

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



**BİLGİ KRİTERİNİ KULLANARAK UYGUN ARMA
MODELLERİNDE DEĞİŞKEN SEÇİMİ YAPMAK:
SİLİKON VADİSİ ŞİRKETLERİNE İLİŞKİN HİSSE
SENEDİ UYGULAMASI**

YÜKSEK LİSANS TEZİ

Alev KAYA

Anabilim Dalı: İstatistik

Program: İstatistiksel Bilgi Sistemleri

Danışman: Prof. Dr. Sinan ÇALIK

ELAZIĞ-2018

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BİLGİ KRİTERİNİ KULLANARAK UYGUN ARMA MODELLERİNDE
DEĞİŞKEN SEÇİMİ YAPMAK: SİLİKON VADİSİ ŞİRKETLERİNE İLİŞKİN
HİSSE SENEDİ UYGULAMASI**

YÜKSEK LİSANS TEZİ

Alev KAYA
(161133101)

Danışman: Prof. Dr. Sinan ÇALIK

Tezin Enstitüye Verildiği Tarih: 05 Temmuz 2018

Tezin Savunulduğu Tarih: 26 Temmuz 2018

Tez Danışmanı : Prof. Dr. Sinan ÇALIK (F.Ü)

Diğer Jüri Üyeleri : Doç. Dr. Mehmet GÜRCAN

Dr. Öğr. Üyesi Ayşe METİN KARAKAŞ

TEMMUZ-2018

ÖNSÖZ

Akademik çalışmalara adım atacağım bu çalışmamda bana bilgi birikimi, tecrübesiyle yardımcı olan ve beni destekleyen danışmanım, Sayın Hocam Prof. Dr. Sinan ÇALIK' a ve çalışmamın uygulama aşamasında bana yardımcı olan Sayın Hocam Öğr. Gör. Dr. Emrah Hanifi FIRAT' a ve son olarak da değerli KAYA ailemin her bir ferdine (annem, babam ve üç erkek kardeşime) gösterdikleri özveriden dolayı teşekkürler...



İÇİNDEKİLER

ÖNSÖZ	I
İÇİNDEKİLER.....	II
ÖZET	IV
SUMMARY	V
ŞEKİLLER LİSTESİ	VI
SEMBOLLER LİSTESİ	VII
KISALTMALAR.....	X
1. GİRİŞ	1
1.1 Silikon vadisi	3
1.1.1. Silikon Vadisi Tarihi.....	4
1.1.2. Stanford Üniversitesi	5
1.1.3. Diğer Gelişmeler	6
1.1.4. Silikon Vadisinin Önceki Yıllara Ait Bazı Araştırma Sonuçları	9
1.1.5. Silikon Vadisi Kültürü	11
1.1.5.1. Çevre Kültürü.....	11
1.1.5.2. Analiz Kültürü	12
1.1.5.3. Deneyim Aktarımı Kültürü	12
1.1.5.4. Danışman Kültürü	12
1.1.5.5. Girişimci Sermayesi Kültürü	13
1.1.6. Silikon Vadisine Ait Önemli Bir Anketin Sonuçları	13
1.1.7. Silikon Vadisi Kopyalanabilir Mi	14
1.1.8. Yaşanılan Alanda Ekosistem Yaratma Tavsiyeleri.....	15
1.2. ARMA Modelleri.....	15
1.2.1. AR(p) Modelleri	16
1.2.1.1. AR(1) ve AR(2) Süreci	17
1.2.1.2. AR(p) Modellerinde Gecikme Operatörünün Kullanımı	19
1.2.2. MA(q) Modelleri.....	20
1.2.2.1. MA(1) ve MA(2) Süreci	21
1.2.2.2. MA(q) Modellerinde Gecikme Operatörünün Kullanımı	21

1.2.3.	ARMA (p,q) Modelleri	22
1.2.3.1.	ARMA(p,q) Modellerinde Gecikme Operatörü	23
1.2.4.	ARIMA(p,d,q) Modelleri	24
2.	MATERYAL ve METOT.....	29
2.1.	Materyal	29
2.2.	Model Seçimi Ve Bilgi Kriterleri	29
2.2.1.	Cimrilik Prensibi	31
2.2.2.	Entropi.....	31
2.2.3.	Kullback-Leibler Uzaklığı	34
2.2.4.	Fisher Bilgi Matrisi	35
2.3.	Model Seçim Kriterleri	36
2.3.1.	R^2 Seçim Kriteri	36
2.3.2.	RD^2 Seçim Kriteri	38
2.3.3.	Akaike Bilgi Kriteri (AIC)	38
2.3.4.	Schwartz Bilgi Kriteri (SBC)	40
2.3.5.	Tutarlı Akaike Bilgi Kriteri ($CAIC - AIC_c$).....	40
2.3.6.	Fisher Bilgi Matrisine Dayalı Tutarlı Akaike Bilgi Kriteri ($CAICF$)	40
2.3.7.	Bilgi Ölçümü Ve Bigi Karmaşıklığı	41
2.3.8.	ICOMP -Tipi Bilgi Kriterleri	45
3.	BULGULAR	49
4.	SONUÇ.....	60
	KAYNAKLAR	61
	ÖZGEÇMİŞ.....	65

ÖZET

Birçok konuda Regresyon Analizi uygulanırken bağımlı değişken veya değişkenleri etkileyecek bağımsız değişkenlerin saptanması çoğu zaman güç olmaktadır. İstatistiksel çıkarımdaki problemlerin büyük bir çoğunluğu istatistiksel modelleme ile ilgili sorunlardandır denebilir. Model Seçimi, açıklayıcı değişkenlerden hangisi ya da hangilerinin açıklanan değişken üzerinde etkili olduğunu ortaya koyarak mevcut aday modeller içerisinde en uygun modelin en basit modelle seçilmesi sürecidir. En uygun modelin en basit modelle seçilmesinin analiz sırasında hem hesaplama rahatlığı hem de veri derlenmesindeki maliyet tablosunda hafifletici etkiye sahiptir. Problemin boyutunun indirgenmesiyle, model parametrelerinin daha doğruya yakın bir şekilde tahmin edilmesi ve daha açık tespitlerde bulunulması da sağlanır. Bu çalışmada Silikon Vadisindeki on büyük şirketin bir aylık süreçte günlük hisse senetlerine ait değerleri, ARMA modelli bir zaman serisi analizinde AIC, AICc, BIC bilgi kriterleri kullanılarak uygun model için gerekli değişken seçimi yapılmış, optimal sonuçlar ortaya konulmaya çalışılmıştır.

Anahtar Kelimeler: Model Seçimi, Bilgi Kriterleri, Silikon Vadisi, Teknoloji, ARMA modelleri, AIC, BIC, AICc

SUMMARY

DIFFERENT CHOICE OF APPROPRIATE ARMA MODEL USING THE INFORMATION CRITERION: APPLYING THE SHARE CERTIFICATE OF SILICONE VALLEY COMPANIES

In many cases, it is often difficult to identify dependent variables or independent variables that will affect variables when Regression Analysis is applied. A large number of problems in the statistical inference may be related to statistical modeling problems. Model Selection is the process of choosing the most suitable model from the existing candidate models by using the simplest model, revealing which of the explanatory variables or which ones are effective on the explained variable. Choosing the most appropriate model with the simplest model has both computational comfort during analysis and mitigating effect on the cost table in the data compilation. By reducing the size of the problem, it is also possible to estimate the model parameters more accurately and make clearer determinations. In this study, the values of the daily stocks of the ten largest companies in the Silicon Valley during the one month period and the AIC, AICc and BIC information criteria in the ARMA model time series analysis were used to determine the appropriate variables for the optimal model.

Key Words: Model Selection, Information Criteria, Silicon Valley, Technology, ARMA Models, AIC, BIC, AICc

ŞEKİLLER LİSTESİ

Şekil 1.1. Silikon Vadisi.....	3
Şekil 1.2. Stanford Üniversitesi.....	5
Şekil 1.3. Hain Sekizler.....	6
Şekil 1.4. İntel Firması	7
Şekil 1.5. Google Şirketi	8
Şekil 1.6. Facebook Şirketi	9
Şekil 1.7. Silicon Valley Dream's	14
Şekil 2.1. Parametre sayısının varyans ve eğilimle ilişkisi	31



TABLÖLAR LİSTESİ

Tablo 3.1.	APPL firmasının bir aylık hisse senedi verileri	50
Tablo 3.2.	APLL firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	50
Tablo 3.3.	INTC firmasının bir aylık hisse senedi verileri	51
Tablo 3.4.	INTC firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	51
Tablo 3.5.	FB firmasının bir aylık hisse senedi verileri	52
Tablo 3.6.	FB firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları	52
Tablo 3.7.	ORCL firmasının bir aylık hisse senedi verileri	53
Tablo 3.8.	ORCL firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	53
Tablo 3.9	CSCO firmasının bir aylık hisse senedi verileri	54
Tablo 3.10.	CSCO firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	54
Tablo 3.11.	EBAY firmasının bir aylık hisse senedi verileri.....	55
Tablo 3.12.	EBAY firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	55
Tablo 3.13	VMW firmasının bir aylık hisse senedi verileri.....	56
Tablo 3.14.	VMW firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	56
Tablo 3.15.	HPQ firmasının bir aylık hisse senedi verileri.....	57
Tablo 3.16.	HPQ firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	57
Tablo 3.17.	GILD firmasının bir aylık hisse senedi verileri	58
Tablo 3.18.	GILD firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	58
Tablo 3.19.	ISRG firmasının bir aylık hisse senedi verileri.....	59
Tablo 3.20.	ISRG firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları.....	59

SEMBOLLER LİSTESİ

n	: Gözlem sayısı
p	:Değişken sayısı
μ	: Ortalama vektörü
λ	: Özdeğerler
Σ	:Anakütle varyans-kovaryans matrisi
$\hat{\Sigma}_{MLE}$	: Varyans – kovaryans matrisinin maksimum olabilirlik tahmini
S	:Örnek varyans-kovaryans matrisi
ε	:Hata,gürültü
$I(X)$	: Bilgi miktarı
$H(X)$	:Entropi
$\otimes$	:Kronecker iç çarpım
$L(\theta X)$	: Olabilirlik fonksiyonu
$\mathcal{F}(\theta)$	: Fisher bilgi Matrisi
$\hat{\mathcal{F}}(\theta)^{-1}$	: Ters Fisher bilgi Matrisi
$l(\theta X)$	:Olabilirlik fonksiyonun logaritması
D	:Dublikasyon matrisi
D^+	: D'nin Moore-Pensore tersi
R	: Toplam risk
$R(M)$	: Modelleme riski
$R(E)$	: Kestirim riski
$E(X)$	: Beklenen değer
$C_0(\Sigma)$	: Varyans-kovaryans matrisi için Van Emden komplekslik ölçüsü
$C_1(\Sigma)$	: Varyans-kovaryans matrisi için maksimal komplekslik ölçüsü
$f(X)$	: Ortak dağılım fonksiyonu
$f_i(X_i)$	: Marjinal dağılım fonksiyonu
$N_p(\mu, \Sigma)$	: Çok değişkenli normal dağılım
$\text{tr}(\Sigma)$	: Matrisin izi
$ \Sigma $	: Kovaryans matrisinin determinantı, genelleştirilmiş varyans
$\text{rank}(\Sigma)$	: Matrisin rankı
λ_a	: Özdeğerlerin aritmetik ortalaması
λ_g	: Özdeğerlerin geometrik ortalaması
σ^2	: Varyans bileşeni
Σ^{-1}	: Hassas-precision matris
$\hat{r}^2(h)$	:Kalıntıların otokorelasyon katsayısını
I	: Fark alma işlemi
Q	: Box-Ljung Q testi
L	: Geçikme operatörü
δ	: Sabit terim
$\hat{I}$	: Dönem gecikmesi
Y_t	: t dönemli bağımlı değişken gözlem değerleri

Φ_t : t dönemli geçmiş gözlem değerleri
 θ : t dönemli hata terimleriyle ilgili katsayılar
 ρ_k : Otokorelasyon Katsayısı
 ρ_{kk} : Kısmi otokorelasyon katsayısı



KISALTMALAR

ACF	: Otokorelasyon katsayı Fonksiyonu
ADF	: Genelleştirilmiş Dickey Fuller Testi
AIC	: Akaike bilgi kriteri
AR	: Otoregresif süreçli modeller
BIC	: Bayes bilgi kriteri
CAIC	: Tutarlı Akaike bilgi kriteri
CAICF	: Fisher bilgi matrisinin kullanıldığı tutarlı Akaike bilgi kriteri
CICOMP	: Tutarlı bilgi karmaşıklığı kriteri
CP	: Cimrilik Prensibi
ÇDR	: Çoklu regresyon analizi
GAIC	: Genelleştirilmiş Akaike bilgi kriteri
ICOMP	: Bilgi karmaşıklığı kriteri
ICOMP-MISS	: Modelin hatalı belirlenme riskini değerlendiren bilgi karmaşıklığı kriteri
ICOMP-PEU	: Sonsal beklenen faydaya bir yaklaşım olarak bilgi karmaşıklığı kriteri
IFIM	: Ters Fisher Bilgi Matrisi
KL	: Kullback-Leibler uzaklığı
MA	: Hareketli ortalama süreçli modeller
PACF	: Kısmi otokorelasyon katsayı fonksiyonu
RA	: Regresyon Analizi
SBC	: Schwartz bilgi kriteri

1. GİRİŞ

İnsanların ihtiyaçları doğrultusunda gelişmesinde, ilerlemesinde icatların, buluşların rolü büyüktür. Yani insanlığın gelişimi ve icatlar arasında güçlü bir korelasyon vardır. Eski dönemlerden beri geleceğin belirsizliği insanoğlunu meraklandırmış, tedirgin etmiş ve bu tedirginliğin azaltılması veya giderilmesi için çeşitli yöntemler uygulanmıştır. Önceleri bilimsel olmayan yöntemlerle (kâhinler, din adamları, falcılar, ...) aşılmaya çalışılan belirsizlik, geleceğin ne getireceği, nasıl tedbirler alınacağı vb. gibi soruların cevaplarının merakı, yönetici statüsündeki (derebeyi, imparator, ...) kişileri daha çok ilgilendirmiştir. İkinci dünya savaşından sonra bilimsel yöntemlerle açıklanmaya çalışılan belirsizlik kavramı istatistik tahmin teknikleriyle daha güvenilir sonuçlara bağlanmaya çalışılmıştır. İstatistik tahmin tekniklerinden biri olan ilişkiye Dayalı Tahmin Teknikleri, tahmin edilecek değişkenin kestiriminde bu değişkeni etkileyen etkenlerin belirlenip varsa bu ilişkinin matematiksel bir formla ifade edilmesidir. İlişki Analizi (Relationship Analysis) veya Regresyon Analizi (Regression Analysis) veya Tahmin Teknikleri (Forecasting Techniques) adlarıyla da anılmaktadır. Bu tahmin tekniklerin iki temel işlevi vardır. Birincisi; tahmin, ikincisi; karar vericiye politika saptamakta yardımcı olmaktır [1].

Regresyon Analizi; bir veya birden çok bağımlı (açıklanan) ve bağımsız (açıklayıcı) değişkenler arasındaki ilişkinin varlığını, varsa bu ilişkinin yönünün ve gücünün potansiyeliyle belirlenmiş veriyi kullanarak bağımlı değişkenlerinin değerlerinin tahmininde başvuru bir istatistik yöntemidir [2].

Regresyon Analizi'nin çeşitli adlandırmaları vardır:

Bağımsız değişken sayısına göre;

- a- Basit Regresyon Analizi (Tek Bağımsız Değişkenli = Simple Regression Analysis)
- b- Çoklu Regresyon Analizi (Birden Çok Bağımsız Değişkenli = Multiple Regression Analysis)

Fonksiyon tipine göre;

- a- Doğrusal Regresyon Analizi(Linear Regression Analysis)
- b- Doğrusal Olmayan(Eğrisel) Regresyon Analizi (Nonlinear Regression Analysis)

Verilerin kaynağına göre;

- a- Anakütle Verileriyle Regresyon Analizi
- b- Örnek Verileriyle Regresyon Analizi
- c- Zaman Serilerinde Regresyon Analizi (Eşleştirilmiş Zaman Serileri = Regression Analysis in Time Series- Cointegration Analysis)


vb. buna benzer farklı çeşitlerde de sınıflandırılabilir.

Birçok alanda olduğu gibi ekonomi ve işletmecilik alanlarında da genellikle bir ekonomik değişkeni tek bir bağımsız (açıklayıcı) etkenle açıklamak yeterli olmayabilir. Ekonomik değişkenler kompleks (karmaşık) değişkenler olduğundan, bir çok kompleks değişken bir araya gelerek bir değişkeni etkileyebildikleri gibi kendi aralarında da birbirleriyle ilişkili olabilmektedirler. Bu nedenle tek bağımsız değişkenli Regresyon Analizi yapmak gerçeği açıklamada yetersiz ve eksik olduğundan birden fazla bağımsız değişkenli analizlere (Çoklu Regresyon Analizi-ÇDR) ihtiyaç vardır.

Bu çalışmada birden çok etkene bağlı bir değişkenin analizinde 1970'lerden günümüze kadar gelmiş olan, geleneksel yöntemlerden farklı bir yaklaşımla, bilgi kriterlerini kullanarak en gerçekçi modelin en az değişkenle optimal model ortaya konması hedeflenmiştir. Çalışma ana başlık altında dört bölümden oluşmaktadır. Birinci bölümde; üzerinde çalıştığımız açıklanan değişkenin genel özellikleri açıklayıcı etkileriyle ilgili bilgiler sunulmakta, ikinci bölümde; zamana bağlı gözlemlerden yararlanıldığından ARMA modelleriyle çalışma genişletilmekte, üçüncü bölümde; bu etkenlerin (bağımsız değişkenlerin) belirlenmesinde geleneksel yöntemlerden farklı bir yaklaşımla bilgi kriterlerini kullanarak materyal ve metot açıklanmakta ve son bölümde; uygulama yapılarak sonuçla birlikte çalışma tamamlanmaktadır.

Dünya bu gün Endüstri 4.0, uzay madenciliği, yapay zeka, dijital sağlık, akıllı yolları, ...konuşurken, kuşkusuz teknoloji, zeka, matematik, inovasyon, ...vb. kavramlar gittikçe daha önem kazanmaktadır. Bu dönem akıl almaz boyutlarda ilerlemekte, bunu yakalayamayan toplumlar ters orantılı bir şekilde gerilemektedir. Bilimde, teknolojiye söz sahibi ülkelerin geleceği daha güvenilir bilgilerle göz önündedir. Bu devletlerin başında ABD gelmektedir. ABD' de çoğu bölge ileri teknoloji, inovasyon, ARGE, ...uğraşırken bu bölgelerden en popüler olanı Silikon Vadisi' dir. Bu bölümde uygulama kısmında seçilen on büyük şirketin kurulduğu yer olan Silikon Vadisi hakkında genel bilgiler verilmektedir.

1.1Silikon vadisi



Şekil 1.1. Silikon Vadisi

Silikon Vadisi (Silicon Valley) şekil 1.1.’ de gösterildiği gibi; yeni fikirlerin bir garajda doğup dünyaya yayıldığı, hiç yoktan başlayıp dünyanın en zengin kişisi haline gelenlerin, girişim gücünün ve dünyanın düşünme, çalışma ve yaşama kültürünü değiştirenlerin, yaratıcılığın doğduğu yerdir. Bilgi ve teknolojinin neler yapabileceğini ve dünyanın nasıl etkileneceğini gösteren en güzel örneklerden biridir. Silikon Vadisi büyük teknoloji şirketlerine ev sahipliği yapan, radyo, telgraf, silikon çip, yarı iletken transistörler, google, facebook gibi iletişim devlerinden, tıptan hukuka, bilimden sanata ve günümüzde çok popüler konu olan yapay zekaya kadar a’ dan z’ ye her türlü oluşumun izlerini barındıran bir bölgedir.

ABD ‘nin Kaliforniya eyaletinin Kuzeyinde bulunan San Francisco Körfezinin güney kesimine verilen takma bir addır. San Jose şehri ve civarındaki şehir ve kasabaları içeren Santa Clara bölgesindeki Santa Clara Vadisi’nden ismini almaktadır. Bölge San Mateo bölgesinde bulunan San Francisco yarım adasının güney yakasını ve Alameda bölgesinin doğu körfezinin güney bölümlerini içeren bir bölgedir. Silikon isminin sebebi bölgede önceleri yoğun olarak üretilen ve geliştirilen silikon çip üreticilerinden gelmektedir. Daha çok tasarım ve mühendislik vadisi olarak anılmaktadır. Vadi AR-GE faaliyetlerinin, ileri teknolojilerinin ve elektroniğin en yoğun şekilde kullanıldığı alan olup amaç yarı iletken teknolojinin geliştirilmesiydi. Sonradan yüksek teknoloji ile ilgili sektörleri ifade etmede kullanıldı [3].

1.1.1. Silikon Vadisi Tarihi

1800 yılların ortalarında Kuzey Amerika' nın batı sahilinde bulunan Kaliforniya' nın başkenti El Dorado bölgesinde altın yatakları keşfiyle bu eyalet Altın Eyaleti olarak anılmaya başlandı. Aynı zamanda süt, bal ve üzüm üretiminde de meşhur bir bölge olmasıyla geçim kaynağı açısından rahat bir yerleşim yerine dönüştüğünden girişimci ruhlu kişileri cezpt etti. Başarısında birçok etkenin olduğu yapay olmayan doğal bir oluşumdur. STEM araştırma üssü, risk sermayeleri çokluğu, öğrencileri, Stanford Üniversitesi, ...gibi faktörlerle bu popülerliğe gelmiştir.

11 Eylül 1853'te Kaliforniya'da ilk telgraf anahtarının tıklandığı, İspanya-Amerikan savaşından sonra (Amerika zaferiyle) Filipinler' den dönen Amerikan Filosunun dönüşünü bildiren San Francisco gemisinden kıyıya gönderilen ilk telsiz telgraf mesajıyla,

1909 yılında Charles Herrold, San Jose'de düzenli yayınlanan programlarla ABD'deki ilk radyo istasyonuyla,

1910 yılında Diod iletkeninin mucidi Lee De Forest Kaliforniya'ya yerleşip, radyo, kıtalar arası telefon iletişimi, televizyon, radar ve dijital elektroniğinin gelişmesine katkıda bulunmasıyla,

1933-1947 yılları arasında Kaliforniya'da bulunan Sunnyvale Have Üssü Birleşik Devletler Hükümeti tarafından kullanılmaya başlanan Deniz Hava Üssü (NASA) ile,

1939-1940 yıllarında Körfez Bölgesi İşçi Hareketi tarafından Eitel McCullough'da yapılan bir sendika örgütlenmesi, emeklilik ikramiyesi, kar paylaşımı, sağlık sigortası, ... gibi imkanları sunan refah kapitalizmi stratejisinin benimsenmesiyle kurulan işbirliği ve dayanışma ortamıyla (sonraki yıllarda EU ve başka sendikalar tarafından yapılan örgütlenmeler veya grevler çok başarılı olamadı.)

4 Ekim 1957'de Sovyetler Birliği Sputnik uydusunu uzaya fırlatarak teknolojik olarak öne çıktığı korkusuyla, başkan Eisenhower Ulusal Havacılık ve Uzay Yasasını (NASA) imzalanarak, dünyada transistör üretebilen tek şirket olan Fairchild Semiconductor ' a yönelmesiyle, ...

ve bunların gibi bir çok oluşumlarla vadi öncülüğünde hayata kazandırılan gelişmeler temelinde vadi ilk oluşum dönemini verimli bir şekilde geçirmiştir [3].

1.1.2. Stanford Üniversitesi



Şekil 1.2. Stanford Üniversitesi

Silikon Vadisi'nin temellerinin atıldığı şekil 1.2.'de gösterilen Stanford Üniversitesi, Kaliforniya'nın eski Valisi Leland Stanford tarafından 1891 de kuruldu. Vadinin babası olarak bilinen üniversitenin dekanı Frederick Terman üniversitedeki yaklaşık 8000 dönümlük araziye başta teknoloji şirketlerine kiralayarak buranın teknoloji merkezi olmasına ön ayak olmuştur. Stanford mezunları Bill Hewlett ve David Packard üniversitenin desteği ile 1939 yılında kampüs yakınındaki bir garajda Hewlett- Packard (HP) şirketini kurdular. Eastman Kodak, General Electric ve Lockheed de Stanford'un diğer ilk kiracıları arasındaydı. 1954'te üniversitenin yüksek lisans ve doktora öğrencilerinin öğrenimlerini devam ettirmesine izin veren tam zamanlı çalışma konusunda Stanford Mezunları İşbirliği Programını başlattı. Böylece şirketlerle öğrenciler arasında bir köprü kurulmaya çalışıldı.

1956' da William Shockley, Shockley Semiconductor Laboratuvarını bu bölgeye taşıyarak, transistörün mucidi çalışmalarıyla elektronik gelişmenin temelini oluşturdu. O zamanlar yarı iletken malzeme olarak germanyum kullanan birçok araştırmacının aksine transistörde silikon kullanarak üretmenin daha iyi sonuçlar verdiğini keşfetti. Ancak mevcut transistörü geliştirmek var olan kadar basit olmadığından maliyetleri karşılayamadı ve çalışmalarına son verdi. Onunla birlikte çalışan sekiz mühendis ayrılarak Fairchild Semiconductor' u kurdular. Shockley, onlara daha sonra meşhur olacak lakabla şekil 1.3.' de de gösterilen “Hain Sekizler” olarak hitap etti.



Şekil 1.3. Hain Sekizler

Daha sonra Fairchild Semiconductor' ın iki çalışanı Robert Noyce ve Gordon Moore Intel' i kurdular. Silikon Vadisi'nde ilk ödöl William Shockley, John Bardeen ve Walter Brattain' ın ilk yarı iletken transistörü icat ederek aldıkları Nobel ödölüdür.

1963' te Doug Engelbert, Fair Stanford Araştırma Enstitüsünde ilk bilgisayar faresini (Mouse) geliştirdi ve internette online sisteminin temellerini attı. Shockley firmasının bünyesinde yirmi yıldan beri çalışan elemanlar ayrıldıktan sonra 70'e yakın şirket kuruldu. Elemanların kendi aralarındaki yaratıcılıkta rekabeti Silikon Vadisi'nde çok normal bir olaydı ve dolayısıyla bölgede kimse sözleşmeli olarak çalışmak istemiyordu. Diğer eyaletlerde teknoloji şirketlerinde çalışan elemanlar sözleşmeli çalıştığından işi bıraktıklarında işverenine rakip olacak şekilde ayrı bir iş kuramıyorlardı. Silikon Vadisi'nde bu kültür çok iyi benimsenmişti.

1.1.3. Diğer Gelişmeler

1963'te Palo Alto'daki bir toplantıda Pentagon ARPA' daki Bilgi İşlem Teknikeri Ofisinin (IPTO) ilk direktörü olan JCR Licklider " Galaksiler Arası Bilgisayar Ağı Üyeleri ve Ortakları" başlıklı konuyla hükümetlerin, kurumların, şirketlerin ve bireylerin etkileşim içinde olduğu herkese açık bir elektronik alan hayal etmekteydi. Licklider 1962-1964 yılları arasında görevde kaldığında bilgi teknolojisindeki en önemli üç gelişmeyi başlattı. Birincisi; Çeşitli büyük üniversitelerde bilgisayar bilimleri bölümlerinin oluşturulması, ikincisi; Zaman paylaşımı, üçüncüsü; Ağ oluşturulması.1960'lı yılların sonu ile 1970'li yılların başında Licklider'in konsepti internet ağ şebekesine dönüşen ARPANET 'İN ilkel bir versiyonuna esin oldu.

Özellikle Asyalı, Latin ve Portekizliler 1965 yılında Göçmenlik ve Uyraklık Yasası ve Vietnamlı teknelerin kitlesel göçüyle Vadiye yöneldi. Burada göçmenler yüksek teknoloji ve üretime büyük katkılar sağladılar. Santa Clara’da 1970’te yapılan nüfus araştırmasında Asyalı-Amerikalı nüfus 43.000 iken 2000 yılında 430.000 yükseldi. Aynı dönemde Latin nüfusu bölgede %24 iken San Jose’de %30 büyüdü. Bölgede Afrikalı-Amerikalı nüfus sabit kalarak ancak % 5’e yükselebildi.

Şekil 1.4. ‘ de görülen İntel firması 1974 Nisan’da bir bilgisayar üzerinde İlk kullanışlı Micro işlemci çip İNTEL 8080 piyasa sürdü.

Bilgisayar, bilgisayar parçaları devreleri, DIY yapımı işlemciler, ...gibi yapıları pazarlamak maksadıyla toplanan bir grup istekli ve gayretli grup Homebrew Bilgisayar Klubü’nü kurdu. Grubun kurucuları olan Gordon French ve Fed Moore insanların bilgisayarlara daha erişebilir hale getirmeye çalışmaları için düzenli ve açık bir form oluşturmak istiyorlardı. People Bilgisayar Şirketi tarafından MITS Altair mikro bilgisayarlarının gözden geçirilmesi için 1975’te Kaliforniya Menlo Park’ta French’in garajında ilk toplantı yapıldı. Apple I ve Apple II bilgisayarlarının esinini bu toplantıda Steve Wozniak ve Steve Jobs aldıklarını belirtmişlerdi.



Şekil 1.4. İntel Firması

Ethernet 1972’ de internet temelli LAN (Local Area Network) teknolojisi olan veri alış verişini sağlamayı başardı. “LAN Protokolü” adı verilen protokol bir merkezde yakın olan bilgisayarların iletişimi anlamına geliyordu.

Xerox Palo Alto’daki araştırma merkezinde lazer yazıcıyı icat etti.

İlk dizüstü WYSIWYG (What You See Is What You Get) sistemi geliştirildi.

1970'lerin başında bölgede yarı iletken şirketler ve bilgisayar firmaları bide her ikisine de hizmet veren programlama ve hizmet şirketleri vardı. Konut fiyatlarının ucuzluğu ve endüstriyel alan bolluğundan dolayı büyüme 1972'de Girişim Sermayesi Endüstrisinin ortaya çıkmasına neden oldu. Apple Computer' ın 1980'de 1.3 Milyar-Dolarlık halka arzının ardından girişim sermayesinin popüleritesini de arttırdı.

1980'lerde yazılım ve internet hizmetlerindeki yenilikler bir hobi dergisi olan Intelligent Machines Journal (adını sonra Infoword olarak değiştirdi) Palo Alto' daki ofisleri ve bilgisayar endüstrisini, bilgisayar işletim sistemlerini, yazılımları ve kullanıcı ara yüzlerini önemli derecede katkı sunarak dünyaya aktardı.

1994 yılında Jerry Yang, Stanford Üniversitesinde bir karavanın arkasında arama motoru olan Yahoo!'yu kurdu.

1995 yılında internet ticari kullanıma açıldı ve internet başlangıcının ilk dalgası Amazon.com, eBay ve Craigslist'in faaliyetleri başladı.



Şekil 1.5. Google Şirketi

1998 yılında Mountain View 'da Sergie Prin ve Larry Page, şekil 1.5.' de de verilen Google şirketini kurdu.

2000'li yıllara doğru NASDAQ borsasının düşüşüyle çöken nokta.com etkisiyle bölge kısa süre içinde dünyanın en pahalı emlak fiyatlarının, ticari gayrimenkullerinin yeri ve gelişen ekonomi ciddi trafik sıkışıklığına neden olmaktaydı.

Harvard'lı bir öğrenci olan Mark Zuckerberg 2004 yılında şekil 1.6. 'da verilen Facebook' u kurdu ve şirketini Palo Alto' ya taşıdı.



Şekil 1.6. Facebook Şirketi

Nokta.com' un çöküşünden sonra Silikon Vadisi dünyanın en iyi ARGE merkezlerinden biri olarak konumunu korumaya devam etti. 2006 yılında Wall Street Journal' ın bir çalışması Amerika'da en yaratıcı 20 ilçenin 12'sinin Kaliforniya' da olduğunu ve bunların 10' unun Silikon Vadisi' nde bulunduğunu ortaya koymuştur.

2005 yılında açılan program patentleriyle listenin birincisi San Jose 3.867 patent, ikinci 1.881 patentle Sunnyvale oldu. Silikon Vadisi değeri bir milyar doları aşan başlangıç şirketleri için kullanılan “Unicorn” girişimcilerine ev sahipliği yapmaktadır.

1.1.4. Silikon Vadisinin Önceki Yıllara Ait Bazı Araştırma Sonuçları

Eklenen bölgelerine bağlı olarak Vadi'nin nüfusu 3.5 – 4 arası değişmektedir. 1999 da AnnaLee Saxenian'ın Kaliforniya Kamu Politikaları Enstitüsü için yaptığı araştırmaya göre Silikon Vadisi'nde çalışan bilim adamları ve mühendislerin üçte birinin göçmen olduğu, 1980'lerden bu yana ileri teknoloji şirketlerinin yaklaşık dörtte birinin Çinli(%17) ve Hintli(%7) Ceo'lar tarafından yönetildiği ortaya konuldu.

AeA tarafından 2008 yılında yapılan bir araştırma göre 2006 yılında Silikon Vadisi, Newyork ve Washington metropolitan alanının ardından 225.300 ileri teknoloji çalışanı ile ABD'nin üçüncü en büyük ileri teknoloji merkezi (siber şehri) oldu. Silikon Vadisi'nin körfez alanı 387.000 yüksek teknoloji çalışanı ile birinci sırada yer almaktaydı. Herhangi bir metropol şehrindeki ileri teknoloji çalışanlarının oranı olarak en yüksek olan bölgedir. Özel sektörde çalışan her 1000 çalışanın 285.9' u yüksek teknoloji işçisidir. Ortalama

144.800 dolara yüksek teknoloji çalışanına en yüksek maaşı ödeyen bölgedir. San Jose, Sunnyvale, Santa Clara Bölgeleri, Amerika'daki kişi başına en fazla milyonerin ve milyarderin yaşadığı yerler olarak raporda bildirilmiştir.

Vadi 2011 yılında ABD'nin toplam girişim yatırımının %41'ini ve 2012 yılında da %46 'lık payına sahiptir.

Çekirdek sanayisinin transistör imalatının yapılmasında üretim iş gücünü çoğunlukla düşük ücretle çalışmayı kabul eden Asya ve Latin göçmenlerin oluşturması, entegre devrelerinin imalatında kullanılan kimyasal maddelerinin bulunması Vadi'yi zirveye taşıyan etkenlerdir.

Bölgede inşa edilen konutların fiyatlarındaki yükseliş, üretim bölümünde çalışan işçilerin karşılayamayacağı miktarda artıştıydı. 2016 yılı itibariyle iki odalı bir dairenin aylık kirası 2.500 dolar iken ortalama bir evin fiyatı 1 milyon dolardı. Evsizlik orta gelirli aileler için önemli bir sorun olduğundan 2015 yılı itibariyle San Jose dışında sığınma evleri bu ihtiyacı karşılayamıyordu. Buna çözüm olarak eski oteller yenilenerek sığınma evleri yapılmaya başlandı.

Kaliforniya Üniversitesinde 2006 yılında kadınların iş hayatındaki liderliğini analiz etmek amacıyla bir rapor yayınlandı. Raporda Kaliforniya merkezli 400 en büyük kamu şirketinin 103'ünün Santa Clara bölgesinde bulunmasına rağmen Silikon Vadisi şirketlerinde kadın Ceo'lar %8.8 idi. Bu eyalette en düşük yüzdeydi (San Francisco'da %19.2, Marin County'de %18.5,...). Teknoloji liderliği pozisyonlarının neredeyse tamamına yakını erkek egomanyası altındaydı. Bu egomanya yeni kurulan şirket sayısında ve girişim sermayesi finansmanında da belirgindi. “Wadhwa” ya göre; erkeklerin bu sektördeki hakimiyetinin nedeni ebeveynlerin fen ve mühendislik alanlarında verdikleri cinsiyet eşitsizliği teşvikleriydi. Ayrıca sektörde kadın rol model olmadığından ve Bill Gates, Steve Jobs ve Mark Zuckerberg gibi en ünlü teknoloji liderlerinin erkek olduğunu kaydetti.

2014 yılında Google, Yahoo!, Facebook, Apple ve diğer teknoloji şirketleri çalışanları hakkında ayrıntılı rapor yayınlandı. Google dünya çapında teknoloji çalışanlarının %17'si kadın, ABD'de teknik işçilerin %1'nin siyahi ve %2'sinin Hispanik olduğunu açıkladı. Yahoo! teknoloji çalışanlarının %15'ni kadınların %2'sinin siyahi, %4'ünün Hispanik olduğunu açıkladı. Facebook teknoloji işgücünün %15'ini kadınlardan

,%1'inin siyahilerden, %3'ünün Hispanik'lerden oluştuğunu açıkladı. Apple dünya genelinde teknik personelinin %80'ninin erkek olduğunu ve ABD'de teknik işlerinin %54'ünün Kafkas kökenliler, %23'ünü Asya kökenliler tarafından yapıldığını bildirdi.

USA Today, Vadi'nin teknoloji endüstrisinin çalışanlarıyla ilgili raporunda, çalışanların çok büyük bir bölümünün beyaz, erkek ve Asya'lı olduğunu belirtti. Siyahi ve Hispanik'lerin oranının çok az olduğu ve kadınların dev şirketlerden yeni teşebbüslere veya girişim sermayesi finansmanlarından diğer oluşumlarda yeterince temsil edilmediği vurgulandı. 2014 yılı itibariyle Silikon Vadisi'ndeki bazı yüksek profilli firmalar kadınların iş gücüne daha fazla ortak edilmesine yardımcı olarak aktif çalışmalar başlatıldı.

1.1.5. Silikon Vadisi Kültürü

1.1.5.1. Çevre Kültürü

Türkiye'deki gibi girişi çıkışı belli olan teknopark benzeri bir yapıya sahip olmayan, devlet desteğiyle şekillenmeyen doğal bir oluşumdur. Stanford Üniversitesinden yeni mezun olan öğrencilerin üniversitenin bulunduğu Palo Alto'nun tüm sokaklarında, barlarında, restoranlarında, kafelerinde, ...vb. girişim, girişimcilik, yatırımcılık ruhundan oldukça etkilenirler. Türkiye'de nasıl bir egemen futbol kültürü varsa, özellikle Palo Alto'da da yaşamın her anında, yerinde girişimcilikle ilgili kültür hakimdir.

Stanford Üniversitesindeki Öğretim Görevlileri'nin ve Öğretim Üyeleri'nin birçok girişim ve yatırım şirketlerinde danışman olduğu göz önüne alınırsa öğrencilerin de böyle oluşumlardan etkilenmesi doğaldır. Türkiye'de Etohum ve Girişim Fabrikası gibi sadece birkaç oluşum dışında böyle alanlar bulunması zordur. Çok iyi maaşlar teklif edilmesine rağmen öğrencilerin çoğu mezuniyet sonrası olmasa bile hayatlarının bir bölümünde girişimci olmayı kafalarına koymuş olarak hayatını planlıyorlar. Özellikle Stanford öğrencilerinin en büyük avantajlarından biri; daha okurken çevre yapabilme şansını yakalamaları. Üst sınıf arkadaşlarının, sıra arkadaşlarının yatırımcı girişimci olduğunu veya teknoloji şirketlerinde çalışmaya başladığını düşünürsek mezun olduklarında iş bulabilmeleri ve iş kurmaları daha da kolaylaşıyor diyebiliriz [4].

1.1.5.2. Analiz Kültürü

Çoğu girişimci Vadide fikir aşamasındayken fikirlerini arkadaşlarına anlatıyor, notlar alıyor, bilgi alış verişinde bulunuyor. Türkiye’deki gibi fikirler kendine saklanıp gizli kapaklı biçimde ilerlenmiyor. Fikir aşamasından prototip aşamasına geçtiklerinde de bazen tanıdıklarından bazen de farklı girişim sahiplerinden topladıkları sermayenin üçte birine yakınını prototiplerini test etmek için test gruplarına harcıyorlar. Test gruplarından elde ettikleri bildirimleri çok iyi irdeleyip sonuçlarını da “melek yatırımcı” diye nitelendirilen yatırımcılar ile paylaşıyorlar. Yatırımcının karşısına çıktıklarında “ biz bu probleme çözüm ürettik, şu kadar kişiyle de ürünümüzün testirini kullandırдық ve şu analizlerle şu sonuçlara vardık...” diyorlar. Yani hem yatırımcı karşısında ellerini güçlendiriyorlar hem de yatırımcının göze alacağı risk faktörlerini azaltıyorlar. Ürünün Pazar beklentisi ile örtüşmesi olarak da nitelendirilen (Product Market Fit) bu durum ileride birçok açıdan zarar edecek şirketlerin kapatmasının önüne geçiyor hem girişimcinin hem yatırımcının işini kolaylaştırıyor [4].

1.1.5.3. Deneyim Aktarımı Kültürü

Silikon Vadisi’nde neredeyse her gün her akşam sürekli belli konularda, eğitim tadında, deneyim aktarımı, küçük toplantılar, konferanslar, ...düzenleniyor. Mesela Apple’ın kullanıcı deneyimi konusunda yaptıkları esin kaynağı oluyor ve daha çok ara yüz kullanım, web tasarım, kullanıcı profilleri, yazılım teknolojileri hakkında konular fazlaca ilgi çekiyor. Vadinin en iyi öğrencileri, girişimci-yatırımcı olurken, teknoloji şirketlerinde çalışırken kuşkusuz bu programlar esin perisi oluyor. Bizim en iyi öğrencilerimiz askeri yazılım donanım (Aselsan, Tübitak, TIA,...) şirketlerinde çalışmakta veya beyin göçü yaşayarak yurt dışını tercih etmektedir. Çok az bir grup yüksek maaşlarla AR-GE konusunu ikinci planda bırakan şirketler, bankalar veya mobil operatörlerinde çalışmaktadır.

1.1.5.4. Danışman Kültürü

Sektördeki tecrübeli kişiler bizde danışmanlık yapmazlar. Mentor kültürünü bile daha oturtamamışken Silikon Vadisi’nde %1 pay verilerek iki haftada bir, size bir saatini ayıracak deneyimli danışmanlar bulmak mümkündür. Bu danışmanlar dört gözle tekrar görüşmeyi bekleyeceğiniz türden kişiler oluyor. Facebook’ un kurucusu, Steve Jobs’ un

eski ortağı, Google şirketini milyonlarca dolara satan bir girişimciye danışmanınız olabiliyor. Yani önemli olan nokta bu kişilere ulaşmanın mümkün olması ve kültürünün yerleşmiş olmasıdır. Danışmanlar, mentorlar gibi çalışmazlar. Kendi çevrelerini de paylaşan, deneyimlerini aktaran hatta bazen yatırımcılarla da tanıştıran kişiler oluyor. Size yol gösteren, kararlarınıza yardımcı olan, çevresini tanıtan kişidir danışman. Mentorlar ise hangi yoldan gitmeniz gerektiğini söylemez, sadece yolları tanımlamanıza ve sorgulamanıza yardımcı olur.

1.1.5.5.Girişimci Sermayesi Kültürü

2011 yılında NVCA(National Venture Capital Association) belirttiği raporda VC'ler Kaliforniya'da 14.5 milyar-dolar yatırım yapmışlar. İkinci en yaklaşan ise 3 milyar-dolar ile Massachvsetts. 14.5 milyar-doların 11.7 milyar-doları Vadi'ye aitti. Aynı yılda tüm Amerika'da tohum döneminde yapılan yatırım miktarı 930 milyon-dolar. Erken dönem yatırım miktarı ise 8.3 milyar-dolar. Yine aynı yıl internet üzeri yapılan yatırım miktarı ise 15 milyar-dolar ve bunun 7 milyar doları vadiye ait.

2013yılında Mackolik ve Yemek Sepetine yapılan iki büyük yatırımı saysak bile Türkiye'de yatırım miktarı 70 milyon –doların altında bu Vadinin yatırım miktarının %1'ne denk geliyor [4,5,6]. Türkiye'de bir elin parmaklarını geçmeyecek VC yapılar vardır.

1.1.6.Silikon Vadisine Ait Önemli Bir Anketin Sonuçları


2013 yılında Silicon Valley Bank'ın Amerika'daki 600 girimci ile yapılan anketteki “Girişimcilere inovasyon ekonomisini geliştirmek için Başkan Obama’ dan ne istersiniz?” sorusuna verilen cevaplar şöyledir:

- %28'i basit büyümeyi teşvik edici vergi sistemi istemiş,
- %18'i kodlamayı daha çok kişiye öğretelim ve dünyanın her yerinde yetenekli insanları işe almak daha da kolaylaşsın demiş,
- %12'si regülasyonları kolaylaştırın demiş,
- %11'i yatırımcıları teşvik edin demiş,
- %10'nu bir kişinin bile başarılı olmasını kolaylaştırın ve ucuzlaştırın demiş,
- %9'u ise yer tahsisi istemiş,
- %2'si ise farklı fikirler öne sürmüş [4,6].

1.1.7. Silikon Vadisi Kopyalanabilir Mi?

Vadinin aynısını inşa etmek neredeyse mümkün değildir. Dünya çapında ünlü markalarının kurucularının neredeyse hepsinin ortak yanı hepsinin Stanford mezunu olması ve o kültürle yaşamış olmasıdır. Dünyanın çeşitli ülkelerinden beyin göçü alan bir yetenek fabrikasıdır. Çalışanlarının çoğu bekar veya çok yoğun çalışanlar olduğundan şirketlerin neredeyse hepsi çalışanlarına ücretsiz yemek, masaj, kuru temizleme, ...hizmetlerini, hatta bazıları hisse senedi vererek (stock option) elemanlarını memnun etme çabasıdadır. Bunca hizmet sunmalarına rağmen elemanlar sözleşmeli çalışmayı pek tercih etmedikleri gibi isteyen istediği firmaya geçiş yapabiliyor veya kendi hayalleri peşinde koşma cesaretini gösteriyorlar. Vadide hızlı hareket etmek, rakiplerinizden daima önde olmak zorundasınız, çünkü teknoloji çok hızlı geliyor ve ilerliyor. Bir anlık sekme değişimi kaçırmaya sebep olabiliyor.

Vadiyi vadi yapan tek etken inovasyona önem vermeleri değil, birçok faktörün bir arada bulunmasıdır. Şekil 1.7’de de görülen tasarımla, Vadi’yi bir yaşam alanına benzetirsek “ Bir yaşam alanını yaşam alanı yapan sadece tohumlar değil, onu yeşertecek toprağında olmasıdır” diyebiliriz.



Şekil 1.7. Silicon Valley Dream's

Vadideki büyük teknoloji varlığı, insan kaynağı, kaliteli üniversitelerle çevrili olması, danışmanları, kendine özgü kültürleri, ...vb. Silikon Vadisi'nin kopyalanamayacağı belirtilmiştir [4,7].

1.1.8. Yaşanılan Alanda Ekosistem Yaratma Tavsiyeleri

Amerika dışındaki ülkelerin kendi ülkelerinde Silikon Vadisi yaratma girişimleri ile aşağıdaki tavsiyeler oldukça dikkat çekicidir [4].

- Girişimci sayısını arttırmada teknoloji odaklı olanların oranını yükseltin,
- Finansal yerli kaynaklar oluşturun,
- Dikkat çekilecek büyük etkinlikler düzenleyin,
- En prestijli üniversitelere ulaşmayı kolaylaştırın,
- Marka taşıcılığı yapacak, yaşadığınız alanı yüceltecek kaliteli girişimcileri arttırın,
- Medya faktöründen yararlanın,
- Bulunduğunuz alanda hemşerilik kavramını da göz önüne alarak bu bölgede yaşamış, okumuş başarılı iş adamlarını ekosisteme dahil edin,
- Etkili olacak başarı hikayelerini çoğaltın ve yayın,
- Başarılı olan girişimlerin döngüsel olarak tekrar ekosisteme katkı sağlamasına yol açın,
- Başarılı girişimcilerin yeni girişimlere girmesini sağlayın,
- Özellikle mühendis beyinleri alanlarınıza çekecek teşviklerde bulunun
- Şehirlerinizde teknoloji şirketlerini cezp edecek yatırımlara yol açın.

1.2. ARMA Modelleri

Zaman serileri, zamana bağlı değişkenlerden elde edilen verilerin analizinde kullanılan istatistiksel bir tahmin tekniğidir. Ekonomide, tarımda, istatistikte, tıpta, biyolojide, ...vb. alanlarındaki verilerin analizinde sıklıkla başvuru alan kestirim yöntemidir. Yıllık işsizlik oranı, aylık yağış miktarı, yıllık ithalat-ihracat miktarı, borsa tahminleri, devletin sonraki yıla yönelik bütçe planlanması, ...zaman serilerine birer örnek olarak verilebilir. Her tahmin tekniğinde olduğu gibi zaman serilerinde de amaca doğru ulaşmada ve daha gerçekçi sonuçlar almada üzerinde çalışılacak modelin iyiliği çok sayıda gözlemle (veriyle) yansıtılabilir. Veriler ne kadar fazlaysa gerçeğe yakın modellerde bir o kadar karakterize edilmiş olur. Zaman serilerinde de bazı varsayımların sağlanması şartı gereklidir. Üzerinde çalışılacak modelin iyi karakterize edilmesi ve model veri uygunluğu, sonrasında da sağlıklı kestirimlerde bulunulması ivedilikle göz önünde bulundurulmalıdır [8]. Genel bir zaman serisi modeli (1.1)' deki eşitlikteki gibi gösterilir.

$$\underbrace{Y_t = f}_{\text{Fonksiyonel Form}} \left(\underbrace{Y_t, Y_{t-1}, \dots}_{\text{Gecikme Yapısı}}, \underbrace{\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}, \dots}_{\text{Kalıntı Terimleri Yapısı}} \right) \quad (1.1)$$

Bu bölümde uygulama kısmında yararlandığımız değişkenlerin zamana bağlı gözlemleri olduğundan, zaman serilerinde sıklıkla kullanılan ARMA modellerinden bahsedilecektir. ARMA modelleri; AR, MA, ARMA ve ARIMA modelleri olmak üzere genel olarak dört bölüm olarak sınıflandırılabilir.

1.2.1.AR(p) Modelleri

Bir serinin geçmiş dönemdeki değerleri ile şimdiki değerleri arasındaki doğru belirlenmiş lineer bağıntısı, yapının kalıntılarının rassal değişkenliğiyle sağlanır. Bağımlı değişkenin evvelini yansıtan bilgi yalnızca kendi değerlerine göre modellenir. Oluşan bu sürece AR(p) modeli otoregresif (Autoregressive) süreçli modeller denir. Bir basit örnekle bunu açıklarsak; her saat başı 5 bardak limonata satan bir satıcı düşünelim. Satıcı eğer zarar etmek istemiyorsa her saat başı tükenen limonata stoku yerine en az saat başı satılan adet miktarı kadar yenisini takviye etmelidir. Böylece yapılan bu takviye satışlarda zarar etmesini önler. Saatteki meyve suyu seviyesi, daha az veya daha fazla limonata satma durumunu etkiler [9]. p'inci mertebeli otoregresif modelde cari değişkenli değerli zaman serisinde; p dönem geçmiş değerlerinin ağırlıklı toplamına rassal hata teriminin eklenmesiyle AR(p) modellerinin gösterimi (1.2)' deki gibi elde edilir [10,11,12,13].

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + \varepsilon_t \quad (1.2)$$

Y_t : Bağımlı değişken gözlem değerlerini

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$: Geçmiş gözlem değerlerini

$\Phi_1, \Phi_2, \dots, \Phi_p$: Geçmiş gözlem değerleri için katsayıları (parametreleri)

δ : Sabit bir değeri (kesme terimi), stokastik süreçli Y_t 'nin ortalamasını

ε_t : Hata terimini ifade etmektedir.

Daha kısa bir formda gösterimi (1.3) nolu eşitlikteki gibi gösterilebilir:

$$Y_t = \delta + \sum_{i=1}^p \Phi_i Y_{t-i} + \varepsilon_t \quad (1.3)$$

1.2.1.1.AR(1) ve AR(2)Süreci

AR(1) modeli veya birinci derece otoregresif model olarak adlandırılır. Birinci derece otoregresif istatistiksel modelinde Φ , -1 ile +1 aralığında değerler aldığı varsayılan bilinmeyen otokorelasyon parametresini ve ε_t ise $ND(0, \sigma^2)$ bağımsız hata terimidir [14,15]. AR(1) modeli aşağıdaki (1.4) nolu eşitlikte gösterilmiştir.

$$Y_t = \delta + \Phi_1 Y_{t-1} + \varepsilon_t \quad (1.4)$$

Aynı şekilde AR(2) modeli (yada ikinci derece otoregresif model) (1.5) nolu denklemdeki gibidir.

$$Y_t = \delta + \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \varepsilon_t \quad (1.5)$$

Evvel ve gelecekteki rassal değişkenler bağımlı değişken gözlemindeki $(Y_1, Y_2, \dots, Y_t)$ aynı olasılık yoğunluk fonksiyonunu izler. Bir değişkenin aynı ortalama ve varyansa sahip olma durumu değişkenin tüm dönemlerde aynı olasılık dağılımına sahip olduğu varsayımıyla sağlanır. Zaman serisi analizinde bağımlı değişken Y_t nin ortalama, varyans ve kovaryansının hesaplanmasıyla başlanır. Zaman serilerinde durağanlık (stationary); zamana bağlı değişmeyen ortalama ile varyansın ve iki dönem arasındaki kovaryansın bakılan döneme değil de dönemler arasındaki uzaklığa bağlı olduğudur.

$E(Y_t) = \mu$, $Var(Y_t) = \gamma_0$, ve $Cov(Y_t, Y_{t+k}) = \gamma_k$ ile gösterilsin. Eğer başlangıç noktasını t 'den $t+k$ ' ya kaydırırsak durağanlık şartı gereği Y_t, Y_{t+k} serilerinin ortalama, varyans ve kovaryansı hep aynı olmalıdır. $k=0$ için $Cov(Y_t, Y_{t+0}) = Var(Y_t) = \sigma^2$ özel bir durumdur.

AR(1) sürecinin ortalaması (1.6) nolu eşitlikte gösterilir.

$$\begin{aligned} E(Y_t) &= E(\delta + \Phi_1 Y_{t-1} + \varepsilon_t) \\ &= E(\delta + \Phi_1 Y_{t-1}) + E(\varepsilon_t) \\ &= E(\delta + \Phi_1 Y_{t-1}) \\ \mu &= \delta + \Phi_1 \mu \\ \mu &= \frac{\delta}{1-\Phi_1} \end{aligned} \quad (1.6)$$

Aynı yöntemle AR(2) sürecinin ortalaması da (1.7) nolu eşitlikteki gibi hesaplanır.

$$E(Y_t) = \mu = \frac{\delta}{1-\Phi_1-\Phi_2} \quad (1.7)$$

Eğer süreç durağansa, $|\Phi_1| < 1$ olur.

Eğer serinin varyansı sabit değil ve zamanla artıyorsa, $\Phi_1 = 1$ olur.

Son olarak; serinin ortalamadan sapmalar cinsinden tanımı olan $(Y_t - \mu)$ 'a ulaşmak için, $\delta = 0$ ise Y_t 'nin ortalaması $\mu = 0$ olmalıdır.

AR(2) sürecinde ise durağanlığı için; $\Phi_1 + \Phi_2 < 1$, $\Phi_2 - \Phi_1 < 1$, $|\Phi_2| < 1$ varsayımlarını sağlamalıdır.

AR(1) sürecinin varyansı;

$\delta = 0$ olarak alınsın. Bu durumda AR(1) sürecinin varyansı (1.8) nolu eşitlikteki gibi gösterilir.

$$Y_t = \Phi_1 Y_{t-1} + \varepsilon_t$$

$$\begin{aligned} Var(Y_t) &= \sigma_Y^2 = Var(\Phi_1 Y_{t-1} + \varepsilon_t) \\ &= \Phi_1^2 Var(Y_{t-1}) + Var(\varepsilon_t) \\ &= \Phi_1^2 \gamma_0 + \sigma_\varepsilon^2 = \gamma_0 \end{aligned}$$

$$\sigma_Y^2 = \frac{\sigma_\varepsilon^2}{1-\Phi_1^2} = \gamma_0 \quad (1.8)$$

AR(1) sürecinin kovaryansı;

Y_t ve Y_{t-k} arasındaki kovaryans zamana bağlı olmayan, bu iki rassal değişken arasındaki k sayıda gecikmeye bağlıdır. Bu ise evvele (geçmişe) dayanarak geleceğe yönelik kestirimlerde önemli husustur.

$$Cov(Y_t, Y_{t-1}) = E \left\{ \left[Y_t - \underbrace{E(Y_t)}_{E(Y_t)=\mu \rightarrow E(\mu)=0} \right] [Y_{t-1} - E(Y_{t-1})] \right\}$$

$$\begin{aligned} E(Y_t Y_{t-1}) &= E[(\Phi Y_{t-1} + \varepsilon_t) Y_{t-1}] \\ &= E[\Phi Y_{t-1}^2 + \varepsilon_t Y_{t-1}] \\ &= \Phi E[Y_{t-1}^2] + E[\varepsilon_t Y_{t-1}] = \Phi_1 \sigma_Y^2 \end{aligned} \quad (1.9)$$

(1.9) nolu eşitlikte gösterilen bu kovaryans hesabı, bütün rassal değişkenlerde aynı sonuçludur. Diğer kovaryans denklemleri (1.10) ve (1.11) nolu eşitliklerde gösterildiği gibidir.

$$Cov(Y_{t-1}, Y_{t-2}) = E(Y_{t-1}Y_{t-2}) = \Phi_1\sigma_Y^2 \quad (1.10)$$

$$Cov(Y_{t-2}, Y_{t-3}) = E(Y_{t-2}Y_{t-3}) = \Phi_1\sigma_Y^2 \quad (1.11)$$

Buraya kadar k=1 için yapılmış denklemler gösterildi. Şimdi de k=2 için hesaplanan denklemler (1.12), (1.13), (1.14) ve (1.15) nolu eşitliklerde verilmiştir.

$$\begin{aligned} Cov(Y_t, Y_{t-2}) &= E\left\{[Y_t - \underbrace{E(Y_t)}_0][Y_{t-2} - \underbrace{E(Y_{t-2})}_0]\right\} = E(Y_t Y_{t-2}) \\ &= E[(\Phi Y_{t-1} + \varepsilon_t)Y_{t-2}] = E[\Phi Y_{t-1}Y_{t-2} + \varepsilon_t Y_{t-2}] \\ &= \Phi E(Y_{t-1}Y_{t-2}) + E(\varepsilon_t Y_{t-2}) \\ &= \Phi E(Y_{t-1}Y_{t-2}) + \underbrace{E(\varepsilon_t Y_{t-2})}_0 \\ &= \Phi_1(\Phi_1\sigma_Y^2) = \Phi_1^2\sigma_Y^2 \end{aligned} \quad (1.12)$$

Daha genel formu (1.13) 'deki gibidir.

$$\gamma_k = Cov(Y_t, Y_{t-k}) = \Phi_1^k\sigma_Y^2 \quad (1.13)$$

Y_t 'nin varyansı (1.14) ve (1.15) nolu denklemlerde verilmiştir.

$$\gamma_0 = Cov(Y_t, Y_t) = \sigma_Y^2 = \frac{\sigma_\varepsilon^2}{(1-\Phi_1^2)} \quad (1.14)$$

$$\gamma_k = \Phi_1\gamma_{k-1} = \Phi_1^k\sigma_Y^2 = \Phi_1^k\gamma_0 \quad (1.15)$$

Y_t ve Y_{t-k} arasındaki kovaryans zamana bağlı değildir. Yukarıdaki varyans ve kovaryans hesabı AR(2) için de benzer yollarla hesaplanabilir.

1.2.1.2.AR(p) Modellerinde Gecikme Operatörünün Kullanımı

Gecikme operatörü L ile gösterilirse AR(p) modeli, Y_t değişkeninin i. dönem geciktirmesi (1.16) nolu eşitlikteki gibidir.

$$L^i Y_t = Y_{t-i} \quad , i=1,2, \dots ,p \quad (1.16)$$

AR(1) süreci için gösterimi (yani $i=1$ için) (1.17) nolu denklemde verilmiştir.

$$Y_t = \delta + \Phi_1 Y_{t-1} + \varepsilon_t$$

İfade de (1.16)' teki yerine denklemde yazılırsa;

$$Y_t = \delta + \Phi_1 L Y_t + \varepsilon_t \text{ olur.}$$

$$Y_t - \Phi_1 L Y_t = \delta + \varepsilon_t$$

$$(1 - \Phi_1 L) Y_t = \delta + \varepsilon_t$$

$$Y_t = \frac{\delta + \varepsilon_t}{1 - \Phi_1 L} = \frac{\delta}{1 - \Phi_1 L} + \frac{\varepsilon_t}{1 - \Phi_1 L} \quad (1.17)$$

Genel olarak AR(p) süreci için uygulanması (1.18), (1.19), (1.20) ve (1.21) nolu eşitliklerde sırasıyla verilmiştir.

$$\varepsilon_t = (1 - \sum_{i=1}^p \Phi_i L^i) Y_t = \Phi(L) Y_t \quad (1.18)$$

$$\Phi(L) = 1 - \sum_{i=1}^p \Phi_i L^i \quad (1.19)$$

Daha açık formu ise:

$$\Phi(L) = 1 - \Phi_1 L - \Phi_2 L^2 - \dots - \Phi_p L^p \quad (1.20)$$

$$Y_t = \frac{\delta}{\Phi(L)} + \frac{\varepsilon_t}{\Phi(L)} \quad (1.21)$$

Modelin durağanlık şartını sağlaması için parametrelerin değerleri üzerinde bazı varsayımlar sağlanmalıdır. Örneğin; AR(1) modelinde $|\Phi_1| \geq 1$ olduğunda durağanlık hali bozulur.

1.2.2.MA(q) Modelleri

MA(q) modellerine genel olarak hareketli ortalama (Moving Averages) modelleri denir. q siparişinin hareketli ortalama modelini belirtir. t dönem değerli bir zaman serisinin ağırlıklı ortalamalı geçmiş ve cari dönemdeki değerlerinin ifade ettiği rastgele değişken olan kalıntı payının da katıldığı bir süreçtir [16]. Bir örnekle açıklarsak; yolda kalan arabaları çekmede uzmanlaşmış bir şirketi ele alalım. Yolda kalan her aracın çekilmesi birbirinden bağımsız olayları teşkil eder. Tecrübeleriniz aracın bozulduğu yere ve araca

sahip olan şirketin bir tamir şirketinin tamirhanesinin olduğu yere bağlı olarak, bir aracın çekilmesi ve onun tamirhaneye götürülmesi için üç günün gerekli olduğunu göstermiştir. Eğer siz yeterli çekiciye sahip olmazsanız aracın sahipleri bu işi başkasına verecektir. Bir gündeki tamir edilmek için çekilmesi gerekli araç sayısı size gerekli olan çekici için bilgi vermektedir. Üç gün ötesinde, bu günkü tercihler size gelecekte olanlar hakkında bir şey söylemez. Bu süreç bir hareketli ortalama sürecidir [9,13,17]. MA(q) modellerinin genel formu (1.22) nolu eşitlikte verilmiştir.

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1.22)$$

Burada;

$\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$: Hata terimlerini

$\theta_1, \theta_2, \dots, \theta_q$: Hata terimleriyle ilgili katsayıları (parametreleri)

μ : Sürecin ortalaması olan bir sabiti gösterir.

Daha kısa formu (1.23) nolu eşitlikteki gibidir.

$$Y_t = \mu + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1.23)$$

1.2.2.1.MA(1) ve MA(2) Süreci

MA(1) modeli, birinci dereceden hareketli ortalama modeli olarak da adlandırılır. MA(1) modeli (1.24) nolu eşitlikte gösterilmiştir.

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (1.24)$$

MA(2) modelini de (1.25) nolu eşitlikte verelim.

$$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \quad (1.25)$$

1.2.2.2.MA(q) Modellerinde Gecikme Operatörünün Kullanımı

MA(q) sürecinin derecesi, hesaplanan otokorelasyon katsayısının kesildiği gecikme dönemi ile belirlenebilir. Otokorelasyonların sıfır olarak alınması q' dan daha büyük gecikmelerde meydana gelir. Herhangi bir model için hesaplanan otokorelasyonlar, daha

ileri gecikmelerde sıfıra doğru azalan, fakat kısmi otokoelasyonlarının hesaplanmasında çok kısa süreli gecikmelerde kesilme söz konusu oluyorsa otoregresif sürecin daha baskın olduğu söylenebilir.

Gecikme operatörü L ile gösterilirse; MA(1) modelinin gecikmeli hali (yani $i=1$ için) (1.26) nolu eşitlikteki gibidir.

$$L^i \varepsilon_t = \varepsilon_{t-i} \quad i=1,2,\dots,q \text{ ise;} \quad (1.26)$$

$Y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1}$ ifadesinde (1.26) nolu eşitliği yerine yazarsak (1.27) nolu form oluşur.

$$\begin{aligned} &= \mu + \varepsilon_t - \theta_1 L \varepsilon_t \\ Y_t - \mu &= (1 - \theta_1 L) \varepsilon_t \\ \varepsilon_t &= \frac{Y_t - \mu}{(1 - \theta_1 L)} = \frac{Y_t}{(1 - \theta_1 L)} - \frac{\mu}{(1 - \theta_1 L)} \end{aligned} \quad (1.27)$$

Genel olarak MA(q) sürecinin gecikmeli hali (1.28) ve (1.29) nolu denklemlerle gösterilir.

$$Y_t = (1 + \sum_{i=1}^q \theta_i L^i) \varepsilon_t = \theta(L) \varepsilon_t \quad (1.28)$$

$$\theta(L) = 1 + \sum_{i=1}^q \theta_i L^i \quad (1.29)$$

Daha açık formu ise (1.30) ve (1.31) nolu denklemlerde verilmektedir.

$$\theta(L) = 1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q \quad (1.30)$$

$$\varepsilon_t = \frac{Y_t}{\theta(L)} - \frac{\mu}{\theta(L)} \quad (1.31)$$

1.2.3.ARMA (p,q) Modelleri

Peter Whitte (1951) tezinde zaman serileri analizi hipotez testinde ARMA modellerini tanımlamış ve daha sonra George EP Box ve Gwilym Jenkins (1970) tarafından popüleritesini arttırmıştır [18,19]. Bu yüzden ARMA modelleri Box-Jenkins yöntemleri kullanılarak kestirimlerde uygulanabilir. ARMA modelleri, en genel durağan, stokastik süreç modelleri olup bir dizi veri verildiğinde bu serinin gelecek değerlerini anlamak ve tahmin etmede kullanılan bir süreçtir. Model otoregresif (AR) ve hareketli ortalama (MA) olmak üzere iki bölümden oluşmaktadır. AR kısmı değişkenin kendi

gecikmeli (yani geçmiş) değerlerinde gerilemeyi içerirken MA kısmı hata teriminin eş zamanlı olarak ve geçmişteki çeşitli zamanlarda meydana gelen hata terimlerinin doğrusal bir birleşimi olarak modellenmesini içerir. Rassal süreçli birçok durağan zaman serilerinde sadece otoregresif ya da sadece hareketli ortalama yapılarıyla modellenmesi süreci eksik kılar. Çoğu zaman bu iki yapının birlikte olmasına ihtiyaç vardır. Model genelde ARMA(p,q), p+q parametrelili olarak gösterilir. p:otoregresif bölümün sırasını, q: hareketli ortalama parçanın sırasınıdır. Genel gösterimi (1.32) nolu eşitlikte verilmiştir.

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1.32)$$

Daha basit formu (1.33) nolu eşitlikteki gibidir.

$$Y_t = \delta + \varepsilon_t + \sum_{i=1}^p \Phi_i Y_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (1.33)$$

Burada ;

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$: Geçmiş gözlem değerlerini

$\Phi_1, \Phi_2, \dots, \Phi_p$: Geçmiş gözlem değerleri için katsayıları (parametreleri)

δ : Sabit değeri

$\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$: Hata terimlerini

$\theta_1, \theta_2, \dots, \theta_q$: Hata terimleriyle ilgili katsayıları göstermektedir.

Hata varsayımı zayıflayınca modelin özellikleri değişecektir. Özellikle iid varsayımda yapılan bir değişiklik oldukça köklü bir fark yaratacaktır.

1.2.3.1. ARMA(p,q) Modellerinde Gecikme Operatörü

AR(p) ve MA(q) modellerinde verilen formülasyonlar bu bölümde de aynı tanımlamalarla geçerliliğini korur. Yine geciktirme derecesi L olmak üzere (1.34) nolu eşitlikte verilmiştir.

Eğer $\Phi_0 = \theta_0 = 1$ ise

$$\sum_{i=1}^p \Phi_i L^i Y_t = \sum_{i=1}^q \theta_i L^i \varepsilon_t \quad (1.34)$$

1.2.4.ARIMA(p,d,q) Modelleri

Zaman serileri kesikli, doğrusal ve stokastik süreci içeriyorsa ARIMA modeli olarak adlandırılır [8,20,21]. Sürecin ortalaması, varyansı, kovaryansı gibi değişkenlerin zamana bağlı olarak değişmediği durumlarda zaman serisi durağan olarak tanımlanır. Böyle durumlarda ARMA(p,q) veya ARMA (p,q)'nın özel halleri olan AR(p) ve MA(q) modellerinden uygun olanı uygulanabilir. Ancak gerçek hayatta zaman serilerinde durağanlık halleri pek nadir görülür. Zamana bağlı olarak varyans, ortalama veya her ikisinde de aynı anda değişimler meydana gelmektedir. Bu duruma durağan olmayan (non-stationary) durum denir. ARMA modellerinde tahmin aşamasında bunların kullanılabilmesi için bu durumlar uygun dönüşüm yöntemleriyle durağan formlara dönüştürülmelidir. Zaman serilerinde durağanlaştırma için fark alma işlemi gereklidir. Böyle serilere uygulanan modellere entegre modeller denir. Otoregresif entegre hareketli ortalama modellerine ARIMA modelleri denir. ARIMA modellerini bir örnekle açıklarsak; Ulusal park yakınında bir hotele sahip olduğunuzu düşünün. Hotel defteri bazı rezervasyonları içermektedir. Müşterilerin bazıları otelinizde bir günden daha fazla zaman harcamakta ve ayrıca müşterilerden bazıları da ulusal parkta bir haftalık tatil geçirirken aynı zamanda evlerine dönmeden önce gece kalmak için sizin otelinize gelmektedirler. Belli bir günde meydana gelecek şok otelde sürekli kalan müşterileri artan-birden fazla dönem- bir şekilde etkileyecektir. Ancak bu şokun, ulusal parkta bir tatil geçirdikten sonra gece için kalmaya gelenler üstünde bir hafta sonra tek bir etkisi olacaktır [9].

Eğer zaman serisinin doğrusal bir trendi var ise birinci fark serisi durağan olur. Eğer zaman serisinin eğrisel bir trendi var ise farkların tekrar farkı alınarak ikinci farklar serisi durağanlaşır. Bu durumdaki modellerde ARIMA(p,d,q) modeller olarak adlandırılır. Buradaki “d”serinin durağanlaştırma (fark alma=integrated) parametresidir [17]. Box-Jenkins yöntemi olarak da anılan ARIMA modelleri doğrusal zaman serileri analizinde sıklıkla kullanılır. Bu modellerde bağımlı değişkenin kendi gecikmiş değerleri ile rassal hata terimleri tarafından açıklandığı varsayılır. ARIMA model belirleme ve model uygunluğunu test etmede sonrasında tahminlerde kullanmada üç temel aşama vardır [19].

1.Aşama: Model Belirleme Aşaması

Ortalama ve varyansın zaman serilerinde durağan olması şartıyla ARIMA modeller uygulanabilir. Gerçek yaşam genellikle doğrusal olmayan birçok özellik gösterir ve bu

özellikler doğrusal istatistiksel modellerle tam olarak açıklanamaz. Durağan olmayan yani bir kestirimden diğer kestirime büyük değişimler gösteren serilere var olan olasılık kuralları ve modelin doğru belirlenmesi yetersiz kalmaktadır. Serinin durağanlaştırması için fark alma, logaritmasını alma gibi dönüşüm yöntemleri uygulanarak durağan hale dönüştürülür. Seri durağanlaştırıldığında kalıntı değerleri sıfıra yaklaşır ve belirli karakteristik bir yapı ortaya koymaz. Bu durum hata teriminin saf(beyaz gürültülü (white noise)) olduğu anlamındadır [22].

İlk aşamada serinin durağanlığını test etmede kullanılmaları için serinin otokorelasyon ve kısmi otokorelasyon fonksiyonları olan korelogram grafikleri incelenmelidir. Korelogram grafikleri serinin belirlenen güven aralıkları içinde kaldığını gösteriyorsa serinin durağan bir yapıya sahip olduğu söylenebilir. Eğer korelogram grafikleri serinin durağanlığı hakkında yeterli ve gerekli bilgi vermiyorsa Q- testleri, Genelleştirilmiş DickeyFuller Testi(ADF), ...vb. istatistiksel testleri de uygulanabilir. Durağan zaman serileri oluşturulduktan sonra geçici modeller atanır. AR, MA ve ARMA modeller olmak üzere üç temel modelden hangisi uygunsa o model kullanılır. AR ve MA modellerinde düzenli fark alma işlemi uygulanırsa ARIMA modeller oluşturulmuş olur. AR ve MA arasındaki “I” harfi fark alma işlemi olarak görevlidir. I(1) olan bir serinin birinci farkının durağan I(0) serisine eşit olduğu benzer şekilde I(2) olan bir zaman serisi de iki kez farkı alındığında I(0) olur. Genel olarak I(d) olan bir zaman serisinin d kez farkı alındığında durağanlaştığını ve bu serinin daha sonra ARMA(p,q) süreci ile modellenebilir. Yani ARIMA modelleri kapsayıcı özellikte bir süreçtir. Örneğin, bir ARMA(1,1) modeli ARIMA(1,0,1) ,sekinde ve bir MA(2) modeli de ARIMA (0,0,2) şeklinde yazılabilir. Bu gösteriyor ki; p,d ve q değerler kendi aralarında ilintilidir.

Serilerin otokorelasyonlarını ve kısmi otokorelasyonlarını gösteren korelogram grafiklerinin incelenmesiyle geçici alternatif modeller kurulur. Eğer otokorelasyon üssel olarak sıfıra doğru azalıp kayboluyorsa AR modeli, kısmi otokorelasyon fonksiyonu üssel olarak sıfıra doğru düşüp kayboluyorsa MA modeli seçilmelidir. AR modelinin derecesi, kısmi otokorelasyon fonksiyonunun anlamlı şekilde sıfırdan farklı olduğu nokta iken, MA modelinin derecesi ise,otokorelasyon fonksiyonunun anlamlı şekilde sıfırdan farklı olan noktada belirlenir. q’ dan daha büyük gecikmelerde otokorelasyonlar sıfır olarak alınır. ARMA modelin derecesi ise hem otokorelasyonun hem de kısmi otokorelasyonun sıfıra doğru yaklaşp kaybolduğu noktada belirlenir [23,24]

2.Aşama: Model Katsayılarının (Parametrelerinin) Belirlenmesi

Modelde gösterilen parametreler EKK, en çok olabilirlik gibi yöntemler kullanılarak istatistiksel paket programlarında ifade edilebilir. Ayrıca parametrelerin anlamlılık değerleri olan R^2 , F istatistiği de program aracılığıyla saptanır.

3.Aşama: Modelin Uygunluğunun Testi

Belirlenen modellerin kestirimlerde kullanılmaları için bazı şartları sağlaması gerekir. Öncelikle modelin kalıntılarının beyaz gürültülü halinin testi yapılmalıdır. Hatalar sıfır ortalamalı, sabit varyanslı aynı dağılıma haiz, hatalar arası otokorelasyonun bağımsızlık şartı gibi normal dağılım gösteriyorsa buna Gaussçu beyaz gürültü (Gaussian white noise- $\varepsilon_t \sim ND(0, \sigma^2)$) denir [25]. Kalıntı analizleri için otokorelasyon ve kısmi otokorelasyon korelogramlarından, Box-Ljung Q-testlerinden faydalanılır. Eğer testler sonucu bulunan katsayılar istatistiksel olarak anlamsız ise otokorelasyon ve kısmi otokorelasyonlarının korelogramları belirli, bir güven sınırları aralığına düşüyorsa kalıntıların rassal olduğu ve beyaz gürültülü özelliğine sahip olduğu anlaşılır [24,26].

Birden fazla uygun model çıkması durumunda en optimal modelin en az sapmayla gerçek modele uygunluğu cimrilik prensibine dayanan ve üçüncü bölümde de değinilecek olan bilgi kriterleri yardımıyla ortaya konulmaya çalışılır [8,19,27]. Bu aşamalardan sonra da model kestirimlerde kullanılması için uygun olur. ARIMA(p,d,q) gösterimi (1.35) nolu eşitlikteki gibidir.

$$Y_t = (1 + \Phi_1)Y_{t-1} + (\Phi_2 - \Phi_1)Y_{t-2} + (\Phi_3 - \Phi_2)Y_{t-3} + \dots + (\Phi_p - \Phi_{p-1})Y_{t-p} - \Phi_p Y_{t-p-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (1.35)$$

Herhangi bir bağımlı değişken Y_t zaman serisi için;

$E(Y_t) = \mu$, $V(Y_t) = \sigma^2$ ve $Cov(Y_t, Y_{t+k}) = \gamma_k$ kovaryansı sadece k 'ye bağlı bir durağandır [28]. Durağan bir zaman serisinde $[-1,+1]$ aralığında değerler alabilen otokorelasyon fonksiyonun (Autocorrelation Function-ACF) gösterimi (1.36) nolu eşitlikte verilmiştir.

$$\rho_k = \frac{\text{gecikme } k \text{ iken kovaryans}}{\text{gecikme sıfır iken kovaryans}} = \frac{\text{cov}(Y_t, Y_{t-k})}{\sqrt{\text{var}(Y_t)}\sqrt{\text{var}(Y_{t-k})}} = \frac{\gamma_k}{\sigma^2} \quad (1.36)$$

Bir durağan zaman serisinde varyans zamana bağlı olmadığından, t dönemdeki varyans (t-k) dönemdeki varyansla eşit değerli olur. $\sqrt{var(Y_t)} = \sqrt{var(Y_{t-k})}$ olduğundan yeni form (1.37) nolu eşitlikteki gibidir [29].

$$\rho_k = \frac{cov(Y_t, Y_{t-k})}{var(Y_t)} = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (1.37)$$

ρ_k 'nın k'ye göre çizimine korelogram (correlogram) denir. Korelogram grafiklerinde genellikle; x eksenine gecikmeler, y eksenine ise otokorelasyon/ kısmi otokorelasyon değerleri yazılır. x eksenini pozitif tamsayı değerleri alırken, y eksenini [-1,+1] arasında değerler alır.

Kısmi otokorelasyon katsayısının tanımında kısmi korelasyon katsayısı terimi önemlidir. Diğer değişkenler sabit tutulduğunda iki veya daha çok değişkenler arasındaki ilişkiyi gösteren bir katsayıdır. Bu tanımdan hareketle kısmi otokorelasyon katsayısı; diğer gecikmeli ($t=1,2,\dots,k-1$) değişkenlerin etkisi ihmal edildiğinde Y_t ve Y_{t-k} zaman serileri arasındaki ilişkiyi ölçen bir katsayıdır. Kısmi otokorelasyon fonksiyonu (Partial Autocorrelation Function- PACF) gösterimi sırasıyla (1.38), (1.39) ve (1.40) nolu eşitliklerdeki gibidir.

$$\rho_1 \quad k=1 \quad (1.38)$$

$$\rho_{kk} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \quad k=2 \quad (1.39)$$

$$\rho_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \rho_{(k-1)j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \rho_{(k-1)j} \rho_j} \quad k=3,4,5,\dots \quad (1.40)$$

ρ_k : k gecikmeli otokorelasyon katsayısı

ρ_{kj} : j. gecikmeli serinin etkisi yok edildikten sonra k gecikmeli otokorelasyon katsayısı ise (1.41) nolu eşitlikteki gibidir.

$$\rho_{kj} = \rho_{(k-1)j} - \rho_{kk} \rho_{(k-1)(k-j)} \quad j=1,2,\dots,k-1 \quad (1.41)$$

Yani Y_t ile Y_{t-1} arasındaki anlamlı bir otokorelasyon olduğu, ayrıca Y_{t-1} ile Y_{t-2} arasında da anlamlı bir otokorelasyon olduğu varsayılırsa; Y_{t-1} hem Y_t hem de Y_{t-2} ile ilişkili

olur. Y_t ile Y_{t-2} arasındaki korelasyonu ölçmede aradaki değerin etkisini bulma işlemi kısmi otokorelasyon olarak adlandırılır [30,31]. Tüm gecikmelere ait kısmi otokorelasyon katsayısı değerleri kısmi otokorelasyon fonksiyonunu oluşturur.



2. MATERYAL ve METOT

2.1. Materyal

Araştırmanın materyali; investing.com internet adresinde yer alan ve yayımlanmış olan “Silikon Vadisindeki 10 büyük şirketin son bir aylık borsa hisse senedinin açılış-kapanış verilerine ait geçmiş göstergeler” adlı kaynaktan bulunan 21.05.2018-20.06.2018 tarihleri arası borsa hisse senedi açılış-kapanış verisel bilgileri kapsamaktadır.

2.2. Model Seçimi ve Bilgi Kriterleri

Birçok konuda Regresyon Analizi (RA) uygulanırken bağımlı değişken veya değişkenleri etkileyecek bağımsız değişkenlerin saptanması çoğu zaman güç olmaktadır. İstatistiksel çıkarımdaki problemlerin büyük bir çoğunluğu istatistiksel modelleme ile ilgili sorunlardandır denebilir [32]. Model Seçimi (Model Selection veya Variable Selection), açıklayıcı değişkenlerden hangisi ya da hangilerinin açıklanan değişken üzerinde etkili olduğunu ortaya koyarak mevcut aday modeller içerisinde en uygun modelin en basit modelle seçilmesi sürecidir. En uygun modelin en basit modelle seçilmesinin analiz sırasında hem hesaplama rahatlığı hem de veri derlenmesindeki maliyet tablosunda hafifletici etkiye sahiptir. Problemin boyutunun indirgenmesiyle, model parametrelerinin daha doğruya yakın bir şekilde tahmin edilmesi ve daha açık tespitlerde bulunulması da sağlanır [33].

İncelenen sistem hakkında gerekli ve yeterli bir ön bilgi bulunmadığında, model kurmada gerekli olan açıklayıcı değişkenlerin sayısının ölçülmesi çoğu kez zordur. Modelleyici için hangi değişkenlerin etkili olduğunu belirleyememesi sonucunda ortaya çok sayıda karmaşık ve gereksiz çok değişkenli bir model çıkması olasıdır. Tüm değişkenleri barındıran bir model kurmak, çeşitli veri analiz sorunlarına neden olur. Özellikle bağımsız değişken sayısının çok olduğu durumlarda aday modellerin sayısı yüzleri, binleri, ...bulabilmektedir (n: bağımsız değişken sayısı olmak üzere $n=10$ için $2^n = 2^{10} = 1048576$ adet değişken kombinasyonlarının (alt kümelerinin) bulunması gibi). Bu durum hem çok maliyetli hem de değişken sayısının çok olmasıyla doğru analizlerin yapılamaması sonuçlarını doğurabilir. Bu nedenle mümkün tüm aday modellerin hepsi denenmeden bunlar arasından seçim yapılmasını sağlayacak değişken seçim kriterlerine

gereksinim vardır [34]. Değişken seçimi için çok sayıda yöntem önerilmiştir. 1970'lerin başlarında klasik model seçim metotları ve bilgi kriterlerine dayanan seçim metotlarına dair birçok çalışma bulunmaktadır. Klasik model seçim metotları genellikle araştırmacının keyfi belirlediği belli bir güven düzeyinde hipotez testlerine dayanmaktadır. Çoğu bilim adamları güven düzeyindeki eksikliklerin (temelsizliklerin) olduğunu vurgulamıştır [35]. Bazı bilim adamları ise, hipotez testlerinin bilimsel bir doğruluğa tam anlamıyla sahip olmadığını ve genellikle geçerliliğinin yetersiz olduğunu belirtmişlerdir [36].


Klasik model seçiminde geleneksel yöntemler; İleriye Doğru Seçim (Forward Selection), Geriye Doğru Eleme (Backward Elimination) ve Adımsal Teknikler (Stepwise Selection) dir. Bu yöntemlerle ilgili birçok eleştiri vardır: Adımsal tekniklerle ilgili en önemli eleştiri, modele alınacak veya modelden atılacak değişkenlerin sırasının belirlenmesindeki kriterin bilimsel dayanağının olmaması ve böylece anlamlı değişkenlerin seçilmesindeki rastlansallık [37,38]. Adımsal tekniklerin beklide en zayıf yönü yerel aramaya takılı bir algoritmaya dayanarak tüm arama uzayının oldukça sınırlı bir bölgesinin işleme dahil edilmesidir [39].

Bu eksiklikler en optimal veya ona yakın model kombinasyonlarının seçiminde tüm olası alt kümeler üzerinden seçim yapmayı önerse de bazı durumlarda (bağımsız değişken sayısı çok olduğunda) hesaplama açısından uygun olmamakla birlikte zaman ve maliyet açısından da külfetli olabilir [34]. Klasik model seçimlerine alternatif olan Bilgi Kriterleri'ne dayalı model seçimi (değişken seçimi) ilk olarak Akaike (1973) tarafından ortaya atılan Akaike Bilgi Kriterleri (Akaike's Information Criterion- AIC) ' dir [40]. Sonradan bu kriteri temel alan birçok kriter geliştirilip literatüre geçmiştir [41,42]. Schwartz (1978) tarafından geliştirilen Schwartz Bayesçi Bilgi Kriteri (Schwartz's Bayesian Information Criterion-SBC ya da Bayesian Information Criterion-BIC) [43], Hannan –Quinn (1979) tarafından geliştirilen Hannan-Quinn Bilgi Kriteri (Hannan & Quinn's Criterion –HQC) [44] ve Bozdogan (1987) tarafından geliştirilen Tutarlı Akaike Bilgi Kriteri (Consistent Akaike Information Criteria-CAIC veya AICc) [45] bu kriterlerden bazılarıdır. Değişken seçiminde farklı bir yaklaşım olan ve Bozdogan (1988-1994-2000) tarafından geliştirilmiş bilgi karmaşıklığına dayalı değişken seçim kriterleri ise ICOMP (Information Complexity) tipi kriterler olarak nitelendirilir [46,47,48]. ICOMP tipi kriterler, sadece uyum iyiliği ve model yalınlığını değil, model karmaşıklığını da dikkate alırlar. Önemli olan biginin tutarlı ölçülmesidir [33]. Kullback- Leibler bilgisine

dayalı bu kriterler günümüze kadar sıklıkla başvuru geleneksel metotlardan daha iyi sonuçlar vermektedirler [49].

2.2.1. Cimrilik Prensibi

Model seçiminin temeli aslında Cimrilik Prensibine dayandırabilir. Verinin en iyi şekilde yansıtılabilmesi için gerekli ve yeterli en az sayıda değişken (parametre) ile ifade edilmesi prensibidir [19]. Böylece oluşacak sapmalar (gereksiz değişkenler modele dahil edilerek varyans artar) için baştan önlem almaya çalışılır. Yani en optimal modelin en az sayıda değişkenle yalınlaştırılması istenmektedir. Bu süreçte veri toplanması, doğru örnek/ veri büyüklüğünün (Sample, Bias, Errors of Meauserement; Örnek büyüklüğünü yanlış seçme ve toplanan verilerden kaynaklanan ölçme hataları model kururken dikkat edilmesi gereken noktalardır.) oluşturulmasıyla başlar.



Şekil 2.1. Parametre sayısının varyans ve eğilimle ilişkisi

Şekil 2.1' e bakıldığında parametre sayısının varyans ve eğilimle ilişkili olduğu görülür. Parametre sayısı arttığında oluşacak modeldeki eğilimin azaldığı fakat varyansın arttığı görülür. Burada varyansın niçin arttığı düşündürücüdür. Ayrıca eğilim ve varyansın kesişim noktası en optimal model için gerekli değildir. CP en uygun dengeyi eğilim varyans noktasında hedeflemeye çalışmaktadır [50].

2.2.2. Entropi

Bilimdeki kesinlik anlayışının Laplace'çı katı yorumun, çağdaş fiziğin gelişimiyle pozitif bilimlerde aşılması, tüm bilim felsefesini etkilemiş ve toplumsal bilimler de dahil her alanda olasılığa dayanan bir yaklaşım yer almaya başlamıştır. Bu olgu her şeyi olasılığın belirsizliğine bırakarak bilimsel kanunların reddi değil, kanunların katı bir mekanik determinist anlayışa bağlamak yerine, her kanunun henüz tamamlanmamış

olduğunu, doğa ile ilgili bilgilerimizin göreceli olmasından dolayı kanunların sadece bir yaklaşım olduğunu belirtmektedir. Çağın ulaştığı bilimsel yaklaşımın temelinde, kanunun belirttiği genel ve zorunlu ilişki, kendisini ancak tek başına ve çeşitli özellikleriyle meydana gelen rastlantısal olaylarla açıklamayla yani rastgelelik ve deterministliği (kesinliği) aynı anda var olan iki kategoride ele almakla açıklar [51]. Olasılık teorisi tümünden gelimci bir yöntemle matematiksel modellerin oluşturulması ile başlayan süreç, uygulama alanında tersine bir çıkarsamayla, belli varsayımlara uygunluk kaydıyla gözlenen değerlerin hangi olasılıkla ortaya çıktığını hesaplamaya çalışır. Gözlemlerin sınırlı olması ve gözlem anında araştırmacının gerçeğe müdahalesi, ... gibi gerçeği tam olarak gözlemeyi engelleyen olguların olumsuz etkilerinin bir şekilde ortadan kaldırılmasını sağlar.

n sayıda değişken ile ilgili N sayıda gözlem yapıldığını varsayalım. Her değişken N boyutlu bir uzayda bir vektör olarak gösterilirse, vektörlerin bu uzaydaki konumlarının mutlak değil ancak olasılıkla belirlenmiş olacağı açıktır. Vektörlerin (değişkenlerin) uzaydaki şekillenmeleri için iki uç durum düşünülebilir: İlk olarak; bütün değişkenlerin bu uzayda ilişki olmayacak şekilde dağıldığı yani tam bir düzensizlik, rastgelelik hali, ikinci olarak; bütün değişkenlerin birkaç noktada yoğunlaştığı tam bir kesinlik hali. Birinci durumda vektörlerle ilgili belirsizliğin en fazla (maksimum) olduğu, ikinci durumda ise en az (minimum) olduğu söylenebilir. Gerçekte rastlanan durumlar ise bu iki uç arasındadır. Benzer şekilde, belirsizlik n boyutlu uzayda yer alan N sayıda değişken içinde söylenebilir [51].

Bu bağlamda entropi, bir rastlantı değişkeni için belirsizlik ölçüsüdür [52]. Bu kavram ilk olarak Fizik'te termodinamik literatüründe ortaya çıkmıştır. Daha sonra Claude E. Shannon (1948) tarafından geliştirilen bilgi kavramı ilişkisi nedeniyle termodinamikteki entropiden ayrılması için Bilgi Teorik Entropi (Information Theoretical Entropy) veya Shannon'un Entropisi olarak adlandırılır [53]. Bir araştırmadan elde edilebilecek veri seti içinde, her türlü ölçme düzeyinde sorulmuş soruların/ gözlemlerin sonuçları olasılıklar biçiminde ifade edilebiliyorsa, değişkenler için entropi değerleri hesaplanabilir. Entropi sistemde var olan düzensizliğin derecesinin ölçüsüdür. Bir şeyin herhangi bir durumda bulunabilme olasılığıdır [54,55].

Herhangi bir X rastgele değişkeni p adet olası değere sahip olsun. X için kesikli değerleri $x_j (j = 1, 2, \dots, p)$ is x_j 'in her bir değeri olasılık şartları altında $p(x_j)$ olasılıklarına sahipse;

$0 \leq p(x_j) \leq 1$ ve $\sum_{j=1}^N p(x_j) = 1$ olur. $p(x_j)$ olasılığı ile $X = x_j$ olayı gözlemlendikten sonra elde edilen bilgi miktarı (2.1)' deki gibi gösterilir.

$$I(x_j) = \log \left(\frac{1}{p(x_j)} \right) = -\log p(x_j) \quad (2.1)$$

Olasılık 1'den küçük olduğunda, logaritması negatif olacağı için formülde $-$ işareti bilgi miktarını pozitif yaparak ölçülmesini sağlamaktadır. Yani eğer X olayı için p adet olası değer farklı olasılıklarla meydana gelirse, özellikle $p(x_j)$ olasılığı düşükse o zaman daha yüksek olasılıklarda meydana gelebilecek diğer x_k değerlerinden ziyade X 'in x_j değerini alması daha fazla bilgi içerir. X olayının entropisi bilginin ortalaması veya beklenen değeri ile tanımlanır. Kesikli dağılımlar için gösterimi (2.2) nolu denklemdeki gibidir.

$$H(X) = E\{I(X)\} = \sum_{j=1}^p p(x_j) I(x_j) = -\sum_{j=1}^p p(x_j) \log p(x_j) \quad (2.2)$$

Sürekli durumlar için (2.3) nolu eşitlik verilmiştir.

$$H(X) = E\{I(X)\} = -\int_{-\infty}^{\infty} p(x_j) I(x_j) dx \quad (2.3)$$

X rastlantı değişkeninin $H(X)$ ile gösterilen entropisi, dağılımın düzgünlüğünü ölçer ve dağılıma ilişkin belirsizliğin ölçüsüdür. Örneklemden elde edilen entropi olasılıklarla ifade edilebilen modellerin bilinmeyen parametrelerinin tahmininde kullanılan önemli bir kavramdır. Standart sapma gibi bir değişim ölçüsüdür [56]. Eğer entropi X rastlantı değişkeninin $P_X(X)$ dağılımına ne kadar uyduğu bilgisini veriyorsa, örnek olarak normal dağılıma uyan bir $X \sim P_X(X) = N(\mu, \sigma^2)$ rastlantı değişkeni için Shannon entropisi (2.4) nolu eşitlikte verilmiştir.

$$\begin{aligned} H(X) &= -E[\log P_X(X)] = -E \left[\log \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\left(\frac{X-\mu}{\sigma}\right)^2} \right] \\ H(X) &= -E \left[\ln 1 - \ln \sqrt{2\pi\sigma^2} - \ln e^{-\left(\frac{X-\mu}{\sigma}\right)^2} \right] = -E \left[-\ln \sqrt{2\pi\sigma^2} + \left(\frac{X-\mu}{\sigma}\right)^2 \right] = \ln \sqrt{2\pi\sigma^2} \end{aligned} \quad (2.4)$$

2.2.3. Kullback-Leibler Uzaklığı

Tüm bilgi kriterlerinin çıkış noktasındaki en büyük etkiye sahip olan kavramlardan birisi de Kullback-Leibler (KL-1951) Uzaklığı'dır [57]. İki olasılık dağılımı arasındaki uzaklığın boyutunun ölçülmesidir. Gerçek model ile tahminlenen model arasındaki uzaklığın ölçümünde kullanılır. KL değeri ne kadar küçük olursa tahmin edilen değer gerçek değere o kadar yakındır diye yorumlanabilir. KL'ın göreceli entropi, ıraksama, ayırım, ...gibi farklı isimlere karşılık geldiği görülür. X rastlantı değişkeninin olası f ve g gibi iki dağılım arasındaki uzaklığının simetrik olmayan bir ölçüsü olarak ifadesiyle f ve g arasındaki dağılımın KL uzaklığı $D_{KL}(f \parallel g)$ gösterilmek üzere (2.5) nolu eşitlikteki gibidir [58].

$$D_{KL}(f \parallel g) = E_f \left[\ln \frac{f(x)}{g(x)} \right] = \int_{-\infty}^{\infty} f(x) \ln \frac{f(x)}{g(x)} dx \quad (2.5)$$

Burada $E_f(\cdot)$, f fonksiyonuna göre beklenen değeri ifade etmektedir. (2.5) eşitliği ile verilen tanımdan (2.6) eşitliği yazılır.

$$D_{KL}(f \parallel g) = E_f[\ln f(x)] - E_f[\ln g(x)] \quad (2.6)$$

KL uzaklığı iki olasılık dağılımının beklenen değerleri arasındaki fark olarak da yorumlanabilir. İki farklı dağılım için genelde (2.7) nolu eşitlik yazılır.

$$D_{KL}(f \parallel g) \neq D_{KL}(g \parallel f) \quad (2.7)$$

(2.7) 'de de verildiği gibi KL uzaklığı bir metrik değildir.

$$D_{KL}(f \parallel g) = D_{KL}(g \parallel f) \quad (2.8)$$

(2.8) nolu eşitliğin olması ancak $f = g$ olmasıyla mümkündür. Yukarıdaki ifade iki olasılık dağılımı için yazıldı, gerçek ve tahmini değer için de yazılabilir. Bir θ parametre vektörü için X rastlantı değişkeninin bileşik olasılık yoğunluk fonksiyonu $f(X \setminus \theta)$ olmak üzere gerçek model $f(X \setminus \theta^*)$ fonksiyonu ile verilmiş olsun. Ayrıca gerçek model ile herhangi bir model olan $f(X \setminus \theta)$ arasındaki KL uzaklığı $I(\theta \setminus \theta^*)$ ile ifade edilsin. Bu durumda x_i ($i = 1, 2, \dots, n$) değişkenleri birbirinden bağımsız olmak üzere KL uzaklığı (2.9) nolu eşitlikteki gibidir.

$$KL(\theta^*, \theta) = \int_{R^n} f(X \setminus \theta^*) \log \left[\frac{f(X \setminus \theta^*)}{f(X \setminus \theta)} \right] dx$$

$$= \sum_{i=1}^n \int f_i(x_i \setminus \theta^*) \log[f_i(x_i \setminus \theta^*)] d_{x_i} - \sum_{j=1}^n \int f_i(x_i \setminus \theta^*) \log[f_i(x_i \setminus \theta)] d_{x_i} \quad (2.9)$$

Yukarıdaki (2.9) nolu formülde yer alan f_i ($i = 1, 2, \dots, n$), x_i değişkenlerinin marjinal olasılık yoğunluk fonksiyonunu göstermektedir. Ayrıca (2.9)'da verilen eşitliğin ilk terimi $f_i(x_i \setminus \theta^*)$ için sabit olan negatif entropisi (2.10) nolu eşitlikteki gibidir.

$$H(\theta^*, \theta) = H(\theta^*) \quad (2.10)$$

İkinci terim ise (2.11) nolu eşitlikte yazılır.

$$- \sum_{i=1}^n \int E[\log f_i(x_i \setminus \theta)] \quad (2.11)$$

Tahminlenmesinin yansız hali ise aşağıdaki (2.12) nolu eşitlikteki gibidir:

$$- \sum_{i=1}^n \int \log f_i(x_i \setminus \theta) = -\log L(\theta \setminus X) \quad (2.12)$$

Böylece bilinmeyen gerçek parametre vektörü θ^* formülden çıkarılmış olur. (2.12)'deki eşitlikte $L(\theta \setminus X)$, gözlemlerin θ parametresi için kestirilen log-olabilirlik fonksiyonudur. Eğer uygulamada $\hat{\theta}$ parametresi vektörü kullanılırsa (2.13) nolu ifade yazılmaktadır [59].

$$- \sum_{i=1}^n \int \log f_i(x_i \setminus \hat{\theta}) = -\log L(\hat{\theta} \setminus X) \quad (2.13)$$

2.2.4. Fisher Bilgi Matrisi

Fisher bilgisi, bir X rastlantı değişkenine ait rastlantısal gözlem değerlerinin θ parametresi hakkında taşıdığı bilginin ölçüsüdür. X rastlantı değişkenine ait olabilirlik fonksiyonun θ parametresine göre ikinci türevinin beklenen değerinin ters işaretlisidir. n bağımsız bileşenden oluşan $X = (x_1, x_2, \dots, x_n)$ rastlantı değişkeninin olasılık yoğunluk fonksiyonu $f(X \setminus \theta)$ olmak üzere X rastlantı değişkenine ait olabilirlik fonksiyonu (2.14) nolu eşitlikteki gibidir.

$$L(\theta \setminus X) = \prod_{i=1}^n f_i(x_i \setminus \theta) \quad (2.14)$$

Log –olabilirlik fonksiyonu ise aşağıdaki (2.15) nolu ifade gibi olur.

$$l(\theta) = l(\theta \setminus X) = \sum_{i=1}^n \ln f_i(x_i \setminus \theta) \quad (2.15)$$

(2.15)' daki eşitlik Fisher bilgisinin beklenen değerinin log- olabilirlik fonksiyonunun kullanımıyla;

$$\mathcal{F}(\theta) = -E \left[\frac{\partial^2 l(\theta)}{\partial \theta^2} \right] = -E \left[\frac{\partial^2 l(\theta)}{\partial \theta^2} \right] \quad (2.16)$$

Yukarıdaki(2.16) nolu ifade negatif değerler almayan bilgi matrisidir. Etkinlik ve Yeterlilik kavramlarıyla yakından ilişkilidir. θ parametresine ilişkin bilginin miktarını ölçmede ve θ 'nın yansız kestiricisinde doğrusal bir orantıya sahiptir. Fisher bilgisi ile Kullback-Leibler bilgisinin yeterlik, etkinlik, toplanabilirlik ve gözlemlerin gruplanmasına ilişkin özellikleri benzerdir [33,60].

Fisher Bilgi Matrisinin Ters, Ters Fisher Bilgi Matrisi (Inverse Fisher Information Matrix =IFIM) model kovaryans matrisi ile yakından ilişkili olup model kurmada bazı değişken seçiminde önemli rol oynar. Gerçek θ parametresinin tahmini olan $\hat{\theta}$ 'nin yardımıyla hesaplanan $\hat{\Sigma}$ 'nın kullanılmasıyla normal dağılım için IFIM aşağıdaki (2.17) nolu eşitlikle hesaplanır.

$$\hat{\mathcal{F}}^{-1} = \begin{bmatrix} \hat{\Sigma}(\hat{\theta}) & 0 \\ 0 & \left(\frac{2}{n} D_{p+q}^+ [\hat{\Sigma}(\hat{\theta}) \otimes \hat{\Sigma}(\hat{\theta})] D_{p+q}^+ \right) \end{bmatrix} \quad (2.17)$$

(2.17) 'deki eşitlikte D_p , $p^2 \times p(p+1)/2$ boyutlu Duplikasyon Matrisi D_p^+ ise D_p 'nin Moore Pensore Ters, Ters Fisher Bilgi Matrisi olacak şekilde $D_p^+ = (D_p' D_p)^{-1} D_p'$ formülü ile hesaplanan $p(p+1)/2 \times p^2$ boyutlu matristir. $\otimes$ işareti ise doğrudan (kronecker) çarpımı ifade eder [33,61].

2.3. Model Seçim Kriterleri

Bu bölümde geleneksel seçim kriterlerinden R^2 ve R_D^2 'ye de değinilmiştir. Sonraki bölümlerde günümüze kadar gelmiş olan bilgi kriterleriyle ilgili bilgiler verilmiştir.

2.3.1. R^2 Seçim Kriteri

[0,1] aralığında değerler alabilen sıfıra yaklaştığında modelin açıklama yeteneğinin zayıflandığı, bire yaklaştığında ise modelin açıklama yeteneğinin yüksek olduğunu gösteren belirlilik katsayısı olarak da nitelendirilen R^2 seçim kriteri modelin uygunluğunun ölçülmesinde en sık kullanılan seçim kriteridir [62]. Açıklanan değişkenin kendi içindeki

değişiminde, modelde yer alan açıklayıcı değişkenler tarafından açıklanan kısmın oranını verir ve (2.18), (2.19), (2.20) ve (2.21) nolu eşitliklerde sırasıyla ifade edilmiştir [1,63].

$$R^2 = \frac{RKT}{TKT} = 1 - \frac{HKT}{TKT} = \frac{TKT-HKT}{TKT} \quad (2.18)$$

$$HKT = \text{Hata Kareler Toplamı} = e^t e = (Y - \hat{Y})^t \cdot (Y - \hat{Y}) \quad (2.19)$$

$$TKT = \text{Toplam Kareler Toplamı} = (Y - \bar{Y} \mathbf{1}_{n \times 1})^t (Y - \bar{Y} \mathbf{1}_{n \times 1}) \quad (2.20)$$

$$RKT = \text{Regresyon Kareler Toplamı} = (\hat{Y} - \bar{Y} \mathbf{1}_{n \times 1})^t (\hat{Y} - \bar{Y} \mathbf{1}_{n \times 1}) \quad (2.21)$$

$Y = n \times 1$ boyutlu açıklanan değişkene ilişkin gözlem vektörünü

$\bar{Y} = Y$ 'nin ortalaması ve $\mathbf{1}_{n \times 1}$, elemanları 1'lerden oluşan vektör

$e = n \times 1$ boyutlu ve $N(0, \sigma^2)$ dağılımlı hata terimi vektörü

$\hat{Y} = Y$ 'nin tahmini değerler vektörünü göstermektedir .

$$\underbrace{\sum (Y - \bar{Y})^2}_{[Y' \text{ deki toplam}]} = \underbrace{\sum (Y - \hat{Y})^2}_{[Y' \text{ deX ile açıklanamayan}]} + \underbrace{\sum (\hat{Y} - \bar{Y})^2}_{[Y' \text{ deX ile açıklanan}]} \quad (2.22)$$

değişkenlik *değişkenlik* *değişkenlik*

(2.22) nolu eşitlikte her üç terimi de $\sum (Y - \bar{Y})^2$ 'ye bölersek (2.23) nolu eşitliğe ulaşırız.

$$1 = \frac{\sum (Y - \bar{Y})^2}{\sum (Y - \bar{Y})^2} + \underbrace{\frac{\sum (\hat{Y} - \bar{Y})^2}{\sum (Y - \bar{Y})^2}}_{R^2} \Rightarrow \left[\begin{array}{c} \underbrace{R^2}_{\substack{\text{Belirlilik Katsayısı} \\ \text{Açıklanabilirlik} \\ R^2 \text{ Kriteri} \\ (1-R^2 = \text{Belirsizlik Kriteri})}} \end{array} \right] = \underbrace{1}_{[\text{Toplam}]} - \underbrace{\frac{\sum (Y - \bar{Y})^2}{\sum (Y - \bar{Y})^2}}_{[\text{Açıklanamayan}]} \quad (2.23)$$

R^2 seçim kriteri olarak alındığında bazı eksikliklerden dolayı sorunlar ortaya çıkmaktadır [50,64].

Verilen örnek büyüklüğü içinde tahmini değerler gerçek değerlere ne kadar yakın (o kadar iyi) olsalar da gelecek kestirimde bu garantiyi sağlamak mümkün olmayabilir.

R^2 değerlerinin kıyası için modellerin fonksiyonel yapısının ve tahmin edicilerinin aynı olması gerekmektedir. Farklı model yapıları için birçok R^2 örneği bulunmaktadır.

Modele alınan açıklayıcı değişken sayısı arttıkça R^2 değeri de artmaktadır. Bu yöntemle maksimum R^2 'ye ulaşılabilir. Fakat bu durumda gelecek tahmin hata

varyansını da arttırabilir. Bu nedenle model seçim kriteri olarak alınması her zaman yeterli değildir.

2.3.2. R_D^2 Seçim Kriteri

R^2 seçim kriterindeki bazı eksikliklerden dolayı R_D^2 seçim kriteri ortaya atılmıştır. İlk defa Henry Theil açıklayıcı değişkenlerin katkısıyla ortaya çıkan R^2 değerindeki yükselmeyi önlemek için R^2 düzeltilmiş kriterini (R_D^2) geliştirmiştir [65].

$$R_D^2 = 1 - \frac{(n-1)}{(n-1-p)} (1 - R^2) \quad (2.24)$$

(2.24) nolu eşitlikte gösterilen R_D^2 , R^2 farklı olarak eklenen değişkenin sadece mutlak t değerinin 1'den büyük olduğu durumlarda yükselir ve daima $R_D^2 \leq R^2$ 'dir. Fakat R^2 kriterinde de olduğu gibi her zaman modelin fonksiyonel yapısının ve tahmin edicilerinin aynı olması şartı vardır. Modeller seçim analizlerinde kıyaslandığında her zaman $Max R^2$ değerini alan ifade göz önünde bulundurulur. R_D^2 , EKK ile tahmin edilmiş regresyonlarda daha çok kullanılmaktadır. Bayesçi yaklaşımlarda zayıf kaldığı görülmektedir [50,66].

2.3.3. Akaike Bilgi Kriteri (AIC)

Model seçim kriterleri kullanılırken genellikle modelin önceden belirlenen belirli bir parametrik dağılıma uyduğu varsayılarak model kestirilir. Ancak veri analizi süreci boyunca elde edilen verilerin bu varsayımı sağlamadığı sıklıkla gözlenir. Bu gibi durumlarda modelin dağılımının doğru belirlenebilmesi anlamında hatalı modelleme riski ortaya çıkmaktadır. Dağılımın doğru kestirilmesi gereklidir fakat yeterli değildir. Yeterliliği için gerçek parametre vektörünün belirlenen model üzerinde sınırlandırılmış parametre uzayında kestirildiği durumlarda kestirim riski ile birlikte ortaya çıkar. Burada risk, kestirimde varyans bileşenidir. Gerçek parametre vektörünün, modelin sınırlandırılmış parametre uzayı tarafından kapsanmadığı durumlarda yan oluşur. Diğer bir ifadeyle kestirimde varyans, modelin kabul edilen parametre uzayının büyüklüğüne karşılık getirilen ceza olarak yorumlanırken, yan ise modelin gerçek parametre vektörü ile

indirgenmiş parametre uzayı arasındaki uzaklıktır. Kısacası (2.25) nolu formla ifade edilebilir.

$$\underbrace{Toplam Risk}_R = \underbrace{Modelleme Riski}_{R(M)} + \underbrace{Kestirim Riski}_{R(E)} \quad (2.25)$$

Model değişken seçimlerinde amaç, Toplam Risk R'nin en küçüklenmesidir. Akaike (1973-1974-1981) yıllarında ard arda yayınladığı makaleleriyle değişken seçim kriterlerine farklı bir yaklaşımda bulunmuştur [48]. *AIC* kriterini temel alan diğer kriterlere de *AIC*-tipi kriterler denir. Bu kriterlerin hepsinde uyum eksikliği bileşeni ortak olmakla beraber, kestirilen parametre sayısının cezalandırıldığı ceza terimleri farklılık göstermektedir. Araştırmacı için minimum bilgi kriteri (hangi kriter kullanılmışsa) değerine sahip olan modeli seçmek önemlidir.

$$AIC = e^{\frac{2k}{n} \frac{\sum \hat{\mu}^2}{n}} = e^{\frac{2k}{n} \frac{RSS}{n}} \quad (2.26)$$

$$\ln(AIC) = \frac{2k}{n} + \frac{RSS}{n}$$

$$AIC = -2\log L(\hat{\theta}) + 2k \quad (2.27)$$

k: sabit terim dahil parametre sayısını (veya bağımsız parametre sayısı)

n: gözlem sayısını

$\hat{\theta} = \theta$ parametre vektörünün maksimum olabilirlik tahminini

$L(\hat{\theta})$: Benzerliği(likelihood) vermekte (maksimize edilmiş olabilirlik fonksiyonu)

(2.26) 'daki eşitlikte $\ln AIC = AIC$ 'nin doğal logaritmasıdır. ve $\frac{2k}{n}$ ise sınırlama (penalty) faktörüdür. AIC, R_D^2 'den eklenen yeni bağımsız değişkenler konusunda daha da serttir (2.27) nolu eşitlikte verilen ortalama beklenen olabilirliğin logaritmasının -2 katının yansız kestiricisi olan *AIC*, modelin uyum eksikliğinin değerlendirilmesi ve parametre sayısının cezalandırılması esasına dayalı bir kriterdir. Parametre sayısının ceza terimi olarak kriter eklenmesi *AIC*'yi farklı boyutlu modellerin karşılaştırılmasına imkan sağlar [55,56]. Uyum eksikliğinin cezalandırılması ise KL uzaklığına dayanmaktadır. Kıyaslandırılan modellerde

en küçük AIC değerin bir başka ifadeyle kestirilen model ile gerçek model arasındaki KL uzaklığının en küçüklenmesidir.

2.3.4. Schwartz Bilgi Kriteri (SBC)

Schwartz bilgi kriteri, Schwartz (1978) [43] tarafından AIC temelli farklı bir formdur. Bayes yaklaşımlarına dayandığından aynı zamanda Bayes Bilgi Kriteri(BIC) olarak da adlandırılır. BIC 'nin ceza terimi, AIC 'nin ceza teriminden daha büyüktür. SBC 'i modeli AIC modelinden daha küçük veya en azından eşit boyutlu model olması beklenir. Genel formu (2.28) nolu eşitlikteki gibidir.

$$SBC = BIC = -2\log L(\hat{\theta}) + k\log(n) \quad (2.28)$$

2.3.5. Tutarlı Akaike Bilgi Kriteri ($CAIC - AICc$)

Örneklem büyüklüğü arttıkça, AIC 'nin birinci terimi artar fakat ceza terimi olan $2k$ değişmez. Yani ceza teriminin yanlılığı telafi etmesindeki etkisinin, n örneklem büyüklüğünün arttıkça azalmasıdır. O halde AIC bilgi kriterinin tutarlılığının asimptotik durumlarda tartışmalıdır. Ayrıca ceza teriminin önündeki 2 sayısının kullanımının hangi kriterle dayandığı sağlam bilgilerle desteklenmediğinden 2'nin yerine bir α sabiti koyarak bu sabitin 1 ile 4 arasında değerler alabileceğini söylemiştir [67]. Bu sayının rastgele belirlendiğini söyleyenler de olmuştur [68]. Bu sorunların çözümlerinden hareketle AIC kriterini geliştirip genişletmek ve onun asimptotik durumlarda tutarlılığını sağlamak için tahminlenen parametre sayısına ait ceza faktörünü daha katı cezalandıran bir başka yaklaşım Bozdoğan(1987)'de Tutarlı Akaike Bilgi Kriteri($CAIC$)' dir. $CAIC$ 'de daha az değişkenli basit en optimal model seçilmesi en küçük $CAIC$ değeriyle sağlanır. SBC 'nin ceza teriminden bilinmeyen parametre sayısı kadar daha olduğundan ona göre daha basit model bizlere sunar. Genel formu (2.29) nolu eşitlikteki gibidir.

$$CAIC = -2\log L(\hat{\theta}) + k[\log(n) + 1] \quad (2.29)$$

2.3.6. Fisher Bilgi Matrisine Dayalı Tutarlı Akaike Bilgi Kriteri($CAICF$)

$CAIC$ 'ye farklı bir yaklaşım olan Fisher Bilgi Matrisinin kullanıldığı Fisher Bilgi Matrisine Dayalı Tutarlı Akaike Bilgi Kriteri ($CAICF$) genel gösterimi (2.30) ve (2.31) nolu eşitliklerdeki gibidir.

$$CAICF = -2\log L(\hat{\theta}) + k[\log(n) + 2] + \log|\mathcal{F}(\hat{\theta})| \quad (2.30)$$

$$= AIC + k\log(n) + \log|\mathcal{F}(\hat{\theta})| \quad (2.31)$$

Tutarlı kriterlerde gözlem sayısının artmasıyla uyum eksikliği ya da aşırı uyum gösterme olasılığı azalacaktır. Yani örneklem büyüklüğünün fazla olduğu durumlarda CAIC veya CAICF, aşırı uyumun büyük sorun olarak görülmediği durumlarda ise AIC kriterinin kullanılması uygundur [56].

2.3.7. Bilgi Ölçümü ve Bilgi Karmaşıklığı

Rastgele bir vektörün bileşenleri arasındaki bağımlılığının (etkileşiminin) ölçüsü onun kompleksliğidir (karmaşıklığıdır) [34]. Bileşenler arasında ne kadar yüksek ilişki varsa karmaşıklığı da o derece yüksek dereceli olur. Bu durumda kestirilen olgu gerçeklik hakkında doğru sonuçların çıkmasında daha da zor bir hal alır. $f(X) = (X_1, X_2, \dots, X_p)$ ortak dağılım fonksiyonu ve $f_j(X_j), j = 1, 2, \dots, p$ marjinal dağılım fonksiyonları olmak üzere p değişkenli sürekli bir dağılımın $X_1, X_2, \dots, X_p$ rastgele değişkenleri arasındaki bağımlılığın ölçüsü (2.32) nolu eşitlikte verilmiştir.

$$I(X) = I(X_1, X_2, \dots, X_p) = E_f \left[\log \frac{f(X_1, X_2, \dots, X_p)}{f_1(X_1) \cdot f_2(X_2) \cdot \dots \cdot f_p(X_p)} \right] \quad (2.32)$$

Sürekli fonksiyonlar için gösterimi (2.33) nolu eşitlikteki gibidir [69-70].

$$I(X) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(X_1, X_2, \dots, X_p) \frac{f(X_1, X_2, \dots, X_p)}{f_1(X_1) \cdot f_2(X_2) \cdot \dots \cdot f_p(X_p)} d_{X_1} \cdot d_{X_2} \dots d_{X_p} \quad (2.33)$$

$I(X)$ bağımsızlığa karşı sapan bilgi miktarı, KL ölçüsüdür. Aynı zamanda beklenen karşılıklı bilgi veya uygun bilgi olarak da bilinen değişken bileşenleri arasındaki beklenen bağımlılığın bir ölçüsüdür.

$I(X)$ 'in özellikleri;

$I(X) = I(X_2, \dots, X_p) \geq 0$ 'dır. Beklenen karşılıklı bilgi pozitif veya sıfırdır. Yani negatif değerler alamaz.

Eğer her p çifti $X_1, X_2, \dots, X_p$ rastgele değişkenleri karşılıklı ve istatistik olarak bağımlı değilse $f(X_1, X_2, \dots, X_p) = f_1(X_1) \cdot f_2(X_2) \cdot \dots \cdot f_p(X_p)$ ' dir. Bu durumda (2.33) eşitliği sıfıra eşit olur. O halde eşitliğin sıfırdan farklı olması bağımlılığa bağlıdır [34].

(2.33)' teki KL sapması, Shannon (1948)'un entropisi ile ilişkilidir. Shannon'un Entropisi, herhangi bir X rastlantı değişkeninin dağılım fonksiyonu $f_X(X)$ olmak üzere (2.34) nolu eşitlik sağlanır.

$$H(X) = -E[\log f_X(X)] \quad (2.34)$$

Bu ifade X rastlantı değişkeninin $f_X(X)$ dağılımına ne kadar uyduğu bilgisini vermektedir. Bu tanımdan hareketle, $H(X_j)$ $j = 1, 2, \dots, p$ marjinal entropiyi ve $H(X_1, X_2, \dots, X_p)$ ortak entropiyi gösterirse (2.35) nolu ifade yazılmaktadır.

$$I(X) = I(X_1, X_2, \dots, X_p) = \sum_{j=1}^p H(X_j) - H(X_1, X_2, \dots, X_p) \quad (2.35)$$

(2.35) nolu eşitliğe bağımlılık ölçüsü ve yapısal ilginçlik de denebilir [71]. Shannon kompleksliği olarak da adlandırılabilir. Bileşenler arasındaki bağımlılığın derecesi ne kadar kuvvetliyse marjinal entropilerinin toplamı o derece büyüktür. Bilginin ilişkili olarak yükselmesi bağımlılık varlığında gerçekleşiyorsa, bağımsızlık durumunda daha az ve daha önemli bileşenlerin ayıklanması mümkün olacaktır.

$f(X) = f(X_1, X_2, \dots, X_p)$ 'i çok değişkenli normal dağılım fonksiyonunun kompleksliğinin kurumsal bilgi ölçütü (2.36) nolu eşitlikte verilmiştir [34,48,72].

$$f(X) = f(X_1, X_2, \dots, X_p) = (2\pi)^{-\frac{p}{2}} |\Sigma|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right\} \quad (2.36)$$

Burada $\mu = (\mu_1, \mu_2, \dots, \mu_p)'$, $-\infty \leq \mu_j \leq \infty$, $j = 1, 2, \dots, p$ ve $\Sigma > 0$ olup $X \sim N_p(\mu, \Sigma)$ ' dir. (2.35) eşitliğindeki ortak entropi (2.37) nolu eşitlikte farklı bir form şeklinde gösterilmiştir.

$$\begin{aligned} H(X) &= \int f(x) \left[\frac{p}{2} \log(2\pi) |\Sigma| + \frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu) \right] d_x \\ &= \frac{p}{2} \log(2\pi) |\Sigma| + \frac{1}{2} \text{tr} \{ \int f(x) \Sigma^{-1} (x - \mu)^T (x - \mu) d_x \} \end{aligned} \quad (2.37)$$

$$E[(x - \mu)^T(x - \mu)] = \Sigma$$

Yukarıdaki eşitlik denklemde yerine yazılırsa (2.38) nolu eşitlik bulunur.

$$\begin{aligned} H(X) &= \frac{p}{2} \log(2\pi) + \frac{p}{2} + \frac{1}{2} \log|\Sigma| \\ &= \frac{p}{2} [\log(2\pi) + 1] + \frac{1}{2} \log|\Sigma| \end{aligned} \quad (2.38)$$

(2.38)'deki eşitliğin çok değişkenli normal dağılım değerlerinin marjinal entropisi (2.39) nolu eşitlikte verilmiştir.

$$\begin{aligned} H(X_j) &= - \int f(X_j) \log f(X_j) d_{x_j} \\ &= \frac{1}{2} \log(2\pi) + \frac{1}{2} + \frac{1}{2} \log|\sigma_{jj}| \quad j = 1, 2, \dots, p \end{aligned} \quad (2.39)$$

Bozdoğan'ın kriteri ICOMP'ın formülünde kullanılan maksimal kovaryans kompleksliğin tanımında ilham kaynağı olan van Emdem [73] tarafından çok değişkenli normal dağılım değerleri için tanımlanan Σ kovaryans matrisinin kompleksliğinin başlangıç tanımı (2.40) nolu eşitlikteki gibidir.

$$I(X) = I(X_1, X_2, \dots, X_p) = \sum_{j=1}^p H(X_j) - H(X_1, X_2, \dots, X_p) \quad (2.40)$$

(2.40) nolu ifadesinde marjinal ve ortak entropi yerlerine yazılırsa (2.41) nolu form yazılır.

$$I(X) = \sum_{j=1}^p \left[\frac{1}{2} \log(2\pi) + \frac{1}{2} + \frac{1}{2} \log|\sigma_{jj}| \right] - \frac{p}{2} \log(2\pi) - \frac{p}{2} - \frac{1}{2} \log|\Sigma| \quad (2.41)$$

(2.41) nolu ifadede gerekli düzenlemelerle (2.42) nolu eşitlik basitleştirilerek yazılır.

$$C_0(\Sigma) = \frac{1}{2} \sum_{j=1}^p \log|\sigma_{jj}| - \frac{1}{2} \log|\Sigma| \quad (2.42)$$

σ_{jj}, Σ 'nın j. köşegen elemanıdır. ve p, Σ 'nin boyutudur. Buradaki $\sigma_{jj} = \sigma_j^2$ ile j'inci değişken varyansını ifade eder.

C_0 'nın bazı karakteristik özellikleri;

Değişkenler doğrusal olarak bağımsız ise, Σ bir diagonal matris (köşegen matris) ve $C_0(\Sigma) = 0$ 'dır.

Değişkenlerden bir tanesi, diğer değişkenlerin doğrusal bir fonksiyonu olarak yazılabilirse $|\Sigma| = 0$ olduğundan $C_0(\Sigma) = \infty$ 'dır.

$C_0(\Sigma)$, $X_1, X_2, \dots, X_p$ rassal değişkenleri ortak ve marjinal dağılımlarına bağlı olduğundan , $C_0(\Sigma)$ 'nın formülündeki sağ tarafın ilk ifadesi ortonormal dönüşüm altında sabit kalmayıp değişebildiğinden $C_0(\Sigma), \Sigma$ kovaryans matrisindeki komplekslik miktarının etkili bir ölçütü değildir [34].

Bu özelliklerden hareketle, Σ 'nın kompleksliğinin maksimal miktarını karakterize etmek için, Bozdoğan [46,72] tarafından $C_0(\Sigma)$ 'nın herhangi bir ortonormal dönüşüm altında maksimumu hesaplanmış ve bu yeni ölçü $C_1(\Sigma)$ olarak tanımlanmıştır. T herhangi bir ortonormal dönüşüm için gösterimi (2.43) ve (2.44) nolu denklemlerle ifade edilir.

$$C_1(\Sigma) = \max_T \{H(X_1) + \dots + H(X_p) - H(X_1, X_2, \dots, X_p)\} \quad (2.43)$$

$$C_1(\Sigma) = \max_T C_0(\Sigma) = \max_T \left\{ \frac{1}{2} \sum_{j=1}^p \log |\sigma_{jj}| - \frac{1}{2} \log |\Sigma| \right\} \quad (2.44)$$

Ortonormal dönüşümler $tr(\Sigma) = \sigma_{11} + \dots + \sigma_{pp}$ 'yi değişmez bıraktığı için (2.45) nolu form oluşur.

$$\max \sum_{j=1}^p \log(\sigma_{jj}) = \max \log \prod_{j=1}^p \sigma_{jj} \quad (2.45)$$

Bu maksimizasyonu yapmak için (2.46) nolu denklem göz önüne alınırsa (2.47) nolu eşitlik oluşur.

$$(\prod \sigma_{jj})^{\frac{1}{p}} \leq \frac{1}{p} \sum \sigma_{jj} \quad (2.46)$$

$$= p \log tr(\Sigma) - p \log p$$

$$= p \log \left[\frac{tr(\Sigma)}{p} \right] \quad (2.47)$$

(2.47) nolu eşitlikteki değer $C_0(\Sigma)$ 'da yerine yazılırsa (2.48) nolu denklem elde edilir [46,72].

$$C_1(\Sigma) = \frac{p}{2} \log \left[\frac{tr(\Sigma)}{p} \right] - \frac{1}{2} \log |\Sigma| \quad (2.48)$$

$C_1(\Sigma), C_0(\Sigma)$ için bir üst sınırdır. ve hem varyanslar arasındaki eşitsizliği hem de Σ 'da kovaryansların katkısını ölçer. Model içindeki model yapısının ilginç yönlerini tanımlamada benzerliklerini, farklılıklarını, yüksek dereceden korelasyonlarını değerlendirmede ve model seçim problemlerinde bu ölçü çok önemli bir ölçüttür.(2.48) 'de düzenlemeler yapılırsa (2.49) nolu form oluşur.

$$C_1(\Sigma) = \frac{1}{2} \log \frac{\frac{tr(\Sigma)}{p}}{|\Sigma|} \quad (2.49)$$

$|\Sigma|$, genelleştirilmiş varyans ve $\frac{tr(\Sigma)}{p}$ toplam varyans ortalaması olduğundan kompleksliği, genelleştirilmiş varyans ile toplam varyans ortalamasının geometrik ortalaması arasındaki oran olarak da söylenebilir. Eğer, Σ 'nın özdeğerlerinin $\lambda_1, \lambda_2, \dots, \lambda_p$ olarak alınırsa o zaman $\frac{tr(\Sigma)}{p} = \bar{\lambda}_a = \frac{1}{p} \sum \lambda_j$ özdeğerlerin aritmetik ortalaması ve $|\Sigma|^{1/p} = \bar{\lambda}_g = (\prod \lambda_j)^{1/p}$ özdeğerlerin geometrik ortalaması olmak üzere Σ 'nın kompleksliğini (2.50) nolu formla gösterebiliriz.

$$C_1(\Sigma) = \frac{p}{2} \log \frac{\bar{\lambda}_a}{\bar{\lambda}_g} \quad (2.50)$$

$C_1(\Sigma), \Sigma$ 'nın özdeğerlerinin nasıl eşit olmadığını ölçmekte ve tek bir fonksiyon içinde determinant ve iz olarak çok değişkenli saçılımın en basit ölçөгünü içermektedir. Σ 'nın tam ranklı olamadığı durumlarda p değeri genellikle $s = \text{rank}(\Sigma)$ olacak şekilde değiştirilir. Değişkenler arasında yüksek bir etkileşimde kompleksliğin büyük değeri olduğu, etkileşimin zayıf kaldığında küçük değeri komplekslik olduğunu gösterir. Yani $\Sigma \rightarrow I$ olduğunda $C_1(\Sigma) \rightarrow 0$ 'dır. Bu hesaplama çabası ile kurumsal bilgi karmaşıklığı arasında makul bir ilişki kurar. Birim matris en az kompleksliğe sahip olan matris olduğundan buna karşılık gelen ortogonal tasarımlar veya ilişkilerin, bağıntıların olmadığı lineer (doğrusal) modellenli yapılardır. Aksi halde $C_1(\Sigma) > 0$ 'dır. $C_1(\Sigma)$ 'nın önemli bir diğer özelliği ise $C_0(\Sigma)$ 'nın tersine ortogonal dönüşümler altında sabit kaldığıdır [55].

2.3.8. ICOMP -Tipi Bilgi Kriterleri

Çok değişkenli doğrusal olan veya olmayan modellerdeki model seçimlerinde kullanılmak üzere Bozdoğan(1988)' de ICOMP(I=Information-COMP; Complexity)

kriterini geliřtirmiřtir. ICOMP, temelde AIC kriterine benzemekle birlikte, AIC ‘ den farklı özellikleri vardır. Bunlar ;

Modelin parametre tahmininde kovaryans matris özelliklerinin bilgiye dayalı belirlenmesinde sonlu örneklem dağılımlarından başlaması,

IFIM(Ters Fisher Bilgi Matrisi) özelliklerinin bilgiye dayanarak, bir modelin doğruluğunun belirlenmesinde AIC kriterlerinden farklı niteliklerdir.

Model yapısının kestirilmesinde karmařıklık faktörünün göz önüne alınması model kalitesini deęerlendirmekte en önemli ölçütlerdendir. Karmařıklık ve uyum iyilięi arasındaki iliřkinin en optimal olması ICOMP tipi kriterlerin amacıdır.

$$Kayıp = \underbrace{Uyum Eksiklięi + Parametrelerin Ceza Terimi}_{\frac{AIC}{ICOMP}} + Komplekslik Ölçüsü \quad (2.51)$$

ICOMP, yukarıdaki (2.51) nolu eřitlikte gösterilen form kayıp fonksiyonunu tahmin etmede kullanılır. *ICOMP* yalnız uyum eksiklięi ve cezalandırmayla yetinmez parametreler arasındaki iliřki faktörünü de deęerlendirmeye katan komplekslik ölçüsüyle model kalitesini yükseltir. Yani direkt cezalandırma yerine modelin kovaryans komplekslięini cezalandırır. AIC’nin model bileřenleri arasındaki baęımlılıęı dikkate almaması çoklu baęlantı problemine sahip model yaratması olası iken, bu *ICOMP* tipi kriterlerle çok zayıftır. Genel gösterimi (2.52) nolu eřitlikte verilmiřtir.

$$ICOMP = -2\log L(\hat{\theta}) + 2C_1(\Sigma) \quad (2.52)$$

$L(\hat{\theta})$; maksimize edilmiř olabilirlik fonksiyonu,

$\hat{\theta}$; θ parametre vektörünün maksimum olabilirlik tahmini,

C_1 ; (2.48) nolu eřitlikteki komplekslik ölçüsü

Σ , modelin parametre vektörlerinin kovaryans matrisidir.

(2.17) nolu denklemde tanımlanan kestirilmiř ters Fisher bilgi matrisi, Σ kovaryans matrisinin tahminin hesaplanmasında farklı yollardan bir tanesiydi. Bu ifadeyi kullanarak *ICOMP*’ın en genel hali (2.53) nolu formla yazılır.

$$ICOMP(IFIM) = -2\log L(\hat{\theta}) + 2C_1(\hat{F}^{-1}) \quad (2.53)$$

Yukardaki (2.53) nolu eşitliğin sağ tarafındaki ilk ifade modelin uyum eksikliğini, ikinci bileşen ise kestirilen parametre doğruluğunu ölçüt alan kestirilen ters Fisher bilgi matrisinin kompleksliğini ölçer. (2.48) nolu eşitliğe dayanarak (2.54) nolu ifade yazılır.

$$C_1(\hat{\mathcal{F}}^{-1}) = \frac{p}{2} \log \left[\frac{\text{tr}(\hat{\mathcal{F}}^{-1})}{p} \right] - \frac{1}{2} \log |\hat{\mathcal{F}}^{-1}| \quad (2.54)$$

$\hat{\mathcal{F}}^{-1}$ 'in tam ranklı olmadığı halde $p, s = \text{rank}(\hat{\mathcal{F}}^{-1})$ olacaktır [34,48,72].

Sonsal beklenen faydayı (Posterior Expected Utility-PEU) maksimize etmek amacıyla *ICOMP* 'ın farklı bir formu olan Bayes uyarlanması (2.55) nolu eşitlikte verilmiştir.

$$ICOMP_PEU = -2\log L(\hat{\theta}) + k + 2C_1(\hat{\mathcal{F}}^{-1}) \quad (2.55)$$

Yukarıdaki (2.55) nolu form model altındaki θ parametrelerinin önsel(prior) dağılımı $f_{\text{prior}}(\theta|y)$ ve sonsal (posterior) dağılımı $f_{\text{post}}(\theta|y)$ arasındaki KL dayanır.

Bir başka *ICOMP* formu Bozdogan tarafından tanımlanan, modellerin genelde yanlış kestirildiği varsayımından hareketle (2.56) nolu form yazılır.

$$ICOMP_MISS = -2\log L(\hat{\theta}) + 2[\text{tr}(\hat{\mathcal{F}}^{-1}\hat{\mathcal{R}}) + C_1(\hat{\mathcal{F}}^{-1})] \quad (2.56)$$

$\mathcal{F}$, Fisher bilgi matrisinin iç çarpım veya Hessian form, $\mathcal{R}$ ise Fisher bilgi matrisinin dış çarpım formudur. Bu iki formun birbirine eşit çıkması ancak modelin doğru belirlenmesi şartına bağlıdır. Modelin doğru belirlenmesi durumunda bu iki form birbirine eşit olacak ve $\text{tr}(\hat{\mathcal{F}}^{-1}\hat{\mathcal{R}}) = \text{iz}(\mathbf{I}) = k$ olacaktır. O halde daha sade yazılımı (2.57) nolu eşitlikteki gibidir [74].

$$\begin{aligned} ICOMP(IFIM)_k &= -2\log L(\hat{\theta}) + 2k + 2C_1(\hat{\mathcal{F}}^{-1}) \\ &= AIC + 2C_1(\hat{\mathcal{F}}^{-1}) \end{aligned} \quad (2.57)$$

Ters Fisher bilgi matrisinin izi, parametre duyarlılığı etkisini ve determinantı, parametrelerin korelasyonunu önemseyen karmaşık bir fonksiyonu temsil eder [33,46,55,56].

Bu gibi farklı formlar daha yazılabilir. Consistent *ICOMP* – *CICOMP* formu aşağıdaki (2.58) nolu eşitlikte gösterilir.

$$CICOMP = CIAC + 2C_1(\hat{\mathcal{F}}^{-1}) \quad (2.58)$$

Bundan sonraki bölümümüzde uygulama yapılarak sonuçlarla birlikte çalışma tamamlanmıştır.



3. BULGULAR

Bu bölümde;investing.com internet adresinde yer alan ve yayımlanmış olan “Silikon Vadisindeki 10 büyük şirketin son bir aylık borsa hisse senedinin açılış-kapanış verilerine ait geçmiş göstergeler” adlı kaynakta bulunan 21.05.2018-20.06.2018 tarihleri arası borsa hisse senedi açılış-kapanış verisel bilgilere ait tablolar verilmekte sonrasında da uygun bilgi kriterleriyle sonuçlar sunulmaktadır.

Silikon Vadisindeki 10 büyük şirketin bir aylık gözlemlerini kapsayan veriler AR programında uygun şekillerde yerleştirilip en optimal modelin seçilmesi için AIC-AICc ve BIC bilgi kriterleri yardımıyla tespit edilmeye çalışılmıştır. Kullanılan bilgi kriterlerinden hangisi en düşük değeri verirse bizim için göz önünde bulunduracağımız model uygundur diye yorumlanabilir. Tablolar halinde verilen gözlem değerlerinde, şimdi yazan sütun bölümü uygulamada kullanacağımız verileri kapsamaktadır. Diğer sütun bölümlerinin gösterilmesi de sağlıklı analizler yapılması için verilmiştir.

Tablo 3.1. APPL firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	186,47	186,32	186,96	185,75	9,35M	0,42%
19.06.2018	185,69	185,14	186,33	183,45	33,58M	-1,62%
18.06.2018	188,74	187,88	189,22	187,20	18,48M	-0,05%
15.06.2018	188,84	190,03	190,16	188,26	61,72M	-1,03%
14.06.2018	190,80	191,55	191,57	190,22	21,61M	0,05%
13.06.2018	190,70	192,42	192,88	190,44	21,64M	-0,82%
12.06.2018	192,28	191,38	192,61	191,15	16,91M	0,55%
11.06.2018	191,23	191,35	191,97	190,21	18,31M	-0,25%
08.06.2018	191,70	191,17	192,00	189,77	26,66M	-0,91%
07.06.2018	193,46	194,14	194,20	192,34	21,35M	-0,27%
06.06.2018	193,98	193,63	194,08	191,92	20,93M	0,35%
05.06.2018	193,31	193,06	193,94	192,36	21,57M	0,77%
04.06.2018	191,83	191,63	193,42	191,35	26,27M	0,84%
01.06.2018	190,24	187,99	190,26	187,75	23,44M	1,80%
31.05.2018	186,87	187,22	188,23	186,14	27,48M	-0,34%
30.05.2018	187,50	187,72	188,00	186,78	18,69M	-0,21%
29.05.2018	187,90	187,60	188,75	186,87	22,51M	-0,36%
25.05.2018	188,58	188,23	189,65	187,65	17,46M	0,23%
24.05.2018	188,15	188,77	188,84	186,21	23,23M	-0,11%
23.05.2018	188,36	186,35	188,50	185,76	20,06M	0,64%
22.05.2018	187,16	188,38	188,88	186,78	15,24M	-0,25%
21.05.2018	187,63	188,00	189,27	186,91	18,40M	0,71%
En Yüksek: 194,20		En Düşük: 183,45		Fark: 10,75	Ortalama: 189,61	Fark %: 0,09

Tablo 3.2. APPL firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(1,0,0) with non-zero mean		
Coefficients:		
	<i>arl</i>	<i>mean</i>
	0.8375	188.7931
<i>s.e</i>	0.1073	1.4975
Sigma^2 estimated as 1.923: log likelihood = -37.96		
AIC=81.93	AICc=83.26	BIC=85.2

Yorum: Tablo 3.1’de verilen APPL firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.2 ‘deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=81.3 değeri olmuştur.

Tablo 3.3. INTC firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	53,43	53,19	53,74	52,71	11,13M	0,94%
19.06.2018	52,93	52,14	52,95	51,88	31,78M	-0,54%
18.06.2018	53,22	54,30	54,30	52,34	40,76M	-3,43%
15.06.2018	55,11	55,17	55,38	54,58	39,19M	-0,77%
14.06.2018	55,54	55,45	55,86	55,18	23,42M	0,93%
13.06.2018	55,03	54,98	55,70	54,91	22,63M	0,38%
12.06.2018	54,82	54,87	55,03	54,22	23,29M	0,55%
11.06.2018	54,52	54,80	55,09	54,26	25,75M	-0,96%
08.06.2018	55,05	55,56	55,70	54,66	30,82M	-1,49%
07.06.2018	55,88	56,92	57,00	55,62	27,60M	-2,02%
06.06.2018	57,03	56,53	57,06	56,08	22,96M	0,88%
05.06.2018	56,53	56,90	57,12	56,22	21,69M	-0,53%
04.06.2018	56,83	57,01	57,60	56,77	22,54M	-0,44%
01.06.2018	57,08	55,84	57,10	55,80	31,18M	3,41%
31.05.2018	55,20	55,67	55,86	55,06	30,96M	-0,86%
30.05.2018	55,68	55,89	56,20	55,62	24,71M	0,65%
29.05.2018	55,32	55,12	55,81	54,81	24,25M	-0,22%
25.05.2018	55,44	54,80	55,50	54,54	18,55M	1,26%
24.05.2018	54,75	55,18	55,30	54,13	19,67M	-0,83%
23.05.2018	55,21	54,00	55,23	53,84	20,56M	1,40%
22.05.2018	54,45	54,73	55,05	54,05	19,01M	0,24%
21.05.2018	54,32	54,36	55,22	53,86	25,37M	1,53%
En Yüksek: 57,60	En Düşük: 51,88	Fark: 5,72	Ortalama: 55,15	Fark %: -0,13		

Tablo 3.4. INTC firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(1,0,0) with non-zero mean		
Coefficients:		
	<i>arl</i>	<i>mean</i>
	0.7705	54.8543
<i>s.e</i>	0.1350	0.6119
Sigma^2 estimated as 0.5722: log likelihood = -24.48		
AIC=54.95	AICc=56.29	BIC=58.23

Yorum: Tablo 3.3’de verilen INTC firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.4 ‘deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=54.95 değeri olmuştur.

Tablo 3.5. FB firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	202,93	198,94	203,54	198,84	17,68M	2,75%
19.06.2018	197,49	196,24	197,96	193,79	19,99M	-0,41%
18.06.2018	198,31	194,80	199,58	194,13	16,83M	1,26%
15.06.2018	195,85	195,79	197,07	194,64	21,86M	-0,49%
14.06.2018	196,81	193,10	197,28	192,91	19,12M	2,29%
13.06.2018	192,41	192,74	194,50	191,91	15,85M	0,01%
12.06.2018	192,40	192,17	193,28	191,56	11,56M	0,45%
11.06.2018	191,54	188,81	192,60	188,80	12,93M	1,29%
08.06.2018	189,10	187,53	189,48	186,43	12,68M	0,49%
07.06.2018	188,18	190,75	190,97	186,77	21,50M	-1,65%
06.06.2018	191,34	191,03	192,53	189,11	22,56M	-0,83%
05.06.2018	192,94	194,30	195,00	192,62	15,54M	-0,18%
04.06.2018	193,28	191,84	193,98	191,47	18,94M	-0,37%
01.06.2018	193,99	193,06	194,55	192,07	17,31M	1,15%
31.05.2018	191,78	187,87	192,72	187,48	30,78M	2,19%
30.05.2018	187,67	186,54	188,00	185,25	13,74M	1,04%
29.05.2018	185,74	184,34	186,81	183,71	16,40M	0,44%
25.05.2018	184,92	186,02	186,33	184,45	10,97M	-0,54%
24.05.2018	185,93	185,88	186,80	185,03	12,35M	-0,52%
23.05.2018	186,90	182,50	186,91	182,18	16,63M	1,69%
22.05.2018	183,80	184,93	185,42	183,43	12,73M	-0,37%
21.05.2018	184,49	183,77	185,30	183,13	13,53M	0,99%
En Yüksek: 203,54	En Düşük: 182,18	Fark: 21,36	Ortalama: 191,26	Fark %: 11,08		

Tablo 3.6. FB firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0) with drift	
Coefficients:	
	<i>drift</i>
	-0.8781
<i>s.e.</i>	0.4746
Sigma^2 estimated as 4.969: log likelihood = -46.11	
AIC=96.23	AICc=96.9 BIC=98.32

Yorum: Tablo 3.5’de verilen FB firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.6’ daki uygulama sonucunda en optimal çözümü için en minimum ifadeyi veren AIC=96.23 değeri olmuştur.

Tablo 3.7. ORCL firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	42,78	43,57	44,77	42,59	40,55M	-7,54%
19.06.2018	46,27	45,84	46,41	45,77	22,76M	-0,54%
18.06.2018	46,52	45,82	46,60	45,46	21,47M	0,52%
15.06.2018	46,28	45,87	46,49	45,19	28,12M	0,83%
14.06.2018	45,90	47,01	47,02	45,66	37,00M	-4,91%
13.06.2018	48,27	48,11	48,67	48,09	18,05M	-0,37%
12.06.2018	48,45	48,21	48,59	48,16	14,71M	0,54%
11.06.2018	48,19	48,15	48,39	47,97	12,52M	0,02%
08.06.2018	48,18	47,41	48,38	47,41	14,52M	1,05%
07.06.2018	47,68	47,93	48,03	47,42	13,71M	-0,15%
06.06.2018	47,75	47,42	47,80	47,10	13,30M	1,32%
05.06.2018	47,13	47,33	47,42	46,80	13,43M	-0,40%
04.06.2018	47,32	47,48	47,57	47,23	12,18M	-0,06%
01.06.2018	47,35	47,08	47,36	46,90	10,86M	1,35%
31.05.2018	46,72	46,93	47,17	46,71	13,06M	-0,70%
30.05.2018	47,05	46,63	47,23	46,43	11,91M	1,71%
29.05.2018	46,26	46,55	46,80	46,03	12,43M	-1,57%
25.05.2018	47,00	46,49	47,16	46,48	11,35M	1,16%
24.05.2018	46,46	46,66	46,94	46,14	12,50M	-0,94%
23.05.2018	46,90	46,08	46,97	46,02	9,20M	1,14%
22.05.2018	46,37	47,24	47,54	46,31	18,51M	-1,78%
21.05.2018	47,21	46,53	47,28	46,49	13,42M	1,92%
En Yüksek: 48,67	En Düşük: 42,59	Fark: 6,08	Ortalama: 46,91	Fark %: -7,64		

Tablo 3.8. ORCL firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(1,0,0) with non-zero mean		
Coefficients:		
	<i>arl</i>	<i>mean</i>
	0.7089	46.5636
<i>s.e</i>	0.2282	0.7245
Sigma^2 estimated as 1.067: log likelihood = -31.23		
AIC=68.45	AICc=69.79	BIC=71.73

Yorum: Tablo 3.7’de verilen ORCL firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.8’deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC= 68.45 değeri olmuştur.

Tablo 3.9 CSCO firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	43,85	43,84	43,99	43,70	11,81M	0,07%
19.06.2018	43,82	43,62	44,02	43,44	22,20M	-0,88%
18.06.2018	44,21	43,87	44,42	43,39	17,63M	-0,09%
15.06.2018	44,25	44,36	44,53	43,59	49,38M	-0,98%
14.06.2018	44,69	44,23	44,81	44,05	24,02M	1,55%
13.06.2018	44,01	44,02	44,53	43,84	24,38M	0,16%
12.06.2018	43,94	43,68	43,95	43,47	17,56M	0,57%
11.06.2018	43,69	43,62	43,92	43,44	15,07M	0,48%
08.06.2018	43,48	43,52	43,73	43,31	18,81M	-0,39%
07.06.2018	43,65	44,24	44,39	43,35	19,72M	-1,38%
06.06.2018	44,26	43,76	44,31	43,66	17,73M	1,35%
05.06.2018	43,67	43,74	43,75	43,39	16,73M	0,21%
04.06.2018	43,58	43,50	43,83	43,21	18,09M	-0,18%
01.06.2018	43,66	42,91	43,69	42,88	18,35M	2,22%
31.05.2018	42,71	42,86	43,13	42,61	31,44M	-0,33%
30.05.2018	42,85	43,08	43,34	42,83	22,50M	-0,28%
29.05.2018	42,97	42,76	43,16	42,52	25,20M	-0,67%
25.05.2018	43,26	43,46	43,62	43,21	15,36M	-0,71%
24.05.2018	43,57	43,60	43,97	43,01	18,38M	-0,25%
23.05.2018	43,68	43,40	43,70	42,89	20,64M	0,07%
22.05.2018	43,65	43,79	43,91	43,48	16,38M	-0,23%
21.05.2018	43,75	43,49	43,94	43,42	21,79M	1,25%
En Yüksek: 44,81	En Düşük: 42,52	Fark: 2,29	Ortalama: 43,69	Fark %: 1,48		

Tablo 3.10. CSCO firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0)

Sigma^2 estimated as 0.1346: log likelihood = -8.74

AIC=19.47 AICc=19.68 BIC=20.52

Yorum: Tablo 3.9’da verilen CSCO firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.10’daki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=19.47 değeri olmuştur.

Tablo 3.11. EBAY firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	39,33	39,48	39,53	38,96	2,35M	0,38%
19.06.2018	39,18	38,32	39,30	38,28	7,19M	0,82%
18.06.2018	38,86	38,50	39,03	38,34	10,08M	-0,08%
15.06.2018	38,89	38,92	39,01	38,43	12,89M	-0,28%
14.06.2018	39,00	39,52	39,67	38,95	9,35M	-0,84%
13.06.2018	39,33	40,25	40,27	38,87	14,04M	-2,77%
12.06.2018	40,45	40,63	40,75	40,30	8,58M	-0,10%
11.06.2018	40,49	40,27	40,76	40,08	5,21M	0,50%
08.06.2018	40,29	40,26	40,41	39,91	6,07M	-0,40%
07.06.2018	40,45	40,06	40,86	39,84	11,57M	1,25%
06.06.2018	39,95	40,07	40,11	39,30	6,99M	-0,22%
05.06.2018	40,04	39,23	40,47	39,22	11,22M	2,48%
04.06.2018	39,07	38,47	39,12	38,39	8,12M	1,90%
01.06.2018	38,34	38,06	38,85	37,91	7,83M	1,64%
31.05.2018	37,72	37,78	37,81	37,18	10,71M	-0,34%
30.05.2018	37,85	37,78	38,12	37,53	7,91M	0,85%
29.05.2018	37,53	37,73	37,88	37,36	8,31M	-1,08%
25.05.2018	37,94	37,84	38,29	37,80	8,74M	0,40%
24.05.2018	37,79	38,03	38,24	37,63	6,26M	-0,66%
23.05.2018	38,04	37,61	38,05	37,47	7,35M	0,71%
22.05.2018	37,77	38,40	38,49	37,69	9,14M	-1,36%
21.05.2018	38,29	38,49	38,81	38,19	6,60M	-0,08%
En Yüksek: 40,86	En Düşük: 37,18	Fark: 3,68	Ortalama: 38,94	Fark %: 2,64		

Tablo 3.12. EBAY firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0)

Sigma^2 estimated as 0.2096: log likelihood = -13.39

AIC=28.78 AICc=28.99 BIC=29.82

Yorum: Tablo 3.11’de verilen EBAY firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.12’deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=28.78 değeri olmuştur.

Tablo 3.13 VMW firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	152,75	152,00	153,80	151,34	666,02K	0,99%
19.06.2018	151,25	149,08	151,43	147,59	1,15M	-0,13%
18.06.2018	151,44	148,71	151,74	147,65	1,17M	0,65%
15.06.2018	150,46	149,94	151,56	148,62	1,60M	0,14%
14.06.2018	150,25	151,09	153,20	149,41	1,41M	-0,36%
13.06.2018	150,79	148,99	152,62	148,90	1,89M	1,70%
12.06.2018	148,27	149,29	150,08	148,11	953,63K	-0,69%
11.06.2018	149,30	149,60	150,48	148,49	1,15M	-0,23%
08.06.2018	149,64	149,89	152,49	148,81	1,88M	-0,42%
07.06.2018	150,27	148,50	150,72	146,57	3,04M	0,87%
06.06.2018	148,98	148,20	149,00	146,41	1,87M	0,99%
05.06.2018	147,52	142,89	149,00	142,67	2,68M	3,46%
04.06.2018	142,59	144,99	145,00	140,34	2,81M	-2,29%
01.06.2018	145,93	144,97	149,48	143,39	4,27M	6,15%
31.05.2018	137,48	137,74	139,33	136,78	2,91M	-0,39%
30.05.2018	138,02	136,87	139,12	136,50	1,91M	1,19%
29.05.2018	136,40	135,54	136,87	134,82	1,48M	-0,04%
25.05.2018	136,45	136,83	137,92	136,45	1,41M	-0,23%
24.05.2018	136,77	138,44	138,90	136,55	2,01M	-1,06%
23.05.2018	138,23	135,36	138,42	135,10	1,58M	1,05%
22.05.2018	136,80	139,32	140,26	136,59	1,70M	-1,36%
21.05.2018	138,69	140,39	141,37	136,96	2,28M	-0,22%
En Yüksek: 153,80	En Düşük: 134,82	Fark: 18,98	Ortalama: 144,92	Fark %: 9,90		

Tablo 3.14. VMW firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(1,1,0) with drift		
Coefficients:		
	<i>arl</i>	<i>mean</i>
	-0.4932	-0.6976
<i>s. e</i>	0.1874	0.3117
Sigma^2 estimated as 4.867: log likelihood = -45.5		
AIC=97	AICc=98.41	BIC=100.13

Yorum: Tablo 3.13’de verilen VMW firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.14’deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=97 değeri olmuştur.

Tablo 3.15. HPQ firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	23,43	23,58	23,68	23,42	2,90M	-0,38%
19.06.2018	23,52	23,31	23,57	23,16	8,86M	-0,55%
18.06.2018	23,65	23,37	23,75	23,30	5,55M	0,25%
15.06.2018	23,59	23,70	23,70	23,44	13,02M	-0,88%
14.06.2018	23,80	23,63	23,99	23,63	8,24M	1,10%
13.06.2018	23,54	23,62	23,75	23,54	8,07M	-0,34%
12.06.2018	23,62	23,99	23,99	23,55	6,09M	-1,62%
11.06.2018	24,01	23,68	24,20	23,65	9,15M	1,27%
08.06.2018	23,71	23,40	23,75	23,40	6,78M	0,68%
07.06.2018	23,55	23,53	23,70	23,37	9,29M	0,17%
06.06.2018	23,51	23,52	23,60	23,18	10,13M	0,38%
05.06.2018	23,42	22,84	23,50	22,78	14,28M	2,99%
04.06.2018	22,74	22,70	22,83	22,60	8,17M	0,26%
01.06.2018	22,68	22,14	22,71	22,11	9,23M	2,95%
31.05.2018	22,03	22,11	22,32	21,96	15,18M	-0,59%
30.05.2018	22,16	22,39	22,48	21,04	18,18M	4,04%
29.05.2018	21,30	21,74	21,77	21,20	13,56M	-2,78%
25.05.2018	21,91	21,86	21,98	21,80	7,73M	-0,05%
24.05.2018	21,92	21,80	21,98	21,44	8,29M	0,09%
23.05.2018	21,90	21,87	21,90	21,55	9,86M	-0,77%
22.05.2018	22,07	22,12	22,26	22,01	8,68M	-0,09%
21.05.2018	22,09	22,34	22,34	22,00	6,35M	-0,23%
En Yüksek: 24,20	En Düşük: 21,04	Fark: 3,16	Ortalama: 22,92	Fark %: 5,83		

Tablo 3.16. HPQ firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0)
Sigma^2 estimated as 0.1177: log likelihood = -7.33
AIC=16.66 AICc=16.87 BIC=17.7

Yorum: Tablo 3.15’de verilen HPQ firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.16’daki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=16.66 değeri olmuştur.

Tablo 3.17. GILD firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	71,41	70,90	71,57	70,36	3,43M	0,66%
19.06.2018	70,94	68,46	70,99	68,16	8,63M	2,72%
18.06.2018	69,06	69,77	69,94	68,92	6,57M	-1,67%
15.06.2018	70,23	71,10	71,41	69,91	11,52M	-1,29%
14.06.2018	71,15	71,00	71,62	70,51	5,23M	-0,20%
13.06.2018	71,29	71,90	71,98	71,00	5,08M	-0,54%
12.06.2018	71,68	71,76	71,98	70,99	6,98M	-0,21%
11.06.2018	71,83	71,79	72,00	71,11	5,43M	-0,11%
08.06.2018	71,91	71,45	72,28	71,35	5,84M	0,01%
07.06.2018	71,90	71,88	71,95	71,10	7,60M	-0,10%
06.06.2018	71,97	70,17	71,97	69,69	12,38M	2,73%
05.06.2018	70,06	70,25	70,73	69,27	7,82M	-0,21%
04.06.2018	70,21	68,19	70,80	67,95	11,73M	2,80%
01.06.2018	68,30	67,62	68,43	67,52	5,13M	1,34%
31.05.2018	67,40	68,10	68,15	67,21	12,45M	-0,43%
30.05.2018	67,69	67,66	67,79	67,31	5,93M	0,53%
29.05.2018	67,33	67,00	67,56	66,71	7,82M	-0,07%
25.05.2018	67,38	67,65	67,93	67,00	4,86M	-0,22%
24.05.2018	67,53	68,04	68,29	67,08	4,89M	-0,94%
23.05.2018	68,17	67,36	68,38	67,35	5,09M	0,50%
22.05.2018	67,83	67,97	68,69	67,51	6,21M	0,30%
21.05.2018	67,63	68,15	68,57	67,25	6,01M	-0,57%
En Yüksek: 72,28	En Düşük: 66,71	Fark: 5,57	Ortalama: 69,68	Fark %: 4,98		

Tablo 3.18. GILD firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0)

Sigma^2 estimated as 0.7197: log likelihood = -26.34

AIC=54.68 AICc=54.89 BIC=55.73

Yorum: Tablo 3.17’de verilen GILD firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.18’deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=54.68 değeri olmuştur.

Tablo 3.19. ISRG firmasının bir aylık hisse senedi verileri

Tarih	Şimdi	Açılış	Yüksek	Düşük	Hac.	Fark %
20.06.2018	489,19	492,00	494,00	488,70	221,91K	0,12%
19.06.2018	488,60	486,87	488,81	483,16	611,21K	-0,42%
18.06.2018	490,67	488,72	491,99	485,35	683,37K	0,04%
15.06.2018	490,49	494,49	496,00	489,64	1,10M	-1,02%
14.06.2018	495,52	492,37	496,61	492,37	1,06M	1,03%
13.06.2018	490,47	495,00	496,92	487,50	766,51K	-0,90%
12.06.2018	494,92	491,69	496,23	488,63	711,04K	0,86%
11.06.2018	490,71	484,60	494,35	483,90	781,16K	1,26%
08.06.2018	484,60	485,00	488,40	480,41	611,43K	-0,15%
07.06.2018	485,34	493,00	493,00	476,23	880,59K	-1,63%
06.06.2018	493,38	493,00	494,07	484,38	973,27K	0,21%
05.06.2018	492,37	478,00	493,41	476,19	1,76M	3,02%
04.06.2018	477,93	480,00	484,12	472,58	1,01M	-0,28%
01.06.2018	479,25	461,81	480,00	459,43	1,22M	4,26%
31.05.2018	459,67	460,00	466,44	458,56	2,05M	0,00%
30.05.2018	459,66	456,20	465,56	455,18	1,08M	1,11%
29.05.2018	454,63	453,29	455,10	449,64	871,22K	-0,42%
25.05.2018	456,56	459,36	461,06	452,75	651,73K	-0,27%
24.05.2018	457,79	459,22	461,25	454,25	472,00K	-0,20%
23.05.2018	458,71	450,00	459,22	450,00	546,47K	0,90%
22.05.2018	454,61	464,00	464,85	453,79	712,41K	-1,89%
21.05.2018	463,38	462,10	467,40	459,66	553,03K	1,00%
En Yüksek: 496,92	En Düşük: 449,64	Fark: 47,28	Ortalama: 477,66	Fark %: 6,63		

Tablo 3.20. ISRG firmasının bir aylık hisse senedi verilerinin AR programı uygulama sonuçları

ARIMA(0,1,0)

Sigma^2 estimated as 43.6: log likelihood = -69.43

AIC=140.86 AICc=141.07 BIC=141.91

Yorum: Tablo 3.19’da verilen GILD firmasının bir aylık şimdiki verileri göz önüne alınarak AR programında uygulanan bilgi kriterlerinde Tablo 3.20’deki uygulama sonucunda, en optimal çözüm için en minimum ifadeyi veren AIC=140.86 değeri olmuştur.

4. SONUÇ

Silikon Vadisinin ilk on büyük şirketlerine ait bir aylık süreçte, günlük hisse senedi verilerine dayalı AR programındaki uygulamasında, AIC, BIC ve AICc bilgi kriteriyle yapılan analizlerin sonuçları verilmiştir. On büyük şirketin hepsinde de AIC bilgi kriterinin en düşük sonuçları ortaya koyduğu gözlemlenmiştir. Kurulacak modellerde en düşük değerlerden başlayarak yüksek değerler veren ifadelerle doğru, model parametrelerinde göz önüne alınması ile modelin optimallliği sağlanabilir. AIC en küçük değerlerinden en yüksek değerlerine doğru sıralanışı; HPQ –CSCO-EBAY-GILD-INTC-ORCL-APPL-FB-VMW-ISRG şeklindedir. Veriler arasında etkileşimler dikkate alınmadığından yani model karmaşıklığı göz ardı edildiğinden sonuçların güvenilirlikleri tartışmalı olabilir. Model karmaşıklığını da ele alan ICOMP tipi kriterlerin kullanılması daha sağlam sonuçlar vereceği, yapay zekanın alt kollarından olan Genetik Algoritma optimizasyon teknikleriyle model değerlendirme sırasında daha doğru kestirimler ortaya konulacağı ve buna benzer veya farklı tekniklerle sonuçların güvenilirlikleri artırılabilir.

KAYNAKLAR

- [1] **Orhunbilge, N.**2002.Uygulamalı Regresyon Ve Korelasyon Analizi, İ.Ü. İşletme Fakültesi, İstanbul.
- [2] **Johnson, R. A. & Bhattacharyya, H. K.** 2006. Statistics: Principles and Methods.USA: John Wiley & Sons.
- [3] **Özkan,S.** 2018. “Silikon Vadisi” İnternet Sitesi:Wikiyours Makaleleri, erişim yılı 26.04.2018.
- [4] **Ünsal, S.**2014. “Silikon Vadisi ve Girişimcilik”.
- [5] **NVCA Yearbook** 2012.–Webrazzi Türkiyede’ki 2012 Yatırımları
- [6] **Halo Raporu** –Silicon Valley Bank
- [7] **Secrets of Silicon Valley** : What Everyone Can Learn From the Innovation Capital of World.
- [8] **Çelik, Ş.**2013 “Zaman Serileri Analizi ve Trafik Kazası Verilerine Uygulanması”. ANKARA
- [9] **Sandy, R.** 1990. Statistics for Business and Economics, Mc-Graw- Hill.C.USA
- [10] **Akgül,I.** 2003. Zaman Serilerinin Analizi ve ARIMA Modelleri. İstanbul:DERYayınları
- [11] **Kaya, L.&Doğan, Z. & Binici, T.**2015 “Durağan Olmayan Zaman Serilerinde Alternatif Tahmin Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi; Pamuk Fiyat Analizi”, Erzurum.
- [12] **Jang, J.S.R.** 1993. "ANFIS Adaptive-Network-Based Fuzzy Inference Systems," Man, And Cybernetics, Vol. 23, No. 3, May, 665-685
- [13] **Demirel, Ö. & Kakilli, A. &Tektaş,M.**2010. “ANFİS ve ARMA Modelleri İle Elektrik Enerjisi Yük Thmini”. İSTANBUL
- [14] **Dagum, E. B. & Giannerini, S.** 2006. A Critical Investigation On Detrending Procedures For Non Linear Processes. Journal of Macroeconomics, Elsevier, Vol. 28(1), 175-191.
- [15] **Aydın, D., İşçi, Ö.**2012. “Doğrusal Olmayan Otoregresif Zaman Serileri Modellerinin Kestirimi” . Muğla
- [16] **Ataseven,B.**2007.Satış Öngörü ModellemesiTekniğiOlarak Yapay Sinir Ağlarının Kullanımı: “Petkim’de Uygulanması”.(Yayımlanmamış Yüksek Lisans Tezi).Manisa: Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü.
- [17] **Hamzaçebi, C. & Kutay, F.**2004. “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, Mühendislik Mimarlık Fakültesi Dergisi,Endüstri Mühendisliği Bölümü, Gazi Üniversitesi, Ankara, 227-233.
- [18] **Whittle P.** 1951 Hypothesis Testing in Time Series Analysis.
- [19] **Box, G.E.P. & Jenkins, G.M.** 1970.*Time Series Analysis: Forecasting and Control*, Holden-Day, London

- [20] **Özmen, A.** 1989. Mevsimler Dalgalanmalar içermeyen Zaman Serilerinde Kısa Dönem Öngörü Amaçlı Box-Jenkins (ARIMA) Modellerinin Kullanımı, Fen-Edebiyat Fakültesi Dergisi, 2(1):105-120.
- [21] **Kutlar, A.**2005. Uygulamalı Ekonometri, 2. Baskı, Nobel Yayınları, Ankara
- [22] **Akmut, Ö., Aktaş, R., Binay, S. B.** 1999. Öngörü Teknikleri ve Finans Uygulamaları, 1. Baskı, SBF yayını:584, Ankara.
- [23] **Makridakis, S. & Wheelwright, S.C.** 1989. Forecasting Methods for Management, Fifth Edition, John Wiley & Sons USA.
- [24] **Benli, K.**2014. “Altın Fiyatının Zaman Serisi Yöntemleri ve Yapay Sinir Ağları İle Öngörüsü”.Ankara.
- [25] **Brockwell, P. J. & Davis, R.A.** 1996. Introduction time series and forecasting. Springer Texts in Statistics, Springer Verlag New York Inc., 35.
- [26] **Arsham, H.** 2000. Time Critical Decision Making for Bussiness Administration.
- [27] **Cryer, J. D.**1986. Time series analysis. PWS Publishing, USA, pp. 52-110.
- [28] **Günay, S. & Eğrioğlu E. & Aladağ, Ç.H.**2007. Tek değişkenli zaman serileri analizine giriş. Hacettepe Üniversitesi Yayınları, Ankara, 77.
- [29] **Akdi, Y.**2010. Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon). Gazi Kitabevi, Ankara, 27.
- [30] **Sevüktekin M., Nargeleçekenler M.** 2010. Ekonometrik Zaman Serileri Analizi: Eviews Uygulamalı. İstanbul.
- [31] **Özari, Ç.**2013. Zaman Serileri Analizi: Ekonometri Kitabı Bölüm: 13.İstanbul.
- [32] **Konishi, S. & Kitagawa, G.**2008. Information Criteria and Statistical Modeling
- [33] **Akbilgiç, O.** 2011. Hibrit Radyal Tabanlı Fonksiyon Ağları İle Değişken Seçimi ve Tahminleme : Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama. Doktora tezi. İstanbul Üniversitesi Sosyal Bilimler Enstitüsü. İstanbul
- [34] **Bozdoğan, H.** 2004. Intelligent Statistical Data Mining with Information Complexity and Genetic Algorithms. H. Bozdoğan içinde, Statistical Data Mining and Knowledge Discovery (s. 15-56). Florida: Chapman and Hall/CRC.
- [35] **Linhart, H. & Zucchini, W.**1986. Finite sample selection criteria for multinomial models. Statistische Hefte.
- [36] **Burnham, K. P., & Anderson, D. R.** (2002). Model selection and multimodel inference: A practical information-theoretic approach (2nd ed.). New York, NY: Springer-Verlag.
- [37] **Boyce, D. E. & Farhi, A. & Weischedel, R.** 1974. Optimal Subset Selection: Multiple Regression, Interdependence, and Optimal Network Algorithms. New York: Springer Verlag.
- [38] **Wilkinson, L.** 1989. Systat: The System for Statistics. Evanston, IL: SYSTAT.
- [39] **Sokal, R. R. & Rohlf, F. J.** 1981. Biometry (2 b.). New York: W.H. Freeman Company.

- [40] **Akaike, H.** 1973. Information Theory and An Extension of The Maximum Likelihood Principle. B. Petrox, & F. Csaki (Dü.), Second International Symposium on Information Theory içinde (s. 267-281). Budapest: Academiai Kiado.
- [41] **Akaike, H.** 1974. A New Look at the Statistical Model Identification. IEEE Transactions on Automatic Control , AC-19, 716-723.
- [42] **Akaike, H.** 1981. Modern Development of Statistical Methods. P. Eykhoff içinde, Trends and Progress in System Identification (s. 169-184). New York: Pergamon Press.
- [43] **Schwartz, G.** 1978. Estimating The Dimension of Model. Annals of Statistics , 6, 461-464.
- [44] **Hannan, E. J. & Quinn, B. G.**1979. The Determination of the Order of an Autoregression. Journal of the Royal Statistical Society B , 41, 190-195
- [45] **Bozdogan, H.** 1987. Model Selection and Akaike's Information Criterion (AIC): The General Theory and It's Analytical Extension. Journal of Mathematical Psychology , 5, 345-370.
- [46] **Bozdogan, H.** 1988. ICOMP: A New Model-Selection Criteria. H. Bock içinde, Classification and Related Methods of Data Analysis. North-Holland.
- [47] **Bozdogan, H.** 1994. Mixture-Model Cluster Analysis Using A New Informational Complexity and Model Selection Criteria
- [48] **Bozdogan, H.** 2000. Akaike's Information Criterion and Recent Developments in Informational Complexity. Journal of Mathematical Psychology , 44, 62-91.
- [49] **Liu, Y.** 2007. Robust and Misspecification Resistant Model Selection in Regression Models with Information Complexity and Genetic Algorithm. Doktora Tezi. University of Tennessee. Knoxville/USA.
- [50] **Ucal, M.**2006. Ekonometrik Model Seçim Kriterleri Üzerine Kısa Bir İnceleme, İstanbul
- [51] **Çetinkaya, O. Z.**2011. “ Belirsizliğin Ölçülmesi ve Entropi”. İSTANBUL
- [52] **Wang, Q. A.** 2008. Probability distribution and entropy as a measure of uncertainty. Journal of Physics A: Mathematical and Theoretical , 41 (6), 1-12.
- [53] **Shannon, C.E.** 1948. Prediction and entropy of printed English. The Bell System Technical Journal, 30, 50-64.
- [54] **Erbaş, Ü.**2010. “Entropi İlkelerinin Boyut İndirgeme Uygulamaları”. Doktora tezi. Marmara Üniversitesi Sosyal Bilimler Enstitüsü. İstanbul.
- [55] **Pamukçu, E.**2015. Yüksek Boyutlu Kanser Sınıflama Probleminde Bilgi Karmaşıklığı Kriteri İle Aykırı Gözlem Tespiti Ve Boyut İndirgeme” . Doktora TEZİ. ELAZIĞ
- [56] **Deniz, E.** 2007. Yapısal Eşitlik Modellerinde Bilgi Kriterleri. İstanbul: Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Ana Bilim Dalı, Basılmamış Doktora Tezi.
- [57] **Kullback, A. & Leibler, R.**1951. On Information and Sufficiency. Annals of Mathematical Statistics , 22, 79-86.

- [58] **Bromideh, A.A. & Valizadeh, R.** 2013. Discrimination between Gamma and Log-Normal Distributions by Ratio of Minimized Kullback-Leibler Divergence. *Pakistan Journal of Statistics and Operation Research*, 9(4).
- [59] **Howe, J. A.** 2007. A New Generaion of Mixture-Model Cluster Analysis with Information Complexity and the Genetic Algorithm. Tennessee: The University of Tennessee.
- [60] **Kotz, S. & Johnson, N. L.** 1982. *Encyclopedia of Statistics Sciences* (3b.). John Wiley&Sons
- [61] **Williams, J.L.& Bozdogan, H.& Aiman-Smith, L.** 1995. *Inference Problems with Equivalent Models*. (A. G. Macoulides, & R.E. Scgumaker, Dü) New Jersey: Lawrence Erlbaum Associates.
- [62] **Yamane, T.** 1973. *Statistics: An Introductory Analysis*. USA: Harper&Row Publishers
- [63] **Berk, R.A.** 2004. *Regression Analysis: A Constructive Critique*. USA: Sage Publication.
- [64] **Gujarati, D.** 2003. *Basic Econometrics*, McGraw Hill, Singapure.
- [65] **Theil, H. (1967).** *Economics and Information Theory*. Amsterdam: North Holland.
- [66] **Burham, K.P. & Anderson, D.R.** 1998. *Model Selection an Inference: A Practical Information Theoric Approach*, Springer-Verlag, New York.
- [67] **Bhansali, R. J.& Downham, D. Y.** 1977. Some Properties of the Order of Autoregresice Model Selected vy a Genaralization of Akaike's EPF Criterion. *Biometrica* , 64 (3), 547-551
- [68] **Rissanen, J.** 1978. Modelling by Shortest Data Description. *Automatica* , 14, 465-471.
- [69] **Kullback, S.** 1968. *Information Theory and Statistics*. Dover . New York.
- [70] **Harris, C. J.** 1978. An Information Theoretic Approach to Estimation. M. ,J. Gregson (ed.) In *Recent Theoretical Developments in Control*. Academic Press. London.
- [71] **Watanable, S.** 1985. *Pattern Recognition : Human and Mechanical*. John Wiley and Sons. New York.
- [72] **Bozdogan, H.** 1990. On the information-based measure of covariance complexity and its application to the evaluation of multivariate linear models. *Communications in Statistics, Theory and Methods*.
- [73] **Van Emden, M.H.** 1971. *An Analysis of Complexity*. Amsterdam: Mathematisch Centrum Amsterdam
- [74] **Bozdogan, H. & Howe, J.,A.** 2012. Misspecified multivariate regression models using the genetic algorithm and information complexity as the fitness function. *European Journal of Pure and Applied Mathematics*

ÖZGEÇMİŞ

1991 yılında Elazığ'da doğan Alev Kaya, ilk orta ve lise öğrenimini Elazığ'da tamamladıktan sonra 2009 yılında Fırat Üniversitesi İstatistik Bölümünü kazanmıştır. 2013 yılında mezun olan Kaya, 2016 yılında Fırat Üniversitesi İstatistik Bölümü İstatistiksel Bilgi Sistemleri Anabilim Dalında Yüksek Lisans Eğitimine başladı. Halen devam etmektedir.

