-216.
- Hyndman, R.J. (2012). *Time Series Data Library*. www.robjhyndman.com/TSDL/. (12/06/2012).
- Iman, R. ve Conover, W.J. (1983). *Modern Business Statistics*. New York: Wiley.
- Jain, A. ve Kumar, A.M. (2007). Hybrid Neural Network Models for Hydrologic Time Series Forecasting. *Applied Soft Computing*. 7(2): 585-592.

Jain, A.S ve Meeran, S. (1998). Job-Shop Scheduling Using Neural Networks. *International Journal of Production Research*. 36(5): 1249-1272.

Jasic, T. ve Wood, D. (2003). Neural Network Protocols and Model Performance. *Neurocomputing*. 55(3-4): 747-753.

Kaastra, I. ve Boyd, M. (1996). Designing A Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*. 10(3): 215-236.

Kang, S. (1991). *An Investigation of the Use of Feedforward Neural Networks for Forecasting*. (Yayınlanmamış Doktora Tezi). Kent: Kent State University Graduate School of Management.

Kohonen, T. (1982). Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*. 43(1): 59-69.

Kuan, C.M. ve White, H. (1994). Artificial Neural Networks: An Econometric Perspective. *Econometric Reviews*. 13(1): 1-91.

Kurfess, F. J. (2000). Neural Networks and Structured Knowledge: Rule Extraction and Applications. *Applied Intelligence*. 12(1-2): 7-13.

Lachtermacher, G. ve Fuller, J.D. (1995). Backpropagation in Time-Series Forecasting. *Journal of Forecasting*. 14(4): 381-393.

LeBaron, B. ve Weigend, A. (1998). A Bootstrap Evaluation of The Effect of Data Splitting on Financial Time Series. *IEEE Transactions on Neural Networks*. 9(1): 213-220.

Lippmann, R.P. (1987). An Introduction To Computing With Neural Nets. *ASSP Magazine, IEEE*. 4(2): 4-22.

Lu, M., AbouRizk, S.M. ve Hermann, U.H. (2001). Sensitivity Analysis of Neural Networks in Spool Fabrication Productivity Studies. *Journal of Computing in Civil Engineering*. 15(4): 299-308.

Makridakis, S., Anderson, A., Carbone, R., Fildes, R., Hibdon, M., Lewandowski, R., Newton, J., Parzen, E. ve Winkler, R. (1982). The Accuracy of Extrapolation (Time Series) Methods: Results of A Forecasting Competition. *Journal of Forecasting*. 1(2): 111-153.

Makridakis, S., Wheelwright, S.C. ve Hyndman, R.J. (1998). *Forecasting Methods and Applications*. New York: John Wiley & Sons.

McDonald, J. ve Xu, Y. (1994). Some Forecasting Applications of Partially Adaptive Estimators of ARIMA Models. *Economics Letters*. 45(2): 155-160.

McMenamin, J.S. (1997). A Primer on Neural Networks for Forecasting. *Journal of Business Forecasting Methods and Systems*. 16(3): 17-22.

Nakamura, E. (2005). Inflation Forecasting Using A Neural Network. *Economic Letters*. 86(3): 373-378.

Nelson, M., Hill, T., Remus, W. ve O'Connor, M. (1999). Time Series Forecasting Using Neural Networks: Should The Data Be Deseasonalized First?. *Journal of Forecasting*. 18(5): 359-367.

Newbold, P. (2000). *İşletme ve İktisat için İstatistik*. Çev. Ümit Şenesen. İstanbul: Literatür Yayınları.

Priestley, M.B. (1988). *Non-linear and Non-Stationary Time Series Analysis*. San Diego, CA: Academic Press.

Qi, M. ve Zhang, G.P. (2001). An Investigation of Model Selection Criteria for Neural Network Time Series Forecasting. *European Journal of Operational Research*. 132(3): 666-680.

Razali, N.M. ve Wah, Y.B. (2011). Power Comparisons of Shapiro-Wilk Kolmogorov-Smirnov, Lilliefors and Anderson-Darling Tests. *Journal of Statistical Modeling and Analytics*. 2(1): 21-33.

Salchenberger, L.M., Cinar, E.M. ve Lash, N.A. (1992). Neural Networks: A New Tool for Prediction. *Decision Sciences*. 23(4): 899-916.

Schiffmann, W., Joost, M. ve Werner, R. (1993). Application of Genetic Algorithms to The Construction of Topologies for Multi- Layer Perceptron. *Proceedings of the International Conference on Artificial Neural Networks and Genetic Algorithms* (ss.675-682), Austria, 1993.

Schindler, K. H. ve Sanguineti, M. (2003). Bounds on the Complexity of Neural-Network Models and Comparison with Linear Methods. *International Journal of Adaptive Control and Signal Processing*. 17(2): 179-194.

Schittenkopf, C., Deco, G. ve Brauer, W. (1997). Two Strategies to Avoid Overfitting in Feedforward Networks. *Neural Networks*. 10(3) :505-516.

Setyawati, B.R. (2005). *Multi-Layer Feed Forward Neural Networks For Foreign Exchange Time Series Forecasting*. (Yayınlanmamış Doktora Tezi). Morgantown, West Virginia: College of Engineering and Mineral Resources at West Virginia University.

Sharda, R. ve Patil, R.B. (1992). Connectionist Approach to Time Series Prediction: An Empirical Test. *Journal of Intelligent Manufacturing*. 3(5): 317-323.

Stone, L. ve He, D. (2007). Chaotic Oscillations and Cycles in Multi-Trophic Ecological Systems. *Journal of Theoretical Biology*. 248(2): 382-390.

Subba Rao, T. ve Sabr, M. M. (1984). *An Introduction to Bispectral Analysis and Bilinear Time Series Models*. New York: Springer-Verlag.

Tagliaferri, R., Eleuteri, A. ve Barone, F. (2001). Fuzy Min-Max Neural Networks: from Classification to Regression. *Soft Computing*. 5(1): 69-76.

Tang, Z., Almeida, C. ve Fishwick, P.A. (1991). Time Series Forecasting Using Neural Networks vs Box-Jenkins Methodology. *Simulation*. 57(5): 303-310.

Tang, Z. ve Fishwick, P.A. (1993). Feedforward Neural Nets as Models for Time Series Forecasting. *ORSA Journal on Computing*. 5(4): 374-385.

Terasvirta, T., Lin, C.F. ve Granger, C.W.J. (1993). Power of The Neural Network Linearity Test. *Journal of Time Series Analysis*. 14(2): 209-220.

Virili, F. ve Freisleben, B. (2001). Neural Network Model Selection for Financial Time Series Prediction. *Computational Statistics*. 16(3): 451-463.

Walczak, S. (2001). An Empirical Analysis of Data Requirements for Financial Forecasting with Neural Networks. *Journal of Management Information Systems*. 17(4): 203-222.

Walczak, S. ve Cerpa, N. (1999). Heuristic Principles for The Design of Artificial Neural Networks. *Information and Software Technology*. 41(2): 107-117.

Weigend, A.S., Huberman, B.A. ve Rumelhart, D.E. (1990). Predicting The Future: A Connectionist Approach. *International Journal of Neural Systems*. 1(3): 193-209.

Weigend, A.S., Huberman, B.A. ve Rumelhart, D.E. (1992). Predicting Sunspots and Exchange Rates with Connectionist Networks. *Advanced Research Workshop on Nonlinear Modeling and Forecasting* (ss. 395-432), Santa Fe, NM, USA. 24-28 Eylül 1990.

White, H. (1989). An Additional Hidden Unit Test for Neglected Nonlinearity in Multilayer Feedforward Networks. *Proceedings Of The International Joint Conference On Neural Networks*, Washington, DC (ss. 451-455). San Diego, CA, USA. 18-22 Haziran 1989.

Wong, F.S., (1991). Time Series Forecasting Using Backpropagation Neural Networks. *Neurocomputing*. 2(4): 147-159.

Wong, C. S. ve Li, W. K. (2000). On A Mixture Autoregressive Model. *Journal of Royal Statistical Society Series B*. 62(1): 91-115.

Yao, X. (1999). Evolving Artificial Neural Networks. *Proceedings of the IEEE*. 87(9): 1423-1447.

Yao, J. ve Tan, C.L. (2000). A Case Study on Using Neural Networks to Perform Technical Forecasting of Forex. *Neurocomputing*. 34(1-4): 79-98.

Yaralıoğlu, K. (2004). *Uygulamada Karar Destek Yöntemleri*. İzmir: İlkem Ofset.

Yoon, Y., Swales, G.J.R. ve Margavio, T.M. (1993). A Comparison of Discriminant Analysis Versus Artificial Neural Networks. *The Journal of the Operational Research Society*. 44(1): 51-60.

Zhang, G.P. (2001). An Investigation of Neural Network Model for Linear Time-Series Forecasting. *Computers & Operations Research*. 28(12): 1183-1202.

Zhang, G.P. (2003). Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model. *Neurocomputing*. 50: 159-175.

Zhang, G.P. ve Qi, M. (2005). Neural Network Forecasting for Seasonal and Trend Time Series. *European Journal of Operational Research*. 160(2): 501-514.

Zhang, G.P., Patuwo, B.E. ve Hu, M.Y. (1998). Forecasting with Artificial Neural Networks: The State of The Art. *International Journal of Forecasting*. 14(1): 35-62.

Zhang, G.P., Patuwo, B.E. ve Hu, M.Y. (2001). A Simulation Study of Artificial Neural Networks for Nonlinear Time Series Forecasting. *Computers and Operations Research*. 28(4): 381-396.

Zou, H.F., Xia, G.P., Yang, F.T. ve Wang, H.Y. (2007). An Investigation and Comparison of Artificial Neural Network and Time Series Models for Chinese Food Grain Price Forecasting. *Neurocomputing*. 70 (16-18): 2913-2923.

EKLER

EK 1:AR2 Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar

Tablo 1.1: AR2 Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	5,502	0,235	5,448	1,662	5,314	0,46	0,27	0,549
G	5,391	0,291	5,239	2,057	4,857	1,18	1,29	0,000
G-G	5,093	0,401	4,736	2,832	4,763	4,89	29,71	0,000
G-G-D	4,330	0,159	4,318	1,122	4,237	0,19	-0,50	0,598


Tablo 1.2: AR2 Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,871	0,044	1,864	0,311	1,862	0,41	1,09	0,526
G	1,802	0,043	1,796	0,305	1,758	0,34	0,76	0,641
G-G	1,743	0,039	1,730	0,279	1,741	0,73	1,60	0,165
G-G-D	1,656	0,032	1,656	0,228	1,674	0,03	-0,20	0,890

Tablo 1.3: AR2 Modeli, 2.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,02	7,240	2,273	6,920	2,498
Girdi Ayrışımı	0,22	3,540	2,418	6,220	2,923
Girdi-Gizli Ayrışımı	0,22	3,540	2,418	4,940	2,867


Şekil 1.1: AR2 Verileri, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 1.2: AR2 Verileri, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 1.3: AR2 Verileri, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 1.4: AR2 Verileri, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 2: AR2 Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar

Tablo 2.1: AR2 Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	5,911	0,897	5,012	6,345	4,870	6,63	45,74	0,000
G	5,962	0,964	4,720	6,820	4,427	5,60	34,01	0,000
G-G	5,314	0,903	4,416	6,389	4,161	6,77	47,11	0,000
G-G-D	4,436	0,334	4,080	2,361	3,990	5,22	31,94	0,000


Tablo 2.2: AR2 Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,784	0,034	1,771	0,238	1,772	0,76	1,45	0,060
G	1,738	0,038	1,714	0,271	1,702	1,36	2,82	0,001
G-G	1,682	0,034	1,668	0,240	1,649	1,09	2,46	0,013
G-G-D	1,617	0,029	1,606	0,204	1,603	0,98	2,87	0,021

Tablo 2.3: AR2 Modeli, 2.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama Ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,04	6,540	2,651	6,100	2,270
Girdi Ayrışımı	0,50	2,640	1,241	6,820	2,405
Girdi-Gizli Ayrışımı	0,50	2,640	2,418	3,880	2,925


Şekil 2.1: AR2 Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 2.2: AR2 Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 2.3: AR2 Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 2.4: AR2 Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 3: AR2 Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar

Tablo 3.1: AR2 Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	4,974	0,337	4,680	2,382	4,465	4,31	24,51	0,000
G	4,724	0,329	4,430	2,325	4,203	4,87	29,45	0,000
G-G	4,338	0,152	4,262	1,078	4,098	0,91	0,96	0,022
G-G-D	4,071	0,131	4,015	0,926	3,921	0,89	1,15	0,045


Tablo 3.2: AR2 Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,737	0,040	1,719	0,282	1,697	0,93	1,47	0,026
G	1,687	0,037	1,668	0,259	1,658	1,27	2,97	0,004
G-G	1,647	0,029	1,639	0,207	1,608	0,63	-0,25	0,049
G-G-D	1,603	0,027	1,593	0,193	1,568	0,79	0,24	0,032

Tablo 3.3: AR2 Modeli, 2.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,18	5,520	2,742	5,420	2,400
Girdi Ayırımı	0,66	2,440	0,907	5,700	2,197
Girdi-Gizli Ayırımı	0,66	2,440	0,907	2,500	1,717

Şekil 3.1: AR2 Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 3.2: AR2 Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı.



Şekil 3.3: AR2 Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 3.4: AR2 Verileri, 2. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 4: AR2 Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar

Tablo 4.1: AR2 Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	12,801	0,807	12,067	5,706	11,439	1,96	4,41	0,000
G	12,57	1,25	10,99	8,85	10,54	4,53	23,64	0,000
G-G	10,555	0,467	10,158	3,305	9,845	2,03	6,05	0,000
G-G-D	10,178	0,773	9,440	5,469	9,287	5,89	38,83	0,000

Tablo 4.2: AR2 Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,773	0,070	2,742	0,497	2,646	0,78	0,01	0,016
G	2,679	0,064	2,637	0,456	2,618	1,56	3,90	0,000
G-G	2,549	0,047	2,532	0,330	2,495	0,55	-0,46	0,035
G-G-D	2,479	0,042	2,462	0,300	2,449	1,09	3,03	0,010

Tablo 4.3: AR2 Modeli, 3.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi Ve Gizli Hücrelerin Ortalama Ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,04	7,600	2,491	6,280	2,399
Girdi Ayrışımı	0,32	3,400	2,373	6,820	2,413
Girdi-Gizli Ayrışımı	0,32	3,400	2,373	5,260	2,982

Şekil 4.1: AR2 Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 4.2: AR2 Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 4.3: AR2 Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 4.4: AR2 Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 5: AR2 Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar

Tablo 5.1: AR2 Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	25,9	15,5	10,4	109,6	10,2	7,06	49,94	0,000
G	10,307	0,395	10,143	2,795	9,965	0,62	0,38	0,049
G-G	9,483	0,348	9,326	2,463	9,232	0,95	1,86	0,027
G-G-D	9,005	0,257	8,932	1,817	8,470	0,52	-0,76	0,016


Tablo 5.2: AR2 Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,698	0,135	2,577	0,952	2,501	5,76	37,69	0,000
G	2,554	0,047	2,551	0,332	2,589	0,09	0,12	0,520
G-G	2,447	0,043	2,449	0,303	2,419	-0,04	-0,04	0,515
G-G-D	2,411	0,037	2,407	0,265	2,357	0,40	-0,35	0,097

Tablo 5.3: AR2 Modeli, 3.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,08	5,760	2,066	6,240	2,462
Girdi Ayrışımı	0,58	2,880	1,649	6,760	2,520
Girdi-Gizli Ayrışımı	0,58	2,880	1,649	3,620	3,030


Şekil 5.1: AR2 Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 5.2: AR2 Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 5.3: AR2 Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 5.4: AR2 Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 6: AR2 Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar

Tablo 6.1: AR2 Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	11,018	0,881	10,148	6,231	9,703	5,34	33,48	0,000
G	9,949	0,534	9,449	3,774	9,042	2,87	11,93	0,000
G-G	9,266	0,305	9,160	2,157	9,017	0,49	-0,54	0,033
G-G-D	9,107	0,306	8,966	2,160	8,845	0,62	-0,13	0,033


Tablo 6.2: AR2 Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,5624	0,054	2,535	0,381	2,478	1,33	3,35	0,001
G	2,477	0,048	2,455	0,337	2,460	0,68	0,18	0,035
G-G	2,424	0,042	2,422	0,294	2,359	0,08	-1,03	0,096
G-G-D	2,400	0,041	2,397	0,289	2,349	0,16	-0,85	0,308

Tablo 6.3: AR2 Modeli, 3.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,16	5,640	2,716	6,260	2,739
Girdi Ayrışımı	0,66	2,540	1,129	5,880	2,655
Girdi-Gizli Ayrışımı	0,66	2,540	1,129	2,260	1,850


Şekil 6.1: AR2 Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 6.2: AR2 Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 6.3: AR2 Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 6.4: AR2 Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 7: GAR Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar


Tablo 7.1: GAR Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	3,77	2,09	1,51	14,80	1,40	7,01	49,36	0,000
G	2,84	1,49	1,28	10,56	1,23	7,03	49,62	0,000
G-G	1,334	0,102	1,225	0,721	1,143	3,60	17,07	0,000
G-G-D	1,074	0,043	1,049	0,303	1,001	1,00	0,62	0,001

Tablo 7.2: GAR Modeli, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,051	0,062	0,977	0,442	0,941	4,39	23,49	0,000
G	0,956	0,054	0,903	0,379	0,876	5,86	38,28	0,000
G-G	0,904	0,024	0,889	0,173	0,854	1,26	1,91	0,001
G-G-D	0,823	0,016	0,816	0,117	0,794	0,69	0,48	0,089


Şekil 7.1: GAR Verileri, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 7.2: GAR Verileri, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 7.3: GAR Verileri, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 7.4: GAR Verileri, 1.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 8: GAR Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar

Tablo 8.1: GAR Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,383	0,084	1,297	0,596	1,189	2,67	9,32	0,000
G	1,247	0,091	1,153	0,641	1,044	2,53	8,31	0,000
G-G	1,142	0,068	1,078	0,480	1,019	1,92	3,81	0,000
G-G-D	1,097	0,067	1,027	0,473	1,026	2,60	8,51	0,000

Tablo 8.2: GAR Modeli, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	0,9112	0,0212	0,8993	0,1496	0,8979	1,36	3,13	0,001
G	0,8577	0,0247	0,8410	0,1745	0,8130	1,33	2,22	0,001
G-G	0,8339	0,0208	0,8230	0,1469	0,8170	1,09	1,29	0,004
G-G-D	0,8135	0,0168	0,8090	0,1189	0,8011	0,42	-0,29	0,314


Şekil 8.1: GAR Verileri, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 8.2: GAR Verileri, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 8.3: GAR Verileri, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 8.4: GAR Verileri, 1.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 9: GAR Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar


Tablo 9.1: GAR Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,244	0,049	1,230	0,346	1,270	0,89	2,94	0,012
G	1,747	0,445	1,186	3,149	1,176	6,11	39,38	0,000
G-G	1,106	0,042	1,083	0,298	1,106	1,71	6,35	0,000
G-G-D	1,109	0,053	1,068	0,376	1,078	3,92	22,10	0,000

Tablo 9.2: GAR Modeli, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	0,887	0,018	0,883	0,127	0,896	0,28	0,68	0,248
G	0,893	0,026	0,872	0,181	0,876	2,48	8,80	0,000
G-G	0,839	0,015	0,836	0,104	0,847	0,42	1,10	0,302
G-G-D	0,825	0,013	0,825	0,090	0,836	-0,12	-0,52	0,840

Şekil 9.1: GAR Verileri, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 9.2: GAR Verileri, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 9.3: GAR Verileri, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 9.4: GAR Verileri, 1.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 10: GAR Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar

Tablo 10.1: GAR Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	7,250	0,840	6,178	5,942	6,058	4,19	19,21	0,000
G	7,19	1,44	5,31	10,16	5,23	5,30	29,66	0,000
G-G	6,46	1,30	5,06	9,16	4,79	6,62	45,53	0,000
G-G-D	4,686	0,306	4,398	2,165	4,104	4,54	26,10	0,000


Tablo 10.2: GAR Modeli, 2.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,022	0,076	1,959	0,538	1,931	3,41	17,35	0,000
G	1,915	0,086	1,828	0,607	1,797	3,60	15,25	0,000
G-G	1,829	0,063	1,773	0,444	1,762	3,22	14,75	0,000
G-G-D	1,687	0,036	1,668	0,256	1,627	1,48	4,31	0,001

Tablo 10.3: GAR Modeli, 2.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,00	7,380	2,329	6,280	2,516
Girdi Ayrışımı	0,26	3,500	2,517	6,500	2,558
Girdi-Gizli Ayrışımı	0,26	3,500	2,517	4,580	3,078


Şekil 10.1: GAR Verileri, 2. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 10.2: Gar Verileri, 2. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 10.3: Gar Verileri, 2. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 10.4: Gar Verileri, 2. Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 11: GAR Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar

Tablo 11.1: GAR Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	6,488	0,521	5,883	3,682	5,535	3,38	14,06	0,000
G	5,586	0,470	5,076	3,326	4,962	4,42	24,19	0,000
G-G	5,299	0,372	4,902	2,631	4,698	3,54	16,10	0,000
G-G-D	4,877	0,258	4,620	1,822	4,387	2,19	5,92	0,000


Tablo 11.2: GAR Modeli, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,920	0,048	1,895	0,341	1,850	1,33	3,56	0,002
G	1,816	0,045	1,792	0,321	1,785	1,82	6,77	0,000
G-G	1,764	0,038	1,750	0,269	1,742	0,86	1,38	0,077
G-G-D	1,710	0,033	1,701	0,236	1,671	0,56	0,07	0,282

Tablo 11.3: GAR Modeli, 2.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,04	6,320	2,706	6,040	2,703
Girdi Ayrışımı	0,46	2,460	2,187	6,820	2,585
Girdi-Gizli Ayrışımı	0,46	2,460	2,187	4,260	2,522

Şekil 11.1: GAR Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 11.2: GAR Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 11.3: GAR Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 11.4: GAR Verileri, 2.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 12: GAR Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar

Tablo 12.1: GAR Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	4,928	0,183	4,832	1,294	4,788	1,29	3,15	0,001
G	4,561	0,146	4,493	1,035	4,349	1,54	4,86	0,001
G-G	4,708	0,274	4,400	1,935	4,323	3,63	15,15	0,000
G-G-D	4,300	0,150	4,215	1,064	4,177	2,09	8,40	0,000


Tablo 12.2: GAR Modeli, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	1,758	0,032	1,753	0,225	1,734	0,25	-1,14	0,032
G	1,716	0,029	1,702	0,204	1,702	1,15	2,89	0,005
G-G	1,706	0,031	1,689	0,221	1,671	1,16	2,37	0,002
G-G-D	1,660	0,027	1,649	0,191	1,652	0,70	0,81	0,047

Tablo 12.3: GAR Modeli, 2.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,08	5,300	3,234	5,660	2,584
Girdi Ayrışımı	0,62	1,580	0,883	6,160	2,629
Girdi-Gizli Ayrışımı	0,62	1,580	0,883	3,100	2,501


Şekil 12.1: GAR Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 12.2: GAR Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 12.3: GAR Verileri, 2. Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 12.4: GAR Verileri, 2.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 13: GAR Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Setine Ait Sonuçlar

Tablo 13.1: GAR Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	19,03	2,89	15,23	20,43	14,09	4,28	18,70	0,000
G	24,09	7,15	14,04	50,59	11,84	5,53	33,46	0,000
G-G	15,28	2,05	12,35	14,49	11,16	3,21	10,04	0,000
G-G-D	10,359	0,462	10,130	3,269	9,906	1,51	4,79	0,001


Tablo 13.2: GAR Modeli, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	3,167	0,114	3,080	0,804	3,027	2,27	8,08	0,000
G	3,026	0,150	2,874	1,060	2,785	2,72	8,81	0,000
G-G	2,765	0,077	2,747	0,547	2,680	0,55	0,18	0,268
G-G-D	2,536	0,048	2,540	0,338	2,474	0,02	-0,15	0,663

Tablo 13.3: GAR Modeli, 3.Gürültü Seviyesinde ve 25 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,00	7,260	2,414	6,340	2,396
Girdi Ayrışımı	0,38	3,360	2,798	7,000	2,483
Girdi-Gizli Ayrışımı	0,38	3,360	2,798	4,520	3,032


Şekil 13.1: GAR Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 13.2: GAR Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 13.3: GAR Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 13.4: GAR Verileri, 3.Gürültü Seviyesi ve 25 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 14: GAR Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Setine Ait Sonuçlar

Tablo 14.1: GAR Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	12,49	1,13	11,24	8,02	10,77	5,14	31,07	0,000
G	12,14	1,39	10,23	9,81	9,80	4,38	19,64	0,000
G-G	11,93	1,27	10,30	8,98	9,34	4,32	21,38	0,000
G-G-D	9,211	0,230	9,217	1,624	9,034	0,10	-0,54	0,704


Tablo 14.2: GAR Modeli, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,703	0,058	2,673	0,411	2,639	1,11	1,84	0,007
G	2,618	0,059	2,571	0,420	2,528	1,86	5,14	0,000
G-G	2,596	0,062	2,553	0,435	2,456	1,30	1,64	0,000
G-G-D	2,431	0,033	2,428	0,235	2,370	0,27	0,31	0,635

Tablo 14.3: GAR Modeli, 3.Gürültü Seviyesinde ve 50 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,04	6,460	2,894	6,040	2,338
Girdi Ayrışımı	0,40	2,520	1,887	7,000	2,657
Girdi-Gizli Ayrışımı	0,40	2,520	1,887	3,440	2,287


Şekil 14.1: GAR Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 14.2: GAR Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 14.3: GAR Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 14.4: GAR Verileri, 3.Gürültü Seviyesi ve 50 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 15: GAR Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Setine Ait Sonuçlar

Tablo 15.1: GAR Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mse Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	10,161	0,306	10,053	2,166	9,839	0,60	0,31	0,164
G	9,669	0,306	9,570	2,163	9,393	0,63	0,56	0,238
G-G	9,112	0,253	9,022	1,790	8,690	0,59	0,28	0,208
G-G-D	9,206	0,310	8,987	2,189	8,766	1,88	6,05	0,000


Tablo 15.2: GAR Modeli, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Elde Edilen Mae Ölçülerinin Tanımlayıcı İstatistik Değerleri

	Ort	Std Hata	Kırp Ort	Std Sap	Medyan	Çarpıklık	Basıklık	Normallik
K	2,559	0,040	2,546	0,285	2,546	0,55	0,69	0,326
G	2,494	0,043	2,483	0,301	2,458	0,60	0,81	0,370
G-G	2,422	0,037	2,405	0,262	2,379	0,93	1,48	0,042
G-G-D	2,415	0,036	2,400	0,255	2,387	0,76	0,99	0,134

Tablo 15.3: GAR Modeli, 3.Gürültü Seviyesinde ve 75 Doğrulama Seti Verisiyle Elde Edilen Girdi ve Gizli Hücrelerin Ortalama ve Standart Sapma Değerleri

	GUDBO	OrtGecikme	StdGecikme	OrtGizli	StdGizli
Klasik Yöntem	0,12	5,660	3,179	4,920	2,530
Girdi Ayrışımı	0,58	1,600	0,833	5,800	2,886
Girdi-Gizli Ayrışımı	0,58	1,600	0,833	2,900	2,384


Şekil 15.1: GAR Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 15.2: GAR Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Girdi Hücrelerinin Frekans Dağılımı



Şekil 15.3: GAR Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde Klasik Yönteme Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



Şekil 15.4: GAR Verileri, 3.Gürültü Seviyesi ve 75 Doğrulama Seti Hacminde G-G-D Ayrışımına Göre Elde Edilen Gizli Hücrelerin Frekans Dağılımı



EK 16: Lynx Veri Setine Ait Sonuçlar

Tablo 16.1: Lynx Veri Seti, Deneme1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	155	3620 – 1430	0,000
Doğrulama2-Doğrulama3	973	2248 – 2802	0,028
Doğrulama1-Doğrulama3	317	3458 – 1592	0,000

Tablo 16.2: Lynx Veri Seti, Deneme1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	141	3634 – 1416	0,000
Doğrulama2-Doğrulama3	1016	2291 – 2759	0,053
Doğrulama1-Doğrulama3	215	3560 – 1490	0,000

Tablo 16.3: Lynx Veri Seti, Deneme1, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1177	2598 – 2452	0,307
Doğrulama2-Doğrulama3	825	2950 – 2100	0,002
Doğrulama1-Doğrulama3	673	3102 – 1948	0,000

Tablo 16.4: Lynx Veri Seti, Deneme1, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1177	2598 – 2452	0,307
Doğrulama2-Doğrulama3	802	2973 – 2077	0,001
Doğrulama1-Doğrulama3	681	3094 – 1956	0,000

Tablo 16.5: Lynx Veri Seti, Deneme2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	271	3504 – 1546	0,000
Doğrulama2-Doğrulama3	1146	2629 – 2421	0,237
Doğrulama1-Doğrulama3	117	3658 – 1392	0,000

Tablo 16.6: Lynx Veri Seti, Deneme2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	228	3547 – 1503	0,000
Doğrulama2-Doğrulama3	1113	2662 – 2388	0,173
Doğrulama1-Doğrulama3	64	3711 – 1339	0,000

Tablo 16.7: Lynx Veri Seti, Deneme2, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1058	2717 – 2333	0,093
Doğrulama2-Doğrulama3	1136	2639 – 2411	0,216
Doğrulama1-Doğrulama3	841	2934 – 2116	0,003

Tablo 16.8: Lynx Veri Seti, Deneme2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	920	2855 – 2195	0,012
Doğrulama2-Doğrulama3	1119	2656 – 2394	0,183
Doğrulama1-Doğrulama3	661	3114 – 1936	0,000

Tablo 16.9: Lynx Veri Seti, Deneme3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	195	3580 – 1470	0,000
Doğrulama2-Doğrulama3	1187	2588 – 2462	0,332
Doğrulama1-Doğrulama3	148	3627 – 1423	0,000

Tablo 16.10: Lynx Veri Seti, Deneme3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	214	3561 – 1489	0,000
Doğrulama2-Doğrulama3	1203	2572 – 2478	0,373
Doğrulama1-Doğrulama3	145	3630 – 1420	0,000

Tablo 16.11: Lynx Veri Seti, Deneme3, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1235	2510 – 2540	0,459
Doğrulama2-Doğrulama3	781	2994 – 2056	0,000
Doğrulama1-Doğrulama3	806	2969 – 2081	0,001

Tablo 16.12: Lynx Veri Seti, Deneme3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1113	2662 – 2388	0,173
Doğrulama2-Doğrulama3	825	2950 – 2100	0,002
Doğrulama1-Doğrulama3	609	3166 – 1884	0,000

EK 17: Sunspot Uzun Veri Setine Ait Sonuçlar

Tablo 17.1: Sunspot Uzun Veri Seti, Deneme1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	867	2142 – 2908	0,004
Doğrulama2-Doğrulama3	254	3521 – 1529	0,000
Doğrulama1-Doğrulama3	614	3161 – 1889	0,000

Tablo 17.2: Sunspot Uzun Veri Seti, Deneme1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	844	2119 – 2931	0,005
Doğrulama2-Doğrulama3	256	3509 – 1541	0,000
Doğrulama1-Doğrulama3	628	3147 – 1903	0,000

Tablo 17.3: Sunspot Uzun veri seti, Deneme1, GGD ayrışımı ve MSE kriterine karşılık gelen grubun Mann-Whitney U testiyle post-hoc analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1162	2613 – 2437	0,272
Doğrulama2-Doğrulama3	656	3119 – 1931	0,000
Doğrulama1-Doğrulama3	510	3265 – 1785	0,000

Tablo 17.4: Sunspot Uzun Veri Seti, Deneme1, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1110	2665 – 2385	0,167
Doğrulama2-Doğrulama3	669	3106 – 1944	0,000
Doğrulama1-Doğrulama3	458	3317 – 1733	0,000

Tablo 17.5: Sunspot Uzun Veri Seti, Deneme2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1122	2397 – 2653	0,189
Doğrulama2-Doğrulama3	237	3538 – 1512	0,000
Doğrulama1-Doğrulama3	397	3378 – 1672	0,000

Tablo 17.6: Sunspot Uzun Veri Seti, Deneme2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1093	2368 – 2682	0,140
Doğrulama2-Doğrulama3	205	3570 – 1480	0,000
Doğrulama1-Doğrulama3	423	3552 – 1698	0,000

Tablo 17.7: Sunspot Uzun Veri Seti, Deneme2, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1224	2551 – 2499	0,429
Doğrulama2-Doğrulama3	647	3128 – 1922	0,000
Doğrulama1-Doğrulama3	669	3106 – 1944	0,000

Tablo 17.8: Sunspot Uzun Veri Seti, Deneme2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1110	2385 – 2655	0,167
Doğrulama2-Doğrulama3	539	3236 – 1814	0,000
Doğrulama1-Doğrulama3	647	3128 – 1922	0,000

Tablo 17.9: Sunspot Uzun Veri Seti, Deneme3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	770	2045 – 3005	0,001
Doğrulama2-Doğrulama3	154	3621 – 1429	0,000
Doğrulama1-Doğrulama3	687	3088 – 1962	0,000

Tablo 17.10: Sunspot Uzun Veri Seti, Deneme3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	720	1995 – 3055	0,000
Doğrulama2-Doğrulama3	190	3585 – 1465	0,000
Doğrulama1-Doğrulama3	633	3142 – 1908	0,000

Tablo 17.11: Sunspot Uzun Veri Seti, Deneme3, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1206	2481 – 2569	0,381
Doğrulama2-Doğrulama3	873	2902 – 2148	0,005
Doğrulama1-Doğrulama3	848	2927 – 2123	0,003

Tablo 17.12: Sunspot Uzun Veri Seti, Deneme3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1170	2445 – 2605	0,290
Doğrulama2-Doğrulama3	669	3106 – 1944	0,000
Doğrulama1-Doğrulama3	731	3044 – 2006	0,000

EK 18: Sunspot Kısa Veri Setine Ait Sonuçlar

Tablo 18.1: Sunspot Kısa Veri Seti, Deneme1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	760	2035 – 3015	0,000
Doğrulama2-Doğrulama3	248	3527 – 1523	0,000
Doğrulama1-Doğrulama3	659	3116 – 1934	0,000

Tablo 18.2: Sunspot Kısa Veri Seti, Deneme1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	810	2085 – 2965	0,001
Doğrulama2-Doğrulama3	217	3558 – 1492	0,000
Doğrulama1-Doğrulama3	566	3209 – 1841	0,000

Tablo 18.3: Sunspot Kısa Veri Seti, Deneme1, GGD Ayırışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	637	3198 – 1912	0,000
Doğrulama2-Doğrulama3	675	3100 – 1950	0,000
Doğrulama1-Doğrulama3	265	3510 – 1540	0,000

Tablo 18.4: Sunspot Kısa Veri Seti, Deneme1, GGD Ayırışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	808	2967 – 2083	0,001
Doğrulama2-Doğrulama3	547	3228 – 1822	0,000
Doğrulama1-Doğrulama3	288	3487 – 1563	0,000

Tablo 18.5: Sunspot Kısa Veri Seti, Deneme2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	774	2049 – 3001	0,001
Doğrulama2-Doğrulama3	204	3571 – 1479	0,000
Doğrulama1-Doğrulama3	541	3234 – 1816	0,000

Tablo 18.6: Sunspot Kısa Veri Seti, Deneme2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	824	2099 – 2951	0,002
Doğrulama2-Doğrulama3	201	3574 – 1476	0,000
Doğrulama1-Doğrulama3	548	3227 – 1823	0,000

Tablo 18.7: Sunspot Kısa Veri Seti, Deneme2, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1113	2662 – 2388	0,173
Doğrulama2-Doğrulama3	486	3286 – 1761	0,000
Doğrulama1-Doğrulama3	484	3291 – 1759	0,000

Tablo 18.8: Sunspot Kısa Veri Seti, Deneme2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1149	2424 – 2626	0,243
Doğrulama2-Doğrulama3	398	3377 – 1673	0,000
Doğrulama1-Doğrulama3	550	3225 – 1825	0,000

Tablo 18.9: Sunspot Kısa Veri Seti, Deneme3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	924	2199 – 2851	0,013
Doğrulama2-Doğrulama3	120	3655 – 1395	0,000
Doğrulama1-Doğrulama3	389	3386 – 1664	0,000

Tablo 18.10: Sunspot Kısa Veri Seti, Deneme3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	922	2197 – 2853	0,012
Doğrulama2-Doğrulama3	184	3591 – 1459	0,000
Doğrulama1-Doğrulama3	480	3295 – 1755	0,000

Tablo 18.11: Sunspot Kısa Veri Seti, Deneme3, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	803	2972 – 2078	0,001
Doğrulama2-Doğrulama3	726	3049 – 2001	0,000
Doğrulama1-Doğrulama3	435	3340 – 1710	0,000

Tablo 18.12: Sunspot Kısa Veri Seti, Deneme3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1137	2638 – 2412	0,218
Doğrulama2-Doğrulama3	433	3342 – 1708	0,000
Doğrulama1-Doğrulama3	478	3297 – 1753	0,000

EK 19: IBM Veri Setine Ait Sonuçlar

Tablo 19.1: IBM Veri Seti, Deneme1, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	863	2912 – 2138	0,004
Doğrulama2-Doğrulama3	688	1963 – 3080	0,000
Doğrulama1-Doğrulama3	1248	2527 – 2523	0,494

Tablo 19.2: IBM Veri Seti, Deneme1, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	918	2857 – 2193	0,011
Doğrulama2-Doğrulama3	1001	2276 – 2774	0,043
Doğrulama1-Doğrulama3	1049	2726 – 2324	0,083

Tablo 19.3: IBM Veri Seti, Deneme1, GGD Ayırışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1227	2502 – 2548	0,437
Doğrulama2-Doğrulama3	697	1972 – 3078	0,000
Doğrulama1-Doğrulama3	751	2026 – 3024	0,001

Tablo 19.4: IBM Veri Seti, Deneme1, GGD Ayırışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1247	2528 – 2522	0,491
Doğrulama2-Doğrulama3	686	1961 – 3089	0,000
Doğrulama1-Doğrulama3	729	2004 – 3046	0,000

Tablo 19.5: IBM Veri Seti, Deneme2, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	975	2800 – 225	0,029
Doğrulama2-Doğrulama3	736	2011 – 3039	0,000
Doğrulama1-Doğrulama3	1092	2367 – 2683	0,138

Tablo 19.6: IBM Veri Seti, Deneme2, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	965	2810 – 2240	0,025
Doğrulama2-Doğrulama3	909	2184 – 2866	0,010
Doğrulama1-Doğrulama3	1172	2603 – 2447	0,295

Tablo 19.7: IBM Veri Seti, Deneme2, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1123	2398 – 2652	0,190
Doğrulama2-Doğrulama3	740	2015 – 3035	0,000
Doğrulama1-Doğrulama3	682	1957 – 3093	0,000

Tablo 19.8: IBM Veri Seti, Deneme2, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	1053	2328 – 2722	0,087
Doğrulama2-Doğrulama3	882	2157 – 2893	0,006
Doğrulama1-Doğrulama3	808	2083 – 2966	0,001

Tablo 19.9: IBM Veri Seti, Deneme3, K Seçim ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	671	3104 – 1946	0,000
Doğrulama2-Doğrulama3	675	1950 – 3100	0,000
Doğrulama1-Doğrulama3	1150	2625 – 2425	0,246

Tablo 19.10: IBM Veri Seti, Deneme3, K Seçim ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	701	3074 – 1976	0,000
Doğrulama2-Doğrulama3	993	2268 – 2782	0,000
Doğrulama1-Doğrulama3	883	2892 – 2158	0,038

Tablo 19.11: IBM Veri Seti, Deneme3, GGD Ayrışımı ve MSE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	964	2239 – 2811	0,025
Doğrulama2-Doğrulama3	614	1889 – 3161	0,000
Doğrulama1-Doğrulama3	578	1853 – 3197	0,000

Tablo 19.12: IBM Veri Seti, Deneme3, GGD Ayrışımı ve MAE Kriterine Karşılık Gelen Grubun Mann-Whitney U Testiyle Post-Hoc Analizi

Grup Karşılaştırması	Mann-Whitney U İstatistiği	Sıralama Toplamı Farkı	P-Değeri
Doğrulama1-Doğrulama2	931	2206 – 2843	0,014
Doğrulama2-Doğrulama3	729	2004 – 3046	0,000
Doğrulama1-Doğrulama3	642	1917 – 3133	0,000