



YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

özel bir bankanın kredileri ile mevd..

Yüksek Lisans Tezi

aslı sabreden

1-21

YILDIZ TEKNİK ÜNİVERSİTESİ
KÜTÜPHANE VE DOKÜMANTASYON
DAİRE BAŞKANLIĞI

Yer No (DDC): R360
10

Kayıt No 3207

Geldiği Yer Feri Arın Enst.

Tarih 7.11.06

Fiyat 4.80

Fatura No

Ayniyat No 1-14

Ek

YILDIZ ÜNİVERSİTESİ

D.B. No: 76738

77011

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ÖZEL BİR BANKANIN KREDİLERİ İLE
MEVDUATLARI ARASINDAKİ BAĞLANTININ
İSTATİSTİK YÖNTEMLERİYLE İNCELENMESİ**

ASLI SABREDEN

FBE İSTATİSTİK PROGRAMINDA HAZIRLANAN

YÜKSEK LİSANS TEZİ

Tez Danışmanı: Prof. Dr. Mehmet Genceli

İSTANBUL, 2006

Mehmet Genceli

*Y. Doç. Dr. H. Taylan
f. Dols*

Doç. Dr. A. Karan Nemlioglu

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	iii
KISALTMA LİSTESİ	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ	vii
ÖNSÖZ	viii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ	1
2. REGRESYON ANALİZİ	2
2.1 Modelin Belirlenmesi	3
2.2 Hata Paylarının Normal Dağılıma Uygun Olup Olmadığının İncelenmesi	7
2.3 Değişen Varyansın İncelenmesi	14
2.3.1 Genelleştirilmiş Farklar Yöntemi	16
2.3.2 Dönüşüm Yöntemi	19
3. YAPAY SİNİR AĞLARI	21
3.1 Yapay Sinir Ağlarının Tanımı	21
3.2 Yapay Sinir Ağlarının Kullanım Alanları	22
3.3 Yapay Sinir Ağlarının Kuramı ve Mimarisi	23
3.4 Yapay Sinir Ağlarının Özellikleri	28
3.5 Yapay Sinir Ağlarının Çeşitleri	29
3.5.1 Çok Katmanlı Yapay Sinir Ağları (MLP)	29
3.5.2 Radyal Temelli Fonksiyon Ağları (RBF)	30
3.5.3 Genelleştirilmiş Regresyon Ağları (GRNN)	31
3.5.4 Olasılık Sinir Ağları (PNN)	32
3.6 Uygulama	33
4. SONUÇ	52
KAYNAKLAR	54
EKLER	56
Ek 1.1 Şubeler Bazında Kredi ve Mevduat Tutarları	57
ÖZGEÇMİŞ	60

SİMGE LİSTESİ

b_j	Eşik değeri
β_0	Regresyon sabiti
β_1	Regresyon katsayısı
$\sqrt{\beta_1}$	Çarpıklık katsayısı
β_2	Basıklık katsayısı
C_j	Gizli katmandaki aktivasyon fonksiyonun merkezi
D	Regresyon katsayısı
e_i	Kalıntı
$F_1(x)$	Birinci sınıfa ait olasılık yoğunluk fonksiyonu
$F_2(x)$	İkinci sınıfa ait olasılık yoğunluk fonksiyonu
h_{ii}	Projeksiyon matrisi
K_1	Birinci sınıf
K_2	İkinci sınıf
L_1	x girdisinin K_1 sınıfına ait iken K_2 olarak yanlış sınıflama oranı
L_2	x girdisinin K_2 sınıfına ait iken K_1 olarak yanlış sınıflama oranı
m_2	İkinci moment
m_3	Üçüncü moment
m_4	Dördüncü moment
p	Parametre sayısı
P_1	Birinci sınıfta görülme olasılığı
P_2	İkinci sınıfta görülme olasılığı
r^2	Belirginlik katsayısı
r_i	Studentize kalıntılar
r_s	Spearman sıra korelasyon katsayısı
$s\sqrt{b_1}$	Çarpıklık katsayısının standart sapması
s_{b_2}	Basıklık katsayısının standart sapması
u	Anakütle hata payı
$Var\sqrt{b_1}$	Çarpıklık katsayısının varyansı
$Varb_2$	Basıklık katsayısının varyansı
v_i	Aktivasyon fonksiyonu
y_i	Çıkış sinyali
σ^2	Varyans
w_i	Ağırlıklar
η	Öğrenme katsayısı
δ_j	Bir nörona ait yerel hata eğitimi

σ_j

Bant genişliği

ρ_s

Anakütle korelasyon katsayısı

KISALTMA LİSTESİ

YSA	Yapay Sinir Ağları	1
MLP	Çok Katmanlı Yapay Sinir Ağları	2
RBF	Radyal Temelli Fonksiyon Ağları	3
GRNN	Genelleştirilmiş Regresyon Ağları	4
PNN	Olasılık Sinir Ağları	7
Şekil 1.2.1	Kalıpların histogram grafiği	11
Şekil 2.1.1	Mevcut ve kredi tutarları	13
Şekil 2.1.2	Öğretici Zorlukları ile kalıpların dağılımı	15
Şekil 2.2.1	Yapay sinirlerin yapısı	16
Şekil 2.2.2	Yapay sinirde katmanların birbiriyle olan ilişkileri	16
Şekil 2.2.3	Tangens-Sigmoid fonksiyonu giriş-çıkış ağırları	23
Şekil 2.2.4	Logaritmik Sigmoid fonksiyonu giriş-çıkış ağırları	26
Şekil 2.2.5	Potansiyel fonksiyonu giriş-çıkış ağırları	26
Şekil 2.6.1	Yapay sinir ağının yapısı	36
Şekil 2.6.2	Yapay sinir ağırları ile yapılan tahmin sonucunda meydana gelen hata miktarları	40
Şekil 2.6.3	Şablonlar göre transfer fonksiyonu sonuçları	43
Şekil 2.6.4	İzole edilmiş kurumsal satış olmadan kurulan yapay sinir ağına girilmesi	45
Şekil 2.6.5	İzole edilmiş kurumsal satış verileri olmadan kurulan yapay sinir ağına girilmesi ile yapılan tahmin sonucunda meydana gelen hata miktarları	49

ŞEKİL LİSTESİ

Şekil 2.1 Şubelere göre mevduat tutarları	2
Şekil 2.2 Şubelere göre kredi tutarları.....	2
Şekil 2.1.1 Mevduat ve kredi tutarları.....	3
Şekil 2.1.2 Regresyon analizi sonucunda öngörülen kredi tutarları ile mevduat tutarları	6
Şekil 2.2.1 Q-Q grafiği	7
Şekil 2.2.2 Kalıntıların histogram grafiği.....	7
Şekil 2.1.1 Mevduat ve kredi tutarları.....	10
Şekil 2.3.1 Öngörü değerleri ile kalıntıların dağılımı	15
Şekil 3.3.1 Yapay nöronun yapısı	24
Şekil 3.3.2 Yapay nöronda katmanların birbirleriyle olan ilişkileri.....	24
Şekil 3.3.3 Tangent-Sigmoid fonksiyonu giriş-çıkış eğrisi.....	25
Şekil 3.3.4 Logaritmik Sigmoid fonksiyonu giriş-çıkış eğrisi	26
Şekil 3.3.5 Purelin fonksiyonu çıkış eğrisi.....	26
Şekil 3.6.1 Yapay sinir ağının şeması	36
Şekil 3.6.2 Yapay sinir ağları ile yapılan tahmin sonucunda meydana gelen hata miktarları..	40
Şekil 3.6.3 Şubelere göre transfer fonksiyonu sonuçları.....	43
Şekil 3.6.4 İstanbul kurumsal şube olmadan kurulan yapay sinir ağının şeması	45
Şekil 3.6.5 İstanbul Kurumsal şubesi verileri olmadan kurulan yapay sinir ağları ile yapılan tahmin sonucunda meydana gelen hata miktarları.....	49

ÇİZELGE LİSTESİ

Çizelge 2.1.1 Regresyon analizi sonucunda hesaplanan kalıntı ve öngörü değerleri.....	4
Çizelge 2.2.1 Studentize kalıntı değerleri	10
Çizelge 3.6.1 Hesaplanan 40 yapay sinir ağının sonuçları.....	34
Çizelge 3.6.2 Yapay sinir ağının regresyon istatistikleri.....	36
Çizelge 3.6.3 Yapay sinir ağı sonucunda hesaplanan tahmin değerleri ve hata miktarları	37
Çizelge 3.6.4 Yapay sinir ağı ile hesaplanan transfer fonksiyonu sonuçları.....	40
Çizelge 3.6.5 İstanbul kurumsal şubesi olmadan hesaplanan yapay sinir ağları.....	43
Çizelge 3.6.6 İstanbul kurumsal şubesi olmadan hesaplanan yapay sinir ağının regresyon istatistikleri.....	45
Çizelge 3.6.7 İstanbul kurumsal şube olmadan oluşturulan yapay sinir ağının tahmin değerleri ve hata miktarları	46
Çizelge 3.6.8 İstanbul kurumsal şube olmadan oluşturan yapay sinir ağının transfer fonksiyonu sonuçları	49
Çizelge Ek 1.1 Şubeler bazında mevduat ve kredi tutarları.....	57

ÖNSÖZ

Bu tezin hazırlanması sırasında öncelikle bana danışmanlık yaparak değerli bilgi ve desteğini esirgemeyen sayın Prof. Dr. Mehmet Genceli hocam başta olmak üzere, tezin başından sonuna kadar her konuda yardımları ve destekleri için eşim Hakan Mustafa Ertem ve Ece Cihan Ertem'e, yoğun çalışmam sırasında anlayış ve desteğinden ötürü aileme çok teşekkür ederim.

Anahtar kelimeler: Regresyon analizi, yapay sinir ağıları, medyan, korelasyon, normallik testleri, güven değerleri.

ÖZET

Günümüzde dayanıklı ve dayanıksız tüketim malları ile konuta olan aşırı talep ister istemez Bankacılık Sektörü'nün ilgisini krediler üzerine yoğunlaştırmıştır. Bunun yanısıra ticari kredilerin de varlığı bankaların verdiği kredileri mercek altına alınmasını gerekli kılmaktadır.

Bu çalışmada, mevduat ile krediler arasındaki bağlantı regresyon analizi ve yapay sinir ağıları yöntemi ile incelenmeye çalışılarak mevduatın yarattığı krediler ile bir analiz yapılmaya çalışılmıştır. Ayrıca her iki yöntemde karşılaştırılarak yapay sinir ağıları yönteminin ad hoc bağıl olarak daha üstün olduğu sonucuna varılmıştır.

Anahtar kelimeler: Regresyon analizi, yapay sinir ağıları, mevduat, krediler, normallik testleri, sapan değerler.

ABSTRACT

In this area, the main focus of Banking has become crediting because of the rise in the appeal of mass consumption and real estate. Besides, the existence of commercial credit makes it necessary to investigate the credit loans given by the banks.

In this works, the relationship between the deposit and credits has been examined with regression analysis and artificial neural network in order to analyze the credits created by deposits. Furthermore, by comparing two methods, it is conclude that artificial neural network is ad hoc superior to the other methods.

Keywords: Regression analysis, artificial neural network, deposits, credits, normality tests, outlier observation.

1. GİRİŞ


Ülkemizde bankaların yabancı ortaklıklar kurması ile finans sektörü büyük bir hareketlilik kazanmıştır. Bankaların en önemli gelir kaynağı kredilerdir. Bankalar rekabeti arttırmak için kredi çeşitlerini çoğaltma ve faiz oranlarını düşürme yoluna gitmişlerdir. Özellikle Mortgage sisteminin Türkiye’de uygulanmaya başlanacak olmasından dolayı konut kredisine talep artmıştır. Bankalar oluşan bu rekabet ortamında gelirlerini arttırmak için, müşterilere daha çabuk ulaşma politikasından yola çıkarak şube sayılarını arttırmaya başlamışlardır. Ortaya çıkan şubeleşme politikası sonucunda, şube yerlerinin belirlenmesi önem kazanmıştır.

Çalışmada Türkiye’de 45 şubesi bulunan özel bir bankanın 2004 yılına ait mevduat miktarları ile kredi miktarları arasındaki bağlantı araştırılmıştır. Şubeler bazında verilen kredi tutarının (bireysel ve kurumsal olarak verilen nakit krediler, nakit dışındaki krediler, yabancı para olarak verilen krediler, ytl olarak verilen krediler ve akreditifler toplamı), topladığı mevduatın bir fonksiyonu olduğu varsayılarak, açıklayıcı değişken olarak mevduat tutarları, açıklanan değişken olarak ise kredi tutarları seçilmiştir.

Çalışmanın ilk bölümünde açıklayıcı değişken mevduat tutarları, açıklanan değişken ise kredi tutarları olmak regresyon analizi uygulanmış, regresyonun temel varsayımları test edilerek şubeler bazında kredi tutarları tahmin edilmiştir. İkinci bölümde ise verilere yapay sinir ağı yöntemi uygulanarak şubeler bazında kredi tutarları tahmin edilmiştir. Son bölümde ise yapılan iki analiz sonucu karşılaştırılmış, kredi tahmininde bulunmak için hangi modelin kullanılmasının daha etkin olacağına karar verilmiştir.


2. REGRESYON ANALİZİ

Şubelerin kredi tutarlarını tahmin etmek için önce regresyon analizi uygulanmıştır. Analizde açıklayıcı değişken olarak 31.12.2004 tarihi itibarıyla şubelerdeki mevduat tutarları, açıklanan değişken olarak ise 31.12.2004 tarihi itibarıyla şubelerin verdiği kredi tutarları kullanılmıştır. Şubeler bazındaki mevduat tutarlarına ilişkin grafik şekil 2.1 de yer almaktadır.



Şekil 2.1 Şubelere göre mevduat tutarları


Şubeler bazındaki kredi tutarlarına ilişkin grafik ise şekil 2.2 de yer almaktadır.



Şekil 2.2 Şubelere göre kredi tutarları

2.1 Modelin Belirlenmesi

En uygun modele karar vermek için öncelikle değişkenlerin birlikte serpilme diyagramına bakılmıştır. Kredi tutarları ile mevduat tutarlarının birlikte dağılımını gösteren ilgili grafik şekil 2.1.1’de görülmektedir.



Şekil 2.1.1 Mevduat ve kredi tutarları

Serpilme diyagramının şeklinden yola çıkarak;

$$Y = \beta_0 + \beta_1 x + u \quad (2.1)$$

şeklinde doğrusal bir regresyon modelinin uygulanabileceği sonucuna varılmıştır.

Regresyon denklemi;

$$\hat{Y} = -20000000 + 1,866 * X \quad r^2 = 0,49 \quad (2.2)$$

(8855779) (0,288)

$$t \quad -1,708 \quad 6,481$$

olarak hesaplanmıştır.

Mevduat tutarlarına ilişkin regresyon katsayısı ise 1,866 olarak tahmin edilmiştir. Bu katsayının t istatistiği 6,481 olarak hesaplanmıştır.

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Hipotez testi için yapılan anlamlılık testinde $t=6,481$ değeri $t_{(0,05;43)} = 1,96$ değerinden büyüktür. Buna göre mevduat ile kredi arasında doğrusal bir bağlantının varlığına hükmedilebilir. Mevduat miktarına ilişkin regresyon katsayısı β_1 için %95 güven aralığı ise $1,286 \leq \beta_1 \leq 2,447$ 'dir. Mevduat tutarındaki 1 birimlik artışın kredi tutarındaki 1,866 birimlik bir artışa neden olduğunu söylenebilir. Belirginlik katsayısı 0,49 olarak hesaplanmıştır. Mevduat tutarları ile kredi tutarlarındaki değişkenliğin %49'u açıklanabilmektedir.


Oluşturulan regresyon denklemi sonucu elde edilen öngörü değerleri ve kalıntılar çizelge 2.1.1'de gösterilmiştir.

Çizelge 2.1.1 Regresyon analizi sonucunda hesaplanan kalıntı ve öngörü değerleri

Şube	Mevduat04	Kredi04	Öngörü	e_i
ADANA	42146998	77817959	63540130,85	14277828,5
ALTUNİZADE	17787153	19903665	18073460,76	1830204,558
AND.KURUMSAL	67090724	137873626	110096591,8	27777034,39
ANKARA	68525253	61801154	112774081,5	50972927,86
ANTAKYA	10690094	14073921	4827085,871	9246835,019
ANTALYA	13784211	22239000	10602129,76	11636870,35
AVCILAR	17456501	23428400	17456311,22	5972088,964
BAKIRKÖY	22990268	775534	27784865,59	27009331,26
BAYRAMPAŞA	17406489	21433903	17362965,78	4070937,695
BORNOVA	16445277	32553931	15568903,35	16985028,02
BURSA	25304477	56008534	32104242,52	23904291,37
CADDEBOSTAN	22021467	1607503	25976637,34	24369134,74
ÇİFTEHAVUZLAR	34710067	3522571	49659397,99	46136826,95
ÇORUM	13727202	3079423	10495725,39	7416302,645

DENİZLİ	27540977	42610101	36278580,46	6331520,282
ESKİŞEHİR	18819501	17285801	20000296,99	2714496,134
ETİLER	24216194	3078780	30073006,18	26994225,98
FINDIKZADE	19564707	25800222	21391193,81	4409028,249
GAZİANTEP	22065106	31008741	26058086,84	4950654,641
GEBZE	12957359	28364507	9058845,296	19305661,81
GÜNEŞLİ	67090724	137873626	110096591,8	27777034,39
HADIMKÖY	19942801	28501186	22096891,1	6404295,1
İKİTELLİ	24822695	33785187	31205016,67	2580170,544
İST.KURUMSAL	63804867	207190688	103963670,7	103227017,2
İZMİR	28856603	57201933	38734142,95	18467790,38
İZMİT	15790661	41587001	14347089,4	27239911,88
KARAKÖY	36853207	30126147	53659482,58	23533335,18
KARŞIYAKA	27789984	2067148	36743341,96	34676193,91
KARTAL	22084258	29639659	26093833,5	3545825,48
KAYSERİ	36160278	50653401	52366158,02	1712756,544
KONYA	11890927	29160713	7068392,407	22092320,33
LEVENT	18323734	37892627	19074968,01	18817659,29
MERTER	18977710	15482016	20295587,56	4813571,476
OSMANBEY	26571502	85800750	34469093,65	51331656,74
SAMSUN	21977596	23766276	25894753,97	2128477,743
SUADİYE	45500231	1311151	69798805,37	68487654,37
SULTANHAMAM	29274903	21512152	39514883,3	18002731,48
ŞANLIURFA	7251119	7875376	1591622,264	9466998,672
TAKSİM	34237937	21694786	48778186,11	27083400,39
TARABYA	20173465	1389093	22527415,43	21138322,66

TOPÇULAR	27691159	16975761	36558888,82	19583127,71
TRABZON	26974826	18813641	35221882,16	16408240,83
TUZLA	4216640	15672537	-7255355,76	22927892,55
ÜMRANİYE	27789520	32103835	36742475,94	4638640,475
YEŞİLKÖY	28732847	1746300	38503157,82	36756858,08



Şekil 2.1.2 Regresyon analizi sonucunda öngörülen kredi tutarları ile mevduat tutarları


Parametrelerin tahmin edilip test sonucunda da anlamlı bulunmaları ve tatmin edici bir belirginlik katsayısına ulaşılması gerek olmakla beraber yeterli değildir. “Kalıntı Analizi” olarak adlandırılan bir yaklaşım içinde kalıntıların incelenerek verilerin homojenliği ve varsayımlardan sapmaların bulunup bulunmadığının incelenmesi sistematik kısmı tamamlamaktadır. *

* Genceli, M., (2001), Ekonometri ve İstatistik İlkeleri, Filiz Kitabevi, İstanbul.

2.2 Hata Paylarının Normal Dağılıma Uygun Olup Olmadığının İncelenmesi

Normal P-P Plot of Regression Standard

Dependent Variable: KREDİ




2.2.1 Q-Q grafiği

Şekil 2.2.1 Q-Q grafiği

Modeldeki hata paylarının normal dağılıp dağılmadığını test etmek için histogramı çizdirilmiş ve çarpıklık, basıklık katsayılarına bakılmıştır. Şekil 2.2.1’de dağılımın normal dağılıma uygun olup olmadığını gösteren Q-Q grafiği yer almaktadır. Bu grafikte kalıntıların çizgiye olan yakınlığı normal dağılıma olan yakınlığını göstermektedir.

Histogram

Dependent Variable: KREDİ



Şekil 2.2.2 Kalıntıların histogram grafiği

Şekil 2.2.2 ‘de kalıntıların histogramı görülmektedir.

Çarpıklık katsayısı $\pm \sqrt{\beta_1}$ simetrik durumdan uzaklaşma derecesini belirlemek için

kullanılır. Çarpıklık katsayısı simetrik bir dağılım için sıfır, sağa eğik dağılımlarda pozitif, sola eğik dağılımlarda negatif değerler almaktadır.

$\sqrt{b_1}$ çarpıklık test istatistiği;

$$\pm \sqrt{b_1} = \frac{m_3}{m_2^{3/2}} = \frac{\sum (X_i - \bar{X})^3 / n}{\left[\sum (X_i - \bar{X})^2 / n \right]^{3/2}} \quad (2.2.1)$$

$$\text{Var} \sqrt{b_1} = \frac{6(n-1)}{(n+2)(n+3)} \quad (2.2.2)$$

$$s_{\sqrt{b_1}} = \sqrt{\frac{6(n-1)}{(n+2)(n+3)}} \quad (2.2.3)$$

şeklinde tanımlanmaktadır.*

$H_0: \sqrt{\beta_1} = 0$ Dağılım simetrik.

$H_1: \sqrt{\beta_1} \neq 0$ Dağılım simetrik değildir.

$\sqrt{b_1} = 0,5962$ $\text{Var} \sqrt{b_1} = 0,1168$ $s_{\sqrt{b_1}} = 0,3418$ olarak hesaplanmıştır. $n=45$ için %95 güven aralığında alt ve üst limitlerin tablo değerleri $(-0,679; +0,679)$ dur. $0,5962 < 0,679$ olduğu için H_0 'ın reddi için yeterli kanıt bulunamamıştır. Dağılım simetrik.

Basıklık katsayısı β_2 ise dağılımın normal dağılıma göre göreceli basıklık veya sivrililiğini belirlemektedir. Normal bir dağılımda basıklık katsayısı 3'tür.

$$b_2 = \frac{m_4}{m_2^2} = \frac{\sum (X_i - \bar{X})^4 / n}{\left[\sum (X_i - \bar{X})^2 / n \right]^2} \quad (2.2.4)$$

$$\text{Var } b_2 = \frac{24n(n-2)(n-3)}{(n+1)^2 (n+3)(n+5)} \quad (2.2.5)$$

* Snedecor, G.W. ve Cochran, W., (1967), Statistical Analysis, Aowa State University Press, Aowa

$$s_{b_2} = \sqrt{\frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}} \quad (2.2.6)$$

olarak tanımlanmaktadır.

$H_0: \beta_2 = 3$ Basıklık ve /veya sivrilik bakımından normal dağılıma uygundur.


$H_1: \beta_2 \neq 3$ Basıklık ve /veya sivrilik bakımından normal dağılıma uygun değildir.

$b_2 = 5,6332$ $\text{Var } b_2 = 2,0609$ $s_{b_2} = 1,4355$ olarak hesaplanmıştır. $n=45$ için %95 güven aralığında alt ve üst limitlerin tablo değerleri (2,02; 4,41) dir. $5,6332 > 4,41$ olduğu için H_0 reddedilir. Dağılım normal dağılıma nazaran daha sivridir.

Bu iki test sonucunda dağılımın simetrik fakat sivri olduğu ortaya çıkmıştır. Bu sonuçlardan yola çıkarak verilerin basıklık bakımından normal dağılmadığına karar verilmiştir.

Regresyon analizine dair yapılan önemli varsayımlardan bir tanesi de oluşturulan modelin tüm veriler için uygun olmasıdır. Uygulamada ise bir ve ya birden çok verinin oluşturulan doğrunun dışında kaldığı belirgin olarak görülür. Verinin geri kalanıyla aynı durumu izlemeyen durumlara “sapan değer” denilir. Kalıntı analizinin önemli işlevlerinden birisi de bu gibi durumları belirlemektir. Sapan değer verileri geniş $\left| \hat{e}_i \right|$ durumları olacaktır. Bütün geniş hata terimleri sapan değer değildir, bazı sapan değerler regresyon değerleri üzerinde daha etkili olabilirler. *

* Weisberg, S., (1985), Applied Linear Regression, John Wiley & Sons, United States of America



Şekil 2.1.1 Mevduat ve kredi tutarları

Şekil (2.1.1)'den de görülebileceği gibi 3 veri diğerlerine nazaran daha yüksek değerlere sahiptir. Bu verilerin sapan değer olup olmadığının araştırılması gerekmektedir.

$$r_i = \frac{e_i}{\sigma \sqrt{1 - h_{ii}}} \quad (2.2.7)$$

(2.2.7)'deki formüle göre student residuals (studentize kalıntı) değerleri hesaplanmıştır. Çizelge 2.2.1'de hesaplanan studentize kalıntı değerleri yer almaktadır.

Çizelge 2.2.1 Studentize kalıntı değerleri

Şube	Tahmin	Hata	Student Residuals
ADANA	63540130,85	14277828,5	0,50448
ALTUNİZADE	18073460,76	1830204,558	0,06416
AND.KURUMSAL	110096591,8	27777034,39	1,06048
ANKARA	112774081,5	50972927,86	-1,96003
ANTAKYA	4827085,871	9246835,019	0,32717

ANTALYA	10602129,76	11636870,35	0,40982
AVCILAR	17456311,22	5972088,964	0,20944
BAKIRKÖY	27784865,59	27009331,26	-0,94367
BAYRAMPAŞA	17362965,78	4070937,695	0,14277
BORNOVA	15568903,35	16985028,02	0,59626
BURSA	32104242,52	23904291,37	0,83466
CADDEBOSTAN	25976637,34	24369134,74	-0,85179
ÇİFTEHAVUZLAR	49659397,99	46136826,95	-1,61581
ÇORUM	10495725,39	7416302,645	-0,2612
DENİZLİ	36278580,46	6331520,282	0,22105
ESKİŞEHİR	20000296,99	2714496,134	-0,09508
ETİLER	30073006,18	26994225,98	-0,94276
FINDIKZADE	21391193,81	4409028,249	0,15434
GAZİANTEP	26058086,84	4950654,641	0,17304
GEBZE	9058845,296	19305661,81	0,68068
GÜNEŞLİ	110096591,8	27777034,39	1,06048
HADIMKÖY	22096891,1	6404295,1	0,22413
İKİTELLİ	31205016,67	2580170,544	0,0901
İST.KURUMSAL	103963670,7	103227017,2	3,88193
İZMİR	38734142,95	18467790,38	0,64489
İZMİT	14347089,4	27239911,88	0,95694
KARAKÖY	53659482,58	23533335,18	-0,8258
KARŞIYAKA	36743341,96	34676193,91	-1,21068

KARTAL	26093833,5	3545825,48	0,12394
KAYSERİ	52366158,02	1712756,544	-0,06006
KONYA	7068392,407	22092320,33	0,78017
LEVENT	19074968,01	18817659,29	0,65939
MERTER	20295587,56	4813571,476	-0,16858
OSMANBEY	34469093,65	51331656,74	1,79212
SAMSUN	25894753,97	2128477,743	-0,0744
SUADIYE	69798805,37	68487654,37	-2,43428
SULTANHAMAM	39514883,3	18002731,48	-0,62871
ŞANLIURFA	1591622,264	9466998,672	0,33712
TAKSİM	48778186,11	27083400,39	-0,94817
TARABYA	22527415,43	21138322,66	-0,73966
TOPÇULAR	36558888,82	19583127,71	-0,68372
TRABZON	35221882,16	16408240,83	-0,57285
TUZLA	-7255355,76	22927892,55	0,82203
ÜMRANIYE	36742475,94	4638640,475	-0,16195
YEŞİLKÖY	38503157,82	36756858,08	-1,2835

Studentize edilmiş kalıntıların -2 değerinden küçük ve 2 değerinden büyük olan değerler sapan değer olarak değerlendirilebilir. Verilerde İstanbul Kurumsal şubesi ve Suadiye şubesi sapan değer olma ihtimali yüksektir. Ankara şubesinin studentize edilmiş kalıntıları da 2 değerine oldukça yakın olduğu için bu noktanın da araştırılması gerekir.

Bu üç değerın sapan değer olup olmadığını test etmek için (2.2.8)'deki formülden yararlanılarak t değerleri hesaplanmıştır.

$$t_i = r_i \left(\frac{n - p^1 - 1}{n - p^1 - r_i^2} \right)^{1/2} = \frac{\hat{e}_i}{\hat{\sigma} \sqrt{1 - h_{ii}}} \quad (2.2.8)$$

İstanbul Kurumsal şubesi için $t = 3,88193 \left(\frac{45 - 2 - 1}{45 - 2 - (3,88193)^2} \right)^{1/2} = 4,76027$ olarak hesaplanmıştır.

Suadiye şubesi için $t = (-2,43428) \left(\frac{45 - 2 - 1}{45 - 2 - (-2,43428)^2} \right)^{1/2} = -2,59095$ olarak hesaplanmıştır.

Ankara şubesi için $t = (-1,96003) \left(\frac{45 - 2 - 1}{45 - 2 - (-1,96003)^2} \right)^{1/2} = -2,1022$ olarak hesaplanmıştır.

$n=45$ için %95 güven aralığında kritik değer 3,50'dir.

İstanbul Kurumsal şube için hesaplanan değer tablo değerinin üstündedir, sapan değerdir. Suadiye ve Ankara şubeleri için hesaplanan değer ise tablo değerinin altında yer almaktadır, sapan değer olarak kabul etmek olası değildir.

İstanbul Kurumsal şubenin regresyon denkleminde etkisi ölçmek amacıyla gösterge değişken kullanılarak

$$Y = \beta_0 + \beta_1 x + \beta_2 D + u \quad (2.2.9)$$

(2.2.9)'da yer alan doğrusal regresyon modeli uygulanmıştır.

$$\hat{Y} = -5832849 + 1,419 * X + 120000000 * D \quad r^2 = 0,81 \quad (2.2.10)$$

$$(7480939) \quad (0,253) \quad (26000000)$$

$$t \quad -0,78 \quad 5,609 \quad 4,76$$

olarak hesaplanmıştır.

İstanbul Kurumsal şubeye ilişkin gösterge değişkenin katsayısı 120000000 olarak tahmin edilmiştir. Bu katsayının t istatistiği 4,76 olarak hesaplanmıştır.

$$H_0 : \beta_2 = 0$$

$$H_1 : \beta_2 \neq 0$$

$t_{(0,05;43)} = 1,96$ 'dır. $4,76 > 1,96$ olduğu için H_0 hipotezini reddedilir. Buna göre kredi tutarları ile İstanbul Kurumsal şubesi arasında doğrusal bir bağlantının varlığına hükmedilebilir.

Gösterge değişken anlamlıdır. İstanbul Kurumsal şubesi için gölge değişken kullanılmalı, İstanbul Kurumsal şubesinin tahmini için ayrı bir regresyon modeli kurulmalıdır. İstanbul Kurumsal şube regresyon modelinin sabitini etkilemekte olup, eğimine herhangi bir etkisi olmadığı söylenebilir.

İstanbul Kurumsal şubenin değerleri veri setinden çıkartılarak kurulan regresyon denklemi sonucu;

$$\hat{Y} = -6000000 + 1,419 * X \quad r^2 = 0,42 \quad (2.2.11)$$

(7480939) (0,253)

t 0,780 5,609

olarak hesaplanmıştır. Burada da (2.2.10) ve (2.2.11) modelleri karşılaştırılırsa; regresyon modellerinin sabitlerinin değiştiği, eğimlerinin ise aynı kaldığı görülmektedir.

İstanbul Kurumsal şubenin değerleri veri setinden çıkarıldığında yeni modelin hata paylarının normal dağılıp dağılmadığı test edilirse;

$H_0: \sqrt{\beta_1} = 0$ Dağılım simetrik.

$H_1: \sqrt{\beta_1} \neq 0$ Dağılım simetrik değildir.

$\sqrt{b_1} = 0,0716$ olarak hesaplanır. $n=45$ için %95 güven aralığında alt ve üst limitlerin tablo değerleri $(-0,679; +0,679)$ dur. $0,0716 < 0,679$ olduğu için H_0 'ın reddi için yeterli kanıt bulunamamıştır. Dağılım simetrik.

$H_0: \beta_2 = 3$ Basıklık ve /veya sivrilik bakımından normal dağılıma uygundur.

$H_1: \beta_2 \neq 3$ Basıklık ve /veya sivrilik bakımından normal dağılıma uygun değildir.

$b_2 = 3,1681$ olarak hesaplanır. $n=45$ için %95 güven aralığında alt ve üst limitlerin tablo değerleri $(2,02; 4,41)$ dir. $3,1684 < 4,41$ olduğu için H_0 'ın reddi için yeterli kanıt bulunamamıştır. Basıklık ve /veya sivrilik bakımından normal dağılıma uygundur.

Çarpıklık test istatistiği ve basıklık test istatistiği değerlerinin sonucunda hata paylarının normal dağıldığı söylenebilir.


2.3 Değişen Varyansın İncelenmesi

Doğrusal regresyon modelinin önemli bir varsayımı da, ana kütle hata paylarına ilişkin

varyansın her alt ana kütle için aynı olmasıdır.

$$E(u_i^2) = \sigma^2 \quad (2.3.1)$$

Değişen varyansın modelde olup olmadığını araştırmak için kalıntıların serpilme diyagramına bakılmıştır.



Şekil 2.3.1 Öngörü değerleri ile kalıntıların dağılımı

Şekil 2.3.1’de kalıntılarla öngörülen değerler için çizilen grafik yer almaktadır. Buradan yola çıkarak değişir varyansın söz konusu olduğunu söyleyebiliriz. Bir diğer seçenek ise verilere Spearman sıra korelasyon testini uygulamaktır. Bu testte kalıntıların mutlak değeri ile bağımsız değişken arasında bir ilişki olup olmadığı araştırılmaktadır.

- $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$ regresyon denklemi elde edilerek kalıntılar, e_i , hesaplanmalıdır.

- Sonra da $|e_i|$ ve x_i ’leri küçükten büyüğe veya büyükten küçüğe doğru sıralamak suretiyle r_s hesaplanmalıdır.

- $n > 8$ olmak koşuluyla

$$H_0 : \rho_s = 0$$

$$H_1 : \rho_s \neq 0$$

testi yapılacaktır.*

Test sonucu 0,509 olarak hesaplanmıştır

$$t = \frac{r_s * \sqrt{n-2}}{1-r_s} \quad (2.3.2)$$

$t = 6,876$ olarak bulunur. Bu değer $t_{(\alpha,n)} = 1,96$ değerinden büyük olduğu için H_0 hipotezi reddedilir, heteroskedastisite mevcuttur.

Heteroskedastisitenin varlığını test etmek için ayrıca verilere Park testi uygulanmıştır. Bu testte kalıntı karelerinin değeri ile bağımsız değişken arasında bir ilişki olup olmadığı araştırılmaktadır.

$$\ln(\hat{u}_i^2) = \ln \sigma^2 + \beta \ln X_i + \nu_i \quad (2.3.3)$$

Kalıntı kareleri bağımlı değişken, mevduat tutarları ise bağımsız değişken olarak alınarak regresyon analizi yapılmış ve aşağıdaki sonuç hesaplanmıştır.

$$\hat{Y} = 5,423 + 1,6 * X \quad r^2 = 0,397 \quad (2.3.4)$$

(9,682) (0,571)

t 0,56 2,801

Mevduat tutarlarına ilişkin regresyon katsayısı ise 1,6 olarak tahmin edilmiştir. Bu katsayının t istatistiği 2,801 olarak hesaplanmıştır.

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Bu değer $t_{(0,05;43)} = 1,96$ değerinden büyüktür. H_0 hipotezi reddedilir. Mevduat tutarları ile kalıntı değerleri arasında doğrusal bir bağlantının varlığına hükmedilebilir. Heteroskedastisite mevcuttur.

Bunun için heteroskedastisitenin düzeltilmesi yoluna gidilmiştir.

2.3.1 Genelleştirilmiş Farklar Yöntemi

Birinci dereceden farklar aslında genelleştirilmiş farklar yönteminin $\rho=1$ için özel bir halidir.

* Genceli, M., (2001), Ekonometri ve İstatistik İlkeleri, Filiz Kitabevi, İstanbul.

Yöntemde Y_t ile Y_{t-1} , X_{jt} ile $X_{j(t-1)}$ $j=1,...,k$ değişkenleri arasındaki farkların belli bir oranına, $(\rho \Delta X_t)$, $(\rho \Delta Y_t)$ 'a E.K.K. uygulanmaktadır. Bu şekilde $\rho < 1$ denklem kapsamına alınarak birinci farkların sakıncaları ortadan kaldırılmaktadır.

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_k X_{kt} + u_t \quad (2.3.1.1)$$

$$Y_{t-1} = \beta_0 + \beta_1 X_{1(t-1)} + \beta_2 X_{2(t-1)} + \dots + \beta_k X_{k(t-1)} + u_{t-1} \quad (2.3.1.2)$$

yazıp (2.3.1.2)'deki ifadeyi ρ ile çarpalım;

$$\rho Y_{t-1} = \rho \beta_0 + \rho \beta_1 X_{1(t-1)} + \rho \beta_2 X_{2(t-1)} + \dots + \rho \beta_k X_{k(t-1)} + \rho u_{t-1} \quad (2.3.1.3)$$

Y_t ile ρY_{t-1} arasındaki fark alınacak olursa;

$$Y_t - \rho Y_{t-1} = \beta_0 - \rho \beta_0 + \beta_1 X_{1(t-1)} + \dots - \rho \beta_k X_{k(t-1)} - u_t - \rho u_{t-1} \quad (2.3.1.4)$$

elde edilir.

$$Y_t' = \beta_0(1 - \rho) + \beta_1 X_{1t} + \beta_2 X_{2(t-1)} + \dots + \beta_k X_{kt} + v_t \quad (2.3.1.5)$$

$$Y_t' = Y_t - \rho Y_{t-1} \quad X_{kt}' = X_{kt} - \rho X_{k(t-1)} \quad v_t = u_t - \rho u_{t-1}$$

Yöntemindeki başka bir farklılık ise ilk değişkenlerin kaybolmayıp Kaidala'nın önerisine uygun olarak $Y_1' = Y_1 \cdot (1 - \rho)^{1/2}$ ve $X_k' = X_k \cdot (1 - \rho)^{1/2}$ dönüşümü ile işlem kapsamına sokulmaktadır. Parais-Winsten işlemi olarak adlandırılan bu dönüşümün amacı $Varu_1' = (1 - \rho)^2 \cdot Varu_1 = \sigma_v^2$ homoskedastisiteyi sağlamaktır. $Y_1' = Y_1 \cdot (1 - \rho)^{1/2}$ olduğuna göre $u_1' = u_1 \cdot \sqrt{1 - \rho^2}$ olacaktır. $(1 - \rho)^{1/2}$ sabittir. Dolayısıyla

$Varu_1' = (1 - \rho)^2 \cdot Varu_1 = \sigma_v^2$ dir. Dönüşüm uygulanmadığı hallerde genelleştirilmiş farklar β 'nın yaklaşık tahminlerini vermektedir. *

Verilere genelleştirilmiş farklar yöntemini uyguladıktan sonra regresyon analizi uygulanmış ve (2.3.1.6)'daki denklem hesaplanmıştır.

* Genceli, M., (2001), Ekonometri ve İstatistik İlkeleri, Filiz Kitabevi, İstanbul.

$$\hat{Y} = 1000000 + 1,368 * X \quad r^2 = 0,457 \quad (2.3.1.6)$$

(4733191) (0,233)

$$t \quad -0,284 \quad 5,871$$

olarak hesaplanmıştır.

Mevduat tutarlarına ilişkin regresyon katsayısı 1,368 olarak tahmin edilmiştir. Bu katsayının t istatistiği 5,871 olarak hesaplanmıştır.

$$H_o : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Hipotez testi için yapılan anlamlılık testinde $t=5,871$ değeri $t_{(0,05,43)} = 1,96$ değerinden büyüktür. Buna göre mevduat ile kredi arasında doğrusal bir bağlantının varlığına hükmedilebilir. Mevduat tutarına ilişkin regresyon katsayısı β_1 için %95 güven aralığı ise $0,897 \leq \beta_1 \leq 1,838$ 'dir. Mevduat tutarındaki 1 birimlik artışın kredi tutarındaki 1,368 birimlik bir artışa neden olduğunu söylenebilir. Belirginlik katsayısı 0,457 olarak hesaplanmıştır. Mevduat tutarları ile kredi tutarlarındaki değişkenliğin %45'ini açıklanabilmektedir.

Salt kredi açısından yeni bir şube açarak mevduatta 1 YTL'lik artış 1,37 YTL'lik marjinal krediye neden olmaktadır. Yeni bir şubenin işletme giderleri ortalama 1 YTL mevduat için 0,36 YTL'lik işletme giderinden düşükse şube açmak avantajlıdır.

Dolayısıyla, toplam mevduatı arttırarak, kredi artışı öngörülse kredilerin bir kısmının tahsil olanağı olmayan kredilerinde olacağı düşünüldüğünde her yerde ve her koşulda şube açmak avantajlı olmamaktadır.

Genelleştirilmiş farklar yöntemi kullanılarak hesaplanan regresyon denkleminde heteroskedastisitenin varolup olmadığını test etmek için Spearman sıra korelasyon testi uygulanmış ve korelasyon katsayısı $r_s = -0,111$ olarak hesaplanmıştır.

$$H_o : \rho_s = 0$$

$$H_1 : \rho_s \neq 0$$

$t = -0,63$ olarak bulunur. Bu değer $t_{(\alpha,n)} = 1,96$ değerinden küçük olduğu için H_o hipotezinin reddi için yeterli kanıt bulunamamıştır, heteroskedastisite yoktur.

Değişen varyansın modelde varolup olmadığını araştırmak için verilere Spearman testinin yanı sıra Park testi de uygulanmıştır.

Yeni modeldeki kalıntı kareleri bağımlı değişken, mevduat tutarları ise bağımsız değişken olarak alınarak regresyon analizi yapılmış ve aşağıdaki sonuç hesaplanmıştır.

$$\hat{Y} = 26,369 + 0,411 * X \quad (2.3.1.7)$$

$$(6,198) \quad (0,388)$$

$$t \quad 4,254 \quad 1,060$$

Mevduat tutarlarına ilişkin regresyon katsayısı ise 0,411 olarak hesaplanmıştır. Bu katsayının t istatistiği 1,060 olarak hesaplanmıştır.

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Bu değer $t_{(0,05;43)} = 1,96$ değerinden küçüktür. H_0 hipotezinin reddi için yeteri kanıt bulunamamıştır. Mevduat tutarları ile kalıntı değerleri arasında bir ilişki yoktur, heteroskedastisite yoktur.

2.3.2 Dönüşüm Yöntemi

Heteroskedastisitenin modelde varolması durumunda verilere dönüşüm uygulanarak heteroskedastisite düzeltilmeye çalışılmaktadır. Öncelikle tüm verilerin logaritmaları alınarak yeni regresyon modeli oluşturulmuştur fakat bu modelde de değişen varyansın sözkonusu olduğu tespit edilmiştir. Hata paylarının varyansının açıklayıcı X'in karesiyle doğru orantılı olduğunu düşünülerek 2.3.2.1'deki model kurulmuştur.*

$$\frac{Y_i}{X_i} = \frac{\beta_0}{X_i} + \frac{\beta_1 X_i}{X_i} + \frac{u_i}{X_i}$$

$$Y'_i = \beta_0 \frac{1}{X_i} + \beta_1 + v_i \quad (2.3.2.1)$$

Verilere dönüşüm yapıldıktan sonra 2.3.2.2'deki regresyon denklemi hesaplanmıştır.

$$\hat{Y}^* = 0,735 + 10000000 * X^* \quad (2.3.2.2)$$

$$(0,211) \quad (3365624)$$

$$t \quad 3,483 \quad 3,003$$

* Gujarati, D.N., (1999), Temel Ekonometri, Literatür Yayıncılık, İstanbul

(2.3.2.1)'deki dönüşüm yöntemi kullanılarak hesaplanan regresyon denkleminde heteroskedastisitenin varolup olmadığını test etmek için Spearman sıra korelasyon testi uygulanmıştır ve korelasyon katsayısı $\rho = -0,29$ olarak hesaplanmıştır.

$$H_0 : \rho_s = 0$$

$$H_1 : \rho_s \neq 0$$

$t = -0,18$ olarak bulunur. Bu değer $t_{(\alpha,n)} = 1,96$ değerinden küçük olduğu için H_0 hipotezinin reddi için yeterli kanıt bulunamamıştır, heteroskedastisite yoktur.

Değişen varyansın modelde varolup olmadığını araştırmak için verilere Spearman testinin yanı sıra Park Testi de uygulanmıştır.

Yeni modeldeki kalıntı kareleri bağımlı değişken, mevduat tutarları ise bağımsız değişken olarak alınarak regresyon analizi yapılmış ve aşağıdaki sonuç hesaplanmıştır.

$$\hat{Y} = 0,959 + 0,158 * X \quad (2.3.2.3)$$

$$(10,723) \quad (0,633)$$

$$t \quad 0,089 \quad 0,25$$

Mevduat tutarlarına ilişkin regresyon katsayısı ise 0,158 olarak hesaplanmıştır. Bu katsayının t istatistiği 0,25 olarak hesaplanmıştır.

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Bu değer $t_{(0,05;43)} = 1,96$ değerinden küçüktür. H_0 hipotezinin reddi için yeterli kanıt bulunamamıştır. Mevduat tutarları ile kalıntı değerleri arasında bir ilişki yoktur, heteroskedastisite yoktur.

3. YAPAY SINİR AĞLARI

3.1 Yapay Sinir Ağlarının Tanımı

Alan Turing 1943'te makinaların düşünüp düşünemeyeceği sorusunu ortaya atarak makine zekasını ya da başka bir deyişle yapay zekayı tartışmaya açan kişi olmuştur. İkinci dünya savaşı sırasında İngiltere'de şifre çözme amacıyla üretilen elektromekanik cihazlar sayesinde bilgisayar bilimi ve yapay zeka kavramları doğmuştur.

Yapay zeka, bir makine ya da insan eliyle üretilmiş otonom bir sistem kullanarak insan zekasının benzetimini yapmaya çalışan bir araştırma alanıdır.

Yapay zekanın uygulama alanlarından biri olan yapay sinir ağları yöntemi, insanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesidir. Yapay Sinir Ağları (YSA), basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve gözlemleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir.

İki sinir hücresi arasındaki bağlantı noktasına "sinaps" adı verilir. Sinapslar sinir hücreleri arasındaki elektrokimyasal teması sağlamaktadır. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olmaktadır. Buna göre, insanlar doğumlarından itibaren yaşayarak öğrenme süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşam esnasında deneyimlerle tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum YSA için de geçerlidir. Öğrenme, eğitime yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi/çıkı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak bağlantı ağırlıklarını (weights of the synapses) bir yakınsama sağlanana kadar, tekrar tekrar/ayarlamasıyla olur.

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış bir çok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları

kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır.

Sinirsel (neural) hesaplamanın merkezinde dağıtılmış, adaptif ve doğrusal olmayan işlem kavramları vardır. YSA'lar, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. YSA'lar ise herbiri büyük bir problemin bir parçası ile ilgilenen, çok sayıda basit işlem elemanlarından oluşmaktadır. En basit şekilde, bir işlem elemanı, bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur. İlk bakışta, işlem elemanlarının çalışma şekli yanıltıcı şekilde basittir. Sinirsel hesaplamanın gücü, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısından gelmektedir.

Çoğu YSA'da, benzer karakteristiğe sahip nöronlar tabakalar halinde yapılandırılırlar ve transfer fonksiyonları eş zamanlı olarak çalıştırılırlar. Hemen hemen tüm ağlar, veri alan nöronlara ve çıktı üreten nöronlara sahiptirler.

YSA'nın ana ögesi olan matematiksel fonksiyon, ağın mimarisi tarafından şekillendirilir. Daha açık bir şekilde ifade etmek gerekirse, fonksiyonun temel yapısını ağırlıkların büyüklüğü ve işlem elemanlarının işlem şekli belirler. YSA'ların davranışları, yani girdi veriyi çıktı veriye nasıl ilişkilendirdikleri, ilk olarak nöronların transfer fonksiyonlarından, nasıl birbirlerine bağlandıklarından ve bu bağlantıların ağırlıklarından etkilenir.*

3.2 Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu çok değişik problemlerin çözümünde kullanılmaktadır. Yapay sinir ağlarının kullanıldığı alanlar özet olarak şu şekilde sıralanabilir;

- Satış tahminleri
- Kalite kontrol
- Müşteri araştırmaları
- Risk Analizi
- Kalite Kontrol
- Finansal Öngörü
- Ekonomik Öngörü

* www.yapayzeka.org

- Konuşma ve Yapı Tanımlama
- Laboratuvar Araştırmaları
- Ses Tanıma
- Meteorolojik Yorumlama
- Petrol ve Gaz Arama
- Hava Tahmini

3.3 Yapay Sinir Ağlarının Kuramı ve Mimarisi


Yapay sinir ağları, insan beynindeki nöronların meydana getirdiği ve öğrenme işlemini gerçekleştiren paralel ağ yapısını taklit ederek, bu sisteme benzeyen zeki programlar tasarlamayı hedefleyen bir yöntemdir. Yapay sinir ağları yöntemi, modelleme simülasyon, öğrenme, tanımlama ve tahmin yapma gibi bir çok uygulama alanında başarı ile kullanılmaktadır.

Bir nöron (sinir hücresi), dendrit ve akson ismi verilen iki ana kısımdan oluşmaktadır. Dendrit, bir nöron ile diğerinin bağlantısını gerçekleştiren kısımdır ve farklı nöronların dendritlerini birbirine bağlayan bölgelere “sinaps” denir. Nöronlar arası elektriksel ve kimyasal sinyal iletimi, bu bağlantı bölgelerinden sinyal geçişleri ile gerçekleşir. Aksonlar ise, dal şeklinde uzun geçiş yapılarıdır. İşleyiş olarak, bir nöronun sinapslar üzerinden aldığı toplam ileti, bir eşik değerinden yüksek ise, nöron, bu toplam iletiyi akson boyunca diğer ucuna iletir ve buradaki diğer sinaps yardımı ile başka bir nörona aktarır. Sinapslar, arttırıcı veya azaltıcı etkili olabilirler. Arttırıcı etkili sinapslar, diğer nörondan alınan toplam iletileri büyütür, diğer yandan, azaltıcı etkili sinapslar gelen iletiler toplamını küçültür. Kısaca, bir nöron, bir dizi giriş sinyali alır. Ve bu sinyalleri işleyerek (arttırarak veya azaltarak) çıkış sinyali olarak diğer bir nörona iletir. Beyin içerisindeki, birbirine paralel olarak bağlı ve yukarıda anlatılan mekanizmaya benzer bir sistem ile çalışan yaklaşık 100 milyar nöron bulunmaktadır.*

Yukarıda anlatılan sinirsel yapıyı örnek alan yapay nöronda ise, dendrit yerine toplama fonksiyonu, hücre gövdesi yerine transfer fonksiyonu ve sinapslar yerine ağırlıklar kullanılmıştır. Kısaca, yapay bir nöron, girişler, ağırlıklar, toplama fonksiyonu ve transfer fonksiyonundan oluşmaktadır. Şekil 3.3.1’de yapay bir nöron yapısı verilmektedir.**


* Ross, T.J., (1995), Fuzzy Logic with Engineering Applications, Mcgraw-Hill Co., USA, 600

** Haykin, S., (1999), Neural Networks: A compreh. Foundation, Prentice-Hall NJ, 842



Şekil 3.3.1 Yapay nöronun yapısı

Yapay nöronlar bir araya gelerek yapay sinir ağını oluştururlar. Sinir hücrelerinin bir araya gelmesi rasgele olmamaktadır. Genel olarak hücreler 3 katman halinde ve her katman içinde paralel olarak bir araya gelerek ağı oluştururlar. Bu katmanlar; girdi katmanı, ara katman (gizli katman) ve çıktı katmanıdır. Bu katmanların birbirleri ile ilişkisi aşağıdaki şekil 3.3.2'de gösterilmektedir.*



Şekil 3.3.2 Yapay nörona katmanların birbirleriyle olan ilişkileri

* Terzi, S. ve Karaşahin M., (2004), "Yapay Sinir Ağları Yöntemi ile Esnek Üstyapı Performans Tahmin Modeli Geliştirilmesi", 4. Ulusal Asfalt Sempozyumu, Ankara, sf. 334-357


Girişler ($x_1, x_2, \dots, x_n$) çevreden aldığı bilgiyi sinire getirir. Girişler, kendinden önceki sinirlerden ve ya dış dünyadan sinir ağına gelebilir. Bir sinir genellikle gelişi güzel bir çok girdiler alabilir.

Ağırlıklar ($w_1, w_2, \dots, w_n$) yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılardır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması ise zayıf ya da önemli olmaması anlamına gelmektedir. Bir ağırlığın değerinin sıfır olması o ağ için en önemli olay olabilir. Sıfır olması herhangi bir etkinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler.*

Aktivasyon fonksiyonu v_i sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamalarını eşik değeri b_j ile toplayarak etkinlik işlevine gönderir. Bazı durumlarda toplama fonksiyonu bu kadar basit bir işlem yerine, en az (min), en çok (max), çoğunluk ve ya bir kaç normaleştirme algoritması gibi çok daha karmaşık olabilir.**

Aktivasyon fonksiyonunun sonucu, transfer fonksiyonuna geçirilip çıkışa iletilir. En çok kullanılan transfer fonksiyonu; Tangent-Sigmoid Fonksiyonu, Log-Sigmoid Fonksiyonu ve Purelin fonksiyonudur.

Tangent- Sigmoid fonksiyonunu değişim aralığı $(-1; +1)$ dır ve fonksiyon yapay sinir ağı toplam girişe bağlı olarak bu aralıkta lineer olmayan bir değişim gösterir.




Şekil 3.3.3 Tangent-Sigmoid fonksiyonu giriş-çıkış eğrisi

* İleri, S., (2006), "Yapay Sinir Ağları ve Uygulama Alanları", Türkiye'de ve Dünyada Otomasyon, 112498:sf: 82-87

** Elmas, Ç., (2003), Yapay Sinir Ağları, Seçkin Kitabevi, Ankara

$$a = \frac{2}{1 + e^{(-n)}} - 1 \quad (3.3.1)$$


Log-Sigmoid fonksiyonunun deęişim aralığı (0;1) dir ve fonksiyon lineer olmayan bir deęişim sergiler.



Şekil 3.3.4 Logaritmik Sigmoid fonksiyonu giriş-çıkış eğrisi

$$a = \frac{1}{1 + e^{(-n)}} \quad (3.3.2)$$

Purelin fonksiyonu girişlerinin deęişimine göre yapay sinir ağıının çıkışı lineer olarak deęişmektedir. Deęişim aralığı ise [-1;+1] dir.



Şekil 3.3.5 Purelin fonksiyonu çıkış eğrisi

$$a = \text{Purelin}(n) = n \quad (3.3.3)$$

* Altun, H., Eminoęlu, U. ve Tezekekici, B.S., "Mlp Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatistiksel Deęişim Gösteren Giriş Verilerine Baęımlılığı", Nięde Üniversitesi Mühendislik-Mimarlık Fakóltesi Elektrik-Elektronik Bölümü, Nięde

Yapay nöron, diğer nöronlardan gelen iletileri (ağırlıklar ile giriş sinyallerinin çarpımını) toplar, bir eşik değeri ile karşılaştırarak aktivasyon potansiyelini hesaplar ve bu potansiyel transfer fonksiyonundan geçirilerek çıkış sinyali üretir. Bunun fonksiyonel ifadesi ise (3.3.4)'te yer almaktadır.

$$y_k = F(v_i) = F\left(\sum_{i=1}^n X_i W_{ij} - b_j\right) \quad (3.3.4)$$

Burada, X_i giriş sinyallerini, W_{ij} sinaptik ağırlıkları, b_j kutuplama değerini (eşik değerinin negatif işaretlisi), v_i aktivasyon potansiyelini, y_k çıkış sinyalini, n önceki katmandaki (giriş sinyali gönderen) nöron sayısını ve k ise işlem yapılan nöronun kaçınıcı olduğunu belirtmektedir.

Sinaptik ağırlıkların pozitif olması artırıcı etkiyi, negatif olması ise azaltıcı etkiyi ifade eder. Eşik değeri ise, toplanan iletilerin bir seviye ile karşılaştırılmasını ve eğer bu seviyeden büyük ise pozitif, küçük ise negatif aktivasyon potansiyeli göndermesini sağlamaktadır. Transfer fonksiyonu ise; aktivasyon potansiyelini normalize etmekte ve istenen aralığa (0;1), (-1;+1) göre ölçeklemektedir. *

Öğrenilmesi istenen hedef değerlerine yakınsamak için, bağlantıların ve kutuplama değerlerinin nasıl bir yöntem ile değiştirileceği, öğrenme algoritması tarafından belirlenir.

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

İleri beslemeli yapay sinir ağları; 1970'li yıllarda geliştirilmiştir. Nöronlar arasındaki bağlantılar bir ilişki oluşturmazlar, iletiler bir katmandaki nöronlardan diğer bir katmandaki nöronlara doğru yapılırlar. Bu ağlar veriye hızlı bir şekilde karşılık üretirler. Eğitim süreci daha kısadır. En önemli özelliği doğrusal olmayan yapı içeren problemlerde de etkili olmasıdır.

Geri beslemeli yapay sinir ağları; birbirinden bağımsız olarak ilk defa Werbs ve daha sonra Rumelhart tarafından önerilmiştir. 1986 yılında Rumelhart ve arkadaşlarının geri yayılım algoritmasını yeniden keşfetmeleri, algoritmanın tanınmasını ve yaygın kullanılmasını sağlamıştır. Geri yayılım algoritması en çok kullanılan öğreticili öğrenme algoritmasıdır. **

* Demuth, H. ve Beale, M., (2000), Neural Network Toolbox For Use with MATLAB, User's Guide, Math Works, Inc., USA, 822

** Hamzaçebi C. ve Kutay F., (2004), "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", Gazi Üniversitesi Müh. Mím. Fak. Der. Cilt 19 No: 3, 227-233

Bağlantılar döngü içerirler ve iletiler hem ileri yönlü hem de geri yönlü olabilir ve nöronların çıkış sinyalleri, kendi giriş birimlerini veya önceki katmanları geri besleyebilir. Döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden bu ağların eğitim süreci daha uzundur.*

Yapay sinir ağları öğrenme yöntemine göre öğreticili öğrenme ve öğreticisiz öğrenme olmak üzere ikiye ayrılır.

Öğreticili öğrenmede; istenen ağ çıkışının elde edilebilmesi için, çıkış hatasının düşürülmesinde ağırlıkların uyarlanabilir hale getirilmesi gereklidir. Her giriş değeri için istenen çıkış değeri sisteme tanıtılır ve yapay sinir ağının giriş-çıkış ilişkisini gerçekleştirene kadar aşama aşama ayarlar. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Çok katmanlı perceptron, geri yayılım ağı, delta kuralı, en küçük kareler ortalaması bu öğrenme tipine örnek verilebilir.

Öğreticisiz öğrenmede ise; Sinir ağına girişin hangi veri parçası sınıfına ait olduğunu veya ağın nerede iyi sonuç vereceği söylenemez. Ağ veriyi üyeleri birbirinin benzeri olan öbeklere yol göstermeksiz ayrır. Matematik algoritmaları öğreticili öğrenmeye göre daha karışıktır. Hebbian öğrenme, Grossberg öğrenme, Kohonen özörgütlemeli harita ağları örnek olarak verilebilir.

3.4 Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının hesaplama ve bilgi işleme gücünün, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri yapay sinir ağlarının karmaşık problemleri çözebilme yeteneğini gösterir. Yapay sinir ağları aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulamada yer bulmuştur.

Doğrusal Olmama :Yapay sinir ağlarının temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen yapay sinir ağları da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile yapay sinir ağları, doğrusal olmayan karışık problemlerin çözümünde en önemli araç olmuştur.

Öğrenme: Yapay sinir ağlarının arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu hücreler arasında doğru bağlantıların yapılması ve bağlantıların

* Yurtoğlu, H., (2005), Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi, DPT, İstanbul

uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağlarının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle yapay sinir ağları istenen davranışı gösterecek şekilde ilgilendiği problemenden aldığı eğitim örneklerini kullanarak problemi öğrenebilir. Bu yöntem, eğitime veya başlangıç tecrübesi sayesinde veriyi kullanarak öğrenme yeteneğine sahiptir. Bu özellikleri sayesinde ise geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmektedir.

Genelleme: Yapay sinir ağları ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Eğitim esnasında kullanılan nümerik bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarır ve böylelikle eğitim sırasında kullanılmayan girdiler için de anlamlı sonuçlar üretebilir. Yapay sinir ağları ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağları problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edebilir.

Hata Toleransı: Yapay sinir ağları çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğu için paralel dağıtılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir yapay sinir ağları bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı gözardı etme yetenekleri oldukça yüksektir.

Sınırsız sayıda değişken kullanabilme: Yapay sinir ağları modelleri sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmel bir öngörü doğruluğu ile genel çözümler sağlayabilmektedir. *

3.5 Yapay Sinir Ağlarının Çeşitleri

3.5.1 Çok Katmanlı Yapay Sinir Ağları (MLP)

Çok katmanlı perseptronlar (MLP), yapay sinir ağlarının en çok kullanılan türüdür ve giriş katmanı, ara katman(lar) ve çıkış katmanından oluşur. Her katmanda, bir veya birden fazla nöron vardır ve her katmandaki nöronlar, diğer katmandaki nöronlara paralel bağlıdır. MLP'daki sinyal (bilgi) akışı ileri yönlüdür ve ilk olarak, çıkış katmanına gelen değerler ile

* Ergezer, H., Dikmen, M. ve Özdemir, E., (2003), Yapay Sinir Ağları ve Tanıma Sistemleri, Pivotka, 2(6), 14-17

hedeflenen değerler arasındaki farklılık (hata miktarı) hesaplanır. Bulunan hata miktarı geri doğru yayılarak (ağırlıklar ve kutuplanma değerleri değiştirilerek) giriş katmanına ulaşır. Daha sonra, MLP, yeni ağırlıklar ile tekrar ileri beslemeli olarak sinyalleri iletir ve yeni hata miktarını hesaplar. Bu ileri besleme ve geri yayılma işlemi, çıkış katmanındaki hata miktarını belli bir limit değerinin altında kalana kadar devam eder. Geri yayılma sırasında serbest değişkenlerin değişimi, öğrenme algoritmasına bağlıdır.

MLP öğrenme algoritmaları içinde en popüler olanı, geri-yayılım algoritmasıdır.* Bu algoritma Widrow-Hoff (delta) öğrenme kuralını kullanır ve azalan hata eğimi (gradyanı) optimizasyon tekniğini uygular. Geri yayılma algoritmasında, hata en küçük kareler yöntemi ile hesaplanır ve çıkış katmanındaki nöronların hepsine ait genel bir hata değerini ifade eder.

Bu işlem bir minimizasyon işlemidir ve ağırlıklardaki $[\Delta W_{ij}(n)]$ iteratif düzeltmeler, hata miktarı ile orantılıdır. Geri yayılım algoritmasında, ağırlık değişimi (düzeltmesi) aşağıdaki formül kullanılarak hesaplanır.

$$[\Delta W_{ij}(n)] = \eta \delta_j(n) y_i(n) \quad (3.5.1.1)$$

burada ΔW_{ij} ağırlık düzeltmesini, η öğrenme katsayısını, δ_j bir nörona ait yerel hata eğitimini, y_i çıkış sinyalini ve n işlem yapılan nöronu ifade etmektedir.

Bu algorithmada öğrenme katsayısının (η) seçimi oldukça önemlidir ve değeri (0,1) aralığında değişir. Eğer η çok küçük ise, ağırlık düzeltmelerinin yapıldığı yakınsama doğrultusunda eğriseldir ve karmaşık bir davranışın modellenmesi daha uygundur. Bunun tersine, η büyük ise, yakınsama doğrultusu çok salınım yapar. Bu sebeple basit problemler için daha yüksek η katsayıları tercih edilir.

3.5.2 Radyal Temelli Fonksiyon Ağları (RBF)

Radyal temelli fonksiyonlar, sayısal analizde çok değişkenli problemlerin çözümünde kullanılmış ve YSA'nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımıyla yararlanılmıştır. RBF ileri beslemeli YSA yapılarına benzer şekilde giriş, gizli ve çıkış katmanlarından oluşur. Ancak giriş katmanından saklı katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Saklı katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir. Çıkış katmanı doğrusal

* Rumelhart, D.E. ve McClelland, J.L., (1986), Paralel Distributed Processing, 1, MIT Press, MA.

olduğundan ağırlıklar, eğim düşme ya da doğrusal en iyileme yöntemleri ile kolayca bulunabilir.*

Gizli katmandaki nöronların aktivasyon fonksiyonları bir C_j merkezi ve σ_j bant genişliği ile belirlenir. Aktivasyon fonksiyonu;

$$F(v_i) = \exp\left(-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right) \quad (3.5.2.1)$$

eşitliği ile tanımlanan Gauss eğrisidir.**

Denklemden de anlaşılabileceği üzere bant genişliği arttıkça eğri daha yayvanlaşmakta ve fonksiyonun sayısal olarak duyarlı olduğu bölge genişlemektedir.***

3.5.3 Genelleştirilmiş Regresyon Ağları (GRNN)

Radyal tabanlı ağların genellikle fonksiyon yaklaşırma problemleri için kullanılmakta olan özel bir halidir. Bu ağlar belirli sayıda saklı katman nöronu ile önemli ölçüde iyi başarı ile sürekli fonksiyonlara yaklaşımı sağlamaktadır. MLP'deki gibi tekrarlı eğitime ihtiyacı duymamaktadır. Giriş ve çıkış arasında, eğitim kümesinden elde ettiği bulgularla herhangi sıradan bir fonksiyona yaklaşabilir. Eğitim kümesinin boyutları büyüdükçe yaklaşımdaki hata oranı sıfıra yakınsar. GRNN, standart teknikleri gibi sürekli değişkenler üzerinde yargıya varılabilmesi içinde kullanılır. Temelinde standart bir istatistiksel yöntem olan kernel yaklaşımını kullanmaktadır. Bu tanıma göre, bağımlı y değişkeninin bağımsız bir x değişkenine göre regresyonu, verilen x girişleri ve eğitim kümesine göre y için en çok olasılığa sahip değere yaklaşır. Yaklaşım yöntemi ortalama karesel hatayı en düşük değere yaklaştıracak şekilde belirlenir. GRNN, belirli bir eğitim kümesinde x ve y giriş ve çıkışları için birleşik olasılık yoğunluk fonksiyonunda tahmini için kullanılmaktadır. Ağırlık matrisi w

* Bose, N.K. ve Liang P., (1996), Neural Network Fundamentals with Graphs, Algorithms and Applications, McGraw-Hill, New York

** Paredes, V. ve Vidal, E.A., (2000), "Class-Dependent Weight Dissimilarity Measure for Nearest Neighbor Classification Problems", Pattern Recognition Letters, Vol. 21, pp 1027-1036

*** Efe, M. ve Kaynak, O., (2004), Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul

eğitilmez eğitim setinden belirlenen hedef değerler ağırlık matrisi olarak atanır. *

GRNN ağlarda bir X_i eğitime girişi, ağdaki Gauss çekirdeklerinden birinin merkezi olarak atanır. Herhangi bir giriş vektörü x için i . biriminin çıkışı şu şekilde hesaplanır;

$$\beta_i = \exp\left[-\frac{(x - x_i)^T (x - x_i)}{2\sigma^2}\right] \quad (3.5.3.1)$$

Herhangi bir x girişi için ağırlık çıkışı 3.5.3.2'deki eşitlik ile hesaplanır.

$$y = \sum_{i=1}^k \alpha_i y_i \quad (3.5.3.2)$$

α katsayısı ise 3.5.3.3'de eşitlik ile hesaplanır.

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^k \beta_i} \quad (3.5.3.3)$$

Eğer giriş vektörü X , herhangi bir X_i eğitime vektörüne yakın ise, X_i 'ye ilişkin α_i en büyük olacak ve istenen çıkış y , X_i 'ye ilişkin y_i çıkışına yaklaşıacaktır. **

3.5.4 Olasılık Sinir Ağları (PNN)

Olasılık sinir ağları bir kategori veya sınıfın parçası olan bir girdinin benzerliğini tahmin etmek için kullanılır. Öğrenilen kalıplar, verilen bir girdi için en uygun sınıfı belirleyecek her bir kategorinin, aynı zamanda nispi sıklık olarak da adlandırılan, bir ön olasılığı vasıtasıyla birleşebilir veya ölçülebilir.

Olasılık sinir ağları (probabilistic neural network-PNN) Bayes- Parzen kestiriciler olarak da bilinir. K_1 ve K_2 sınıflarından birine ait, m boyutlu bir x vektörü olsun. K_1 ve K_2 sınıflarına ait olasılık yoğunluk fonksiyonları $F_1(x)$ ve $F_2(x)$ olsun. Bayes teoremine göre x vektörü;

$$\frac{F_1(x)}{F_2(x)} > \frac{L_1 P_2}{L_2 P_1} \quad (3.5.4.1)$$

* Specht, D.F.,(1991), A General Regression Neural Network,IEEE Transaction Neural Networks, 2(6): 568-576

** Wong, H.S., Wu, M. ve Joyce, R.A., (2000), " A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems", Proc. IEEE Pasific RIM Conference on Multimedia, Sydney, Australia

Eşitliği doğru ise K_1 , eşitliğin tersi doğru ise K_2 sınıfına aittir. Burada P_1 ve P_2 , K_1 ve K_2 sınıflarının görülme olasılığıdır. L_1 , x girdisinin K_1 sınıfına ait iken K_2 olarak yanlış sınıflama oranı; L_2 ise x girdisinin K_2 sınıfına ait iken K_1 olarak yanlış sınıflama oranıdır ve maliyet fonksiyonu olarak adlandırılır. Burdan görülebileceği gibi, $F_1(x)$, $F_2(x)$, L_1 ve L_2 'nin bilinmesi durumunda x girdisinin en yüksek olasılıkla hangi sınıfa ait olduğu tespit edilebilir.*

Olasılık sinir ağlarında yoğunluk fonksiyonu aşağıdaki şekilde bulunur;

$$F(x) = \frac{1}{(2\pi)^{m/2} \sigma^m n} \sum_{i=1}^n \exp \left[-\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (3.5.4.2)$$

Burada n eğitim verisi sayısı, m giriş uzayının boyutu, i örüntü numarası ve σ ise ayarlanabilir bir yumuşatma terimidir.

Eğer kategorinin nispi sıklığı bilinmiyorsa bu durumda tüm kategoriler eşit derecede uygun farz edilir ve kategorinin belirlenmesi yalnızca, girdinin özelliğinin bir sınıfın dağıtım işlevine yakınlığı temel alınarak gerçekleştirilir.**

3.6 Uygulama

Özel bir bankaya ait Ek 1 'de yer alan mevduat tutarlarından yola çıkarak kredi tutarları yapay sinir ağları yöntemi ile tahmin edilmeye çalışılmıştır. Analizde Statistica 5.5 paket programının Neural Network eklentisinden yararlanılmıştır.

Mevduat tutarları girdi katmanı, kredi tutarları ise çıktı katmanı olarak statistica programına tanımlanmıştır. Hatası en düşük, performansı en yüksek değerde olan bir yapay sinir ağı modeli kurulması için programa; PNN, RBF, Linear, MLP, GRNN yapay sinir ağ çeşitlerinin herbiri kullanılıp, gizli katman sayısı serbest bırakılarak denemeler yaptırılmıştır.

Çizelge 3.6.1'de Statistica 5.5 paket programı aracılığıyla hesaplanmış en iyi sonuç veren 40 yapay sinir ağının sonuçları yer almaktadır. Type bölümü kurulan yapay sinir ağının çeşidini, Inputs bölümü ağın kurulumunda girdi olarak kullanılan katman sayısını, Hidden bölümü ise ağda kullanılan gizli katman sayısını göstermektedir. Error bölümü kurulan yapay sinir ağı

* Parzen E.,(1932), "On Estimation of a Probability Density Function and Mode", Annals of Mathematical Statistics, Vol 36, pp. 1065-1076

** Elmas, Ç., (2003), Yapay Sinir Ağları, Seçkin Yayınevi, Ankara

modeli sonucunda hesaplanan tahmin değeri ile gerçek değer arasındaki hata miktarını, Performans bölümü ise %5 anlam düzeyine göre kurulan yapay sinir ağı modeli ile doğru tahminde bulunabilme olasılığını göstermektedir. Sisteme verilerin arasındaki ilişkiyi öğrenerek hatayı minimuma indirebilmesi için çeşitli ağ yapıları kurdurulmuştur. Program veriler arasındaki ilişkiyi öğrenerek bir adım sonra kurduğu ağda, tüm yapay sinir ağı çeşitlerinin tüm olası sonuçlarını karşılaştırarak hatayı en çok düşüren yapay sinir ağı çeşidi seçmiştir. Değerlendirme sonucuna göre; en iyi sonucu 1 girdi katmanına, 13 gizli katmana, 11740000 hata payına ve %77 lik bir performansa sahip olan Multilayer Perceptron ağ çeşidi vermiştir.


Çizelge 3.6.1 Hesaplanan 40 yapay sinir ağının sonuçları

	Type	Error	Inputs	Hidden	Performance
01	Linear	2.862e+07	1	-	0.7203801
02	MLP	2.802e+07	1	7	0.7048855
03	MLP	2.768e+07	1	5	0.6964067
04	MLP	2.708e+07	1	8	0.6810658
05	MLP	2.693e+07	1	13	0.6768882
06	MLP	2.573e+07	1	1	0.6468493
07	MLP	2.527e+07	1	8	0.6363641
08	MLP	2.445e+07	1	8	0.6141785
09	RBF	2.438e+07	1	2	0.6077662
10	RBF	2.347e+07	1	1	0.5892960
11	RBF	2.904e+07	1	3	0.6363655
12	RBF	2.859e+07	1	1	0.6451161
13	RBF	2.854e+07	1	4	0.6541588

14	Linear	2.532e+07	1	-	0.5826055
15	RBF	2.448e+07	1	2	0.5120664
16	MLP	2.389e+07	1	1	0.5573480
17	MLP	2.283e+07	1	13	0.5775036
18	MLP	2.279e+07	1	13	0.5796737
19	MLP	2.275e+07	1	8	0.5782962
20	MLP	2.273e+07	1	13	0.5786557
21	MLP	1.988e+07	1	7	0.9038784
22	MLP	1.986e+07	1	20	0.9047344
23	MLP	1.986e+07	1	20	0.9025556
24	MLP	1.985e+07	1	20	0.9052872
25	MLP	1.983e+07	1	20	0.9046531
26	MLP	1.982e+07	1	20	0.9040993
27	MLP	1.982e+07	1	20	0.9007069
28	MLP	1.981e+07	1	1	0.9017415
29	MLP	1.977e+07	1	1	0.9016632
30	MLP	1.935e+07	1	1	0.8817360
31	MLP	1.182e+07	1	1	0.7735383
32	MLP	1.181e+07	1	6	0.7765097
33	MLP	1.181e+07	1	8	0.7725532
34	MLP	1.181e+07	1	4	0.7766677
35	MLP	1.18e+07	1	20	0.7759370
36	MLP	1.179e+07	1	20	0.7733770

37	MLP	1.178e+07	1	20	0.7731441
38	MLP	1.177e+07	1	20	0.7743929
39	MLP	1.176e+07	1	20	0.7721365
40	MLP	1.174e+07	1	13	0.77235

En iyi sonucu veren 1 girdi katmanına ve 13 gizli katmana sahip yapay sinir ağının gösterimi Şekil 3.6.1’de yer almaktadır.



Şekil 3.6.1 Yapay sinir ağının şeması

Çizelge 3.6.2 Yapay sinir ağının regresyon istatistikleri

	Tr. VAR6	Ve. VAR6	Te. VAR6
Data Mean	4.067e+07	3.451e+07	2.356e+07
Data S.D.	5.317e+07	1.594e+07	2.096e+07
Error Mean	-3227201	-8370.012	7752621
Error S.D.	4.57e+07	1.231e+07	1.824e+07
Abs E. Mean	3.006e+07	9450748	1.552e+07
S.D. Ratio	0.859366	0.7723597	0.8703007
Correlation	0.7892847	0.6352659	0.5873312

Çizelge 3.6.2’de hesaplanan yapay sinir ağıнын regresyon istatistikleri görülmektedir. Hata miktarını minimum yapacak yapay sinir ağını oluşturmak için, 45 adet veriden önce rasgele seçilen 11 tanesi ile bir test ağı oluşturulmuştur. Yukarıdaki çizelgede yer alan Te.VAR6 isimli değişken kurulan bu test ağına ilişkin istatistik değerlerini göstermektedir. Test verilerinin ortalaması 23560000 olup, standart sapması 20960000’tür. 11 veri ile kurulan bu ağ ile yapılan tahminler sonucu oluşan hata miktarının ortalaması 7752621 olup, bu hata miktarının standart sapması 18240000, mutlak hata miktarı ise 15520000’tür. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 0,8703007 olarak hesaplanmıştır. Hesaplanan tahmin değeri ile gerçek değer arasındaki yakınlığı ise çizelgede yer alan Correlation değeri göstermektedir. Test ağında bu değer 0,5873312 olarak hesaplanmıştır. Test ağıнын geçerliliğini sınamak amacıyla, kurulan ağ modelinde rasgele seçilen 11 adet veri kullanılarak tahmin yapılmaya çalışılmıştır. Ve.VAR6 isimli değişken bu sınamanın sonuçlarını göstermektedir. Kullanılan 11 verinin ortalaması 34510000, standart sapması 15940000’tır. Ağ sonucu hesaplanan hata miktarının ortalaması -8370.012, standart sapması 12310000, mutlak hata miktarı 9450748’dir. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 0,7723597 olup, gerçek değeri ile hesaplanan tahmin değeri arasındaki ilişki 0.6352659’dur. Yapılan sınama sonucu hata miktarının düştüğü ve tahmin değeri ile gerçek değer arasındaki ilişkinin de arttığı gözlemlenmiştir. Oluşturan bir yapay sinir ağı geriye kalan 23 veriye uygulanmış hesaplama sonuçları Tr.VAR06 isimli değişkenle gösterilmiştir. Verilerin ortalaması 40670000, standart sapması 53170000’dır. Hataların ortalaması -3227201, standart sapması 45700000, mutlak derleri 30060000’tür. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 0,859366 olup, gerçek değeri ile hesaplanan tahmin değeri arasındaki ilişki 0.7892847’dir.

Çizelge 3.6.3 Yapay sinir ağı sonucunda hesaplanan tahmin değerleri ve hata miktarları


	VAR6	T.VAR6	E. VAR6	Error
ADANA	4.456e+07	7.782e+07	-3.326e+07	0.1615647
ALTUNİZADE	2.964e+07	1.99e+07	9738354	0.0473

AND.KURUMSAL	6.036e+07	1.379e+08	-7.751e+07	0.3764844
ANKARA	6.127e+07	6.18e+07	-530451.8	0.002577
ANTAKYA	2.551e+07	1.407e+07	1.144e+07	0.05555
ANTALYA	2.73e+07	2.224e+07	5057538	0.02457
AVCILAR	2.945e+07	2.343e+07	6018500	0.02923
BAKIRKÖY	3.274e+07	775534.3	3.197e+07	0.1552722
BAYRAMPAŞA	2.942e+07	2.143e+07	7983506	0.03878
BORNOVA	2.885e+07	3.255e+07	-3702245	0.01798
BURSA	3.414e+07	5.601e+07	-2.187e+07	0.1062229
CADDEBOSTAN	3.216e+07	1607503	3.055e+07	0.1484064
ÇİFTEHAVUZLAR	3.991e+07	3522571	3.639e+07	0.1767356
ÇORUM	2.726e+07	3079423	2.418e+07	0.1174667
DENİZLİ	3.55e+07	4.261e+07	-7111776	0.03454
ESKİŞEHİR	3.025e+07	1.729e+07	1.297e+07	0.06298
ETİLER	3.348e+07	3078780	3.04e+07	0.1476721
FINDIKZADE	3.07e+07	2.58e+07	4894811	0.02378
GAZİANTEP	3.219e+07	3.101e+07	1178754	0.005725
GEBZE	2.682e+07	2.836e+07	-1547790	0.007518
GÜNEŞLİ	6.036e+07	1.379e+08	-7.751e+07	0.3764844
HADIMKÖY	3.092e+07	2.85e+07	2418698	0.01175
İKİTELLİ	3.385e+07	3.379e+07	62675.41	0.0003044
İST.KURUMSAL	5.828e+07	2.072e+08	-1.489e+08	0.7232868
İZMİR	3.63e+07	5.72e+07	-2.09e+07	0.1015167

İZMİT	2.847e+07	4.159e+07	-1.312e+07	0.06372
KARAKÖY	4.124e+07	3.013e+07	1.112e+07	0.05399
KARŞIYAKA	3.565e+07	2067148	3.358e+07	0.1631197
KARTAL	3.22e+07	2.964e+07	2559317	0.01243
KAYSERİ	4.081e+07	5.065e+07	-9843542	0.04781
KONYA	2.62e+07	2.916e+07	-2960399	0.01438
LEVENT	2.996e+07	3.789e+07	-7933460	0.03853
MERTER	3.035e+07	1.548e+07	1.486e+07	0.0722
OSMANBEY	3.491e+07	8.58e+07	-5.089e+07	0.2471958
SAMSUN	3.214e+07	2.377e+07	8368771	0.04065
SUADIYE	4.667e+07	1311151	4.536e+07	0.2203057
SULTANHAMAM	3.656e+07	2.151e+07	1.505e+07	0.0730797
ŞANLIURFA	2.355e+07	7875376	1.568e+07	0.0761437
TAKSİM	3.962e+07	2.169e+07	1.792e+07	0.08705
TARABYA	3.106e+07	1389093	2.967e+07	0.1441042
TOPÇULAR	3.559e+07	1.698e+07	1.861e+07	0.09041
TRABZON	3.515e+07	1.881e+07	1.634e+07	0.07937
TUZLA	2.185e+07	1.567e+07	6177815	0.03001
ÜMRANİYE	3.565e+07	3.21e+07	3546043	0.01722
YEŞİLKÖY	3.623e+07	1746300	3.448e+07	0.1674753

Çizelge 3.6.3'de her bir şube için yapay sınır ağı sonucunda hesaplanan tahmin değerleri ve oluşan hata miktarları gösterilmektedir. Çizelge 3.6.3'de yer alan T.Var6 değişkeni algoritmanın ilk döngüsünden sonra hesaplanan tahmin değerini göstermektedir. E. Var6

değişkeni ise gerçek değer ile tahmin değer arasındaki hata miktarını göstermektedir. Error değişkeni ise ağırlıkların ileri besleme ve geri yayılma işlemi ile düşürülen hata miktarını göstermektedir. Hata miktarı en büyük olan veri 0,7232868 ile İstanbul Kurumsal şubesi olmuştur. Bu hata miktarı diğer şubelere göre oldukça yüksektir.



Şekil 3.6.2 Yapay sinir ağları ile yapılan tahmin sonucunda meydana gelen hata miktarları

Şekil 3.6.2’de yapay sinir ağları ile yapılan tahmin sonucunda meydana gelen hata miktarlarının grafiksel gösterimi yer almaktadır.


Çizelge 3.6.4 Yapay sinir ağı ile hesaplanan transfer fonksiyonu sonuçları

ADANA	0.2100449
ALTUNİZADE	0.137609
AND.KURUMSAL	0.2868281
ANKARA	0.2912361
ANTAKYA	0.1175369
ANTALYA	0.1262165

AVCILAR	0.1366612
BAKIRKÖY	0.1526706
BAYRAMPAŞA	0.136518
BORNOVA	0.1337701
BURSA	0.1594538
CADDEBOSTAN	0.1498458
ÇİFTEHAVUZLAR	0.1874769
ÇORUM	0.1260555
DENİZLİ	0.1660543
ESKİŞEHİR	0.1405754
ETİLER	0.1562578
FINDIKZADE	0.1427237
GAZİANTEP	0.1499729
GEBZE	0.1238859
GÜNEŞLİ	0.2868281
HADIMKÖY	0.1438158
İKİTELLİ	0.1580376
İST.KURUMSAL	0.2767132
İZMİR	0.1699566
İZMİT	0.1319046
KARAKÖY	0.1939492
KARŞIYAKA	0.1667918
KARTAL	0.1500286

KAYSERİ	0.1918535
KONYA	0.1208919
LEVENT	0.1391494
MERTER	0.141031
OSMANBEY	0.1631878
SAMSUN	0.1497181
SUADIYE	0.2203057
SULTANHAMAM	0.1712002
ŞANLIURFA	0.1080275
TAKSİM	0.1860549
TARABYA	0.1444828
TOPÇULAR	0.166499
TRABZON	0.1643794
TUZLA	0.0997632
ÜMRANIYE	0.1667904
YEŞİLKÖY	0.1695889

Çizelge 3.6.4’de kurulan yapay sinir ağı sonucunda her şube için hesaplanmış olan transfer fonksiyonunun sonuçları gösterilmektedir.



Şekil 3.6.3 Şubelere göre transfer fonksiyonu sonuçları

Yapay sinir ağları yöntemi ile hesaplanan tahminler sonuçlarında İstanbul Kurumsal şubesinin hata miktarı çok büyük çıkmıştır. Bu verinin ağın tahmin gücüne olan etkisini test etmek için, İstanbul kurumsal şubesinin değeri çıkartılarak tekrar yapay sinir ağı kurulmuştur.


Çizelge 3.6.5 İstanbul kurumsal şubesi olmadan hesaplanan yapay sinir ağları

	Type	Error	Inputs	Hidden	Performance
01	RBF	1.09e+07	1	3	0.9466649
02	MLP	1.088e+07	1	8	0.9860833
03	MLP	1.082e+07	1	8	0.9695296
04	MLP	1.076e+07	1	8	0.9748175

05	MLP	1.075e+07	1	8	0.9736849
06	MLP	1.065e+07	1	8	0.9653286
07	MLP	1.061e+07	1	8	0.9415198
08	MLP	1.057e+07	1	8	0.9582584
09	MLP	1.056e+07	1	8	0.914337
10	MLP	1.021e+07	1	13	0.9185585
11	Linear	1.619e+07	1	-	1.466165
12	RBF	1.185e+07	1	1	1.040812
13	GRNN	1.171e+07	1	22	1.037602
14	GRNN	1.171e+07	1	22	1.035837
15	GRNN	1.171e+07	1	22	1.036145
16	RBF	1.156e+07	1	4	1.034393
17	RBF	1.09e+07	1	3	0.9466649
18	MLP	1.088e+07	1	1	0.98523
19	MLP	1.027e+07	1	13	0.9110309
20	MLP	1.017e+07	1	8	0.9211566

Çizelge 3.6.5'te İstanbul Kurumsal şubesinin değerleri veri setinden çıkartıldığında kalan 44 şubenin değerleri ile kurulmuş yapay sinir ağlarının sonuçları yer almaktadır. 20. ağda en iyi sonuca ulaşılmıştır. En iyi sonucu; 1 girdi katmanına, 8 gizli katmana sahip MLP yapay sinir ağı vermiştir. Hatası 10170000 ve performansı 0,921166'dır.

Hata miktarı çok büyük olan İstanbul Kurumsal şubesi veri setinden çıkarılarak yapay sinir ağı kurulduğunda; daha az deneme ile sistemin daha çabuk sonuca ulaştığı, hata miktarını daha düşürdüğü ve performansı daha yükselttiği gözlemlenmiştir.



Şekil 3.6.4 İstanbul kurumsal şube olmadan kurulan yapay sinir ağının şeması

Şekil 3.6.4'te İstanbul kurumsal şubesinin verileri çıkarılarak oluşturulan 1 girdi katmanına ve 8 gizli katmana sahip yapay sinir ağının gösterimi yer almaktadır.

Çizelge 3.6.6 İstanbul kurumsal şubesi olmadan hesaplanan yapay sinir ağının regresyon istatistikleri

	Tr. VAR2	Ve. VAR2	Te. VAR2
Data Mean	3.016e+07	2.102e+07	4.293e+07
Data S.D.	3.073e+07	1.157e+07	4.14e+07
Error Mean	-1.225e+07	-161196	-2.555e+07
Error S.D.	3.526e+07	1.066e+07	4.688e+07
Abs E. Mean	2.278e+07	8570785	3.287e+07
S.D. Ratio	1.147296	0.9211566	1.132403
Correlation	0.6146	0.418109	0.8423

Çizelge 3.6.6'da hesaplanan yapay sinir ağının regresyon istatistikleri görülmektedir. Hata miktarını minimum yapacak yapay sinir ağını oluşturmak için, 44 adet verinin önce rasgele seçilen 11 tanesi ile bir test ağı oluşturulmuştur. Yukarıdaki çizelgede yer alan Te.VAR6 isimli değişken kurulan bir test ağına ilişkin istatistik değerlerini göstermektedir. Test

verilerinin ortalaması 42930000 olup, standart sapması 41400000'tür. 11 veri ile kurulan bu ağ ile yapılan tahminler sonucu oluşan hata miktarının ortalaması -25550000 olup, bu hata miktarının standart sapması 46880000, mutlak hata miktarı ise 32870000'tür. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 1,132403 olarak hesaplanmıştır. Hesaplanan tahmin değeri ile gerçek değer arasındaki yakınlığı ise Correlation değeri göstermektedir. Test aşında bu değer -0,8723 olarak hesaplanmıştır. Test aşının geçerliliği sınamak amacıyla, kurulan ağ modelinde rasgele seçilen 11 adet veri kullanılarak tahmin yapılmaya çalışılmıştır. Ve.VAR6 isimli değişken bu sınamanın sonuçlarını göstermektedir. Kullanılan 11 verinin ortalaması 21020000, standart sapması 11570000'tür. Ağ sonucu hesaplanan hata miktarının ortalaması -161196, standart sapması 10660000, mutlak hata miktarı 8570785'tir. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 0,921156 olup, gerçek değeri ile hesaplanan tahmin değeri arasındaki ilişki 0.418109'dur. Oluşturan bir yapay sinir ağı geriye kalan 22 veriye uygulanmış hesaplama sonuçları Tr.VAR06 isimli değişkenle gösterilmiştir. Verilerin ortalaması 30160000, standart sapması 30730000'tür. Hataların ortalaması -12250000 standart sapması 35260000, mutlak değerleri 22780000'tür. Hata miktarının standart sapmasının verilerin standart sapmasına oranı 1147296 olup, gerçek değeri ile hesaplanan tahmin değeri arasındaki ilişki 0,6146'dır.


Çizelge 3.6.7 İstanbul kurumsal şube olmadan oluşturulan yapay sinir ağının tahmin değerleri ve hata miktarları

	VAR2	T.VAR2	E. VAR2	Error
ADANA	1.159e+07	7.782e+07	-6.623e+07	0.4830527
ALTUNİZADE	2.198e+07	1.99e+07	2080249	0.01517
AND.KURUMSAL	1575712	1.379e+08	-1.363e+08	0.9941635
ANKARA	1023229	6.18e+07	-6.078e+07	0.4433171
ANTAKYA	2.509e+07	1.407e+07	1.101e+07	0.08034
ANTALYA	2.373e+07	2.224e+07	1492958	0.0108897
AVCILAR	2.213e+07	2.343e+07	-1300436	0.009485
BAKIRKÖY	1.973e+07	775534	1.895e+07	0.1382265

BAYRAMPAŞA	2.215e+07	2.143e+07	715854.2	0.005221
BORNOVA	2.257e+07	3.255e+07	-9985030	0.07283
BURSA	1.873e+07	5.601e+07	-3.728e+07	0.2719277
CADDEBOSTAN	2.015e+07	1607503	1.854e+07	0.1352147
ÇİFTEHAVUZLAR	1.471e+07	3522571	1.119e+07	0.08162
ÇORUM	2.376e+07	3079423	2.068e+07	0.1508226
DENİZLİ	1.777e+07	4.261e+07	-2.484e+07	0.1812093
ESKİŞEHİR	2.153e+07	1.729e+07	4248787	0.03099
ETİLER	1.92e+07	3078780	1.612e+07	0.1175655
FINDIKZADE	2.121e+07	2.58e+07	-4589578	0.0334766
GAZİANTEP	2.013e+07	3.101e+07	-1.088e+07	0.07938
GEBZE	2.409e+07	2.836e+07	-4270402	0.03115
GÜNEŞLİ	1575712	1.379e+08	-1.363e+08	0.9941635
HADIMKÖY	2.105e+07	2.85e+07	-7454768	0.05438
İKİTELLİ	1.894e+07	3.379e+07	-1.485e+07	0.1083158
İZMİR	1.72e+07	5.72e+07	-4e+07	0.2917536
İZMİT	2.285e+07	4.159e+07	-1.873e+07	0.1366346
KARAKÖY	1.381e+07	3.013e+07	-1.632e+07	0.1190213
KARŞIYAKA	1.766e+07	2067148	1.559e+07	0.1137341
KARTAL	2.012e+07	2.964e+07	-9521655	0.0694514
KAYSERİ	1.41e+07	5.065e+07	-3.655e+07	0.2666189
KONYA	2.456e+07	2.916e+07	-4599025	0.03355
LEVENT	2.175e+07	3.789e+07	-1.614e+07	0.117743

MERTER	2.147e+07	1.548e+07	5983770	0.0436459
OSMANBEY	1.818e+07	8.58e+07	-6.762e+07	0.4932085
SAMSUN	2.016e+07	2.377e+07	-3602101	0.02627
SUADIYE	1.021e+07	1311151	8894041	0.06487
SULTANHAMAM	1.702e+07	2.151e+07	-4487991	0.03274
ŞANLIURFA	2.66e+07	7875376	1.873e+07	0.1365933
TAKSİM	1.491e+07	2.169e+07	-6782210	0.04947
TARABYA	2.095e+07	1389093	1.956e+07	0.142651
TOPÇULAR	1.77e+07	1.698e+07	726487.7	0.005299
TRABZON	1.801e+07	1.881e+07	-804048.2	0.005865
TUZLA	2.794e+07	1.567e+07	1.227e+07	0.08949
ÜMRANİYE	1.766e+07	3.21e+07	-1.444e+07	0.1053535
YEŞİLKÖY	1.726e+07	1746300	1.551e+07	0.1131286

Çizelge 3.6.7’de İstanbul Kurumsal çıkartıldığında kalan 44 şube için kurulan yapay sinir ağı sonucunda hesaplanan tahmin değerleri ve oluşan hata miktarları gösterilmektedir. Çizelge 3.6.7’de yer alan T.Var6 değişkeni algoritmanın ilk döngüsünden sonra hesaplanan tahmin değerini göstermektedir. E.Var6 değişkeni ise gerçek değer ile tahmin değer arasındaki hata miktarını göstermektedir. Error değişkeni ise ağırlıkların ileri besleme ve geri yayılma işlemi ile düşürülen hata miktarını göstermektedir. Şekil 3.6.5’te ise hata miktarlarının grafiksel gösterimi yer almaktadır.



Şekil 3.6.5 İstanbul Kurumsal şubesi verileri olmadan kurulan yapay sinir ağı ile yapılan tahmin sonucunda meydana gelen hata miktarları

İstanbul Kurumsal şubesi olmadan 44 şubenin verileri ile kredi tutarlarını tahmin etmek amacıyla oluşturulan yapay sinir ağının transfer fonksiyonu sonuçları Çizelge 3.6.8’de yer almaktadır.

Çizelge 3.6.8 İstanbul kurumsal şube olmadan oluşturulan yapay sinir ağının transfer fonksiyonu sonuçları

VAR2	
ADANA	0.0789
ALTUNİZADE	0.1546949
AND.KURUMSAL	0.005837
ANKARA	0.001807

ANTAKYA	0.1773425
ANTALYA	0.1674452
AVCILAR	0.1557456
BAKIRKÖY	0.1382265
BAYRAMPAŞA	0.1559046
BORNOVA	0.1589619
BURSA	0.1309444
CADDEBOSTAN	0.1412831
ÇİFTEHAVUZLAR	0.1016592
ÇORUM	0.1676273
DENİZLİ	0.123934
ESKİŞEHİR	0.1514175
ETİLER	0.1343655
FINDIKZADE	0.1490547
GAZİANTEP	0.1411454
GEBZE	0.1700868
GÜNEŞLİ	0.005837
HADIMKÖY	0.1478568
İKİTELLİ	0.1324582
İZMİR	0.1198232
İZMİT	0.1610461
KARAKÖY	0.09506
KARŞIYAKA	0.1231552

KARTAL	0.1410849
KAYSERİ	0.09719
KONYA	0.1734973
LEVENT	0.1529909
MERTER	0.1509157
OSMANBEY	0.1269695
SAMSUN	0.1414217
SUADIYE	0.06878
SULTANHAMAM	0.1185183
ŞANLIURFA	0.1883799
TAKSİM	0.1031163
TARABYA	0.1471263
TOPÇULAR	0.1234643
TRABZON	0.125706
TUZLA	0.1981471
ÜMRANİYE	0.1231567
YEŞİLKÖY	0.1202095

4. SONUÇ

Bu çalışmada, regresyon analizi ve yapay sinir ağları yöntemleri kullanılarak 45 şubeye sahip özel bir bankanın mevduat tutarları ile kredi tutarları arasındaki bağlantılar incelenmeye çalışılmıştır.

Birinci bölümde verilere regresyon analizi uygulanmıştır. Bu amaçla serpilme diyagramından yola çıkarak mevduat tutarları bağımsız, kredi tutarları bağımlı değişken olmak üzere doğrusal bir regresyon modeli kurulabileceği sonucuna varılmıştır. Önce regresyon modelinin temel varsayımları sağlanıp sağlanmadığı test edilmiştir. Hata paylarının normal dağılıma uygun olup olmadığını test etmek için Q-Q grafiğine ve kalıntıların histogramına bakılmış daha sonra $\sqrt{\beta_1}$ çarpıklık katsayısı ve β_2 basıklık katsayısını test etmek için $\sqrt{b_1}$ ve b_2 test istatistikleri hesaplanmıştır. $\sqrt{b_1}$ çarpıklık katsayısı istatistiğine göre dağılım simetrik, b_2 basıklık test istatistiğine göre dağılım sivri olduğu sonucuna varılmıştır. Buna göre hata payları basıklık bakımından normal dağılmamaktadır. Dolayısıyla verilerin dağılımına bakıldığında ise bir kaç verinin diğer verilere göre serpilme diyagramında aşırı sapmalar gösterdiği görülmüştür. Bu verilerin sapan değer olup olmadığını test etmek için studendize kalıntı değerleri hesaplanarak (-2;+2) aralığının dışında sonuç veren İstanbul Kurumsal şubesi, Suadiye şubesi ve Ankara şubesinin verilerinin sapan değer olup olmadığı test edilmiştir. Test sonucunda İstanbul Kurumsal şubenin sapan değer olduğu sonucu ortaya çıkmıştır. Gösterge değişken kullanılarak İstanbul Kurumsal şubenin mevcut regresyon modelinde etkili olup olmadığı test edilmiştir. Test sonucunda gösterge değişken anlamlı bulunmuş, böylece İstanbul Kurumsal şubesinin değerleri veri setinden çıkartılarak yeni bir regresyon modeli kurulmuştur. Kurulan yeni modelin hata paylarının normal dağılıma uygun olup olmadığının incelenmesi için $\sqrt{\beta_1}$ çarpıklık ve β_2 basıklık katsayılarını tekrar test etmek için $\sqrt{b_1}$ ve b_2 test istatistikleri hesaplanmıştır. Çarpıklık test ve basıklık test istatistikleri değerlerinin sonucunda hata paylarının normal dağıldığı sonucuna varılmıştır. Regresyon modelinin diğer bir varsayımı olan her alt anakütle varyansının eşit olduğu varsayımını test etmek için verilere Spearman sıra korelasyonu test ve Park testi uygulanmıştır. Her iki testin sonucunda heteroskedastisitenin modelde bulunduğu sonucuna varılmıştır. Değişen varyansı düzeltmek için genelleştirilmiş farklar yöntemi ve dönüşüm yöntemi uygulanmış, yeni oluşan regresyon modellerindeki değişen varyans durumunu test etmek için de Spearman korelasyon testi ve Park testi uygulanmıştır. Her iki yöntem sonucunda oluşturulan yeni regresyon modellerinde değişen varyans olmadığı sonucuna varılmıştır.

Çalışmanın ikinci bölümünde kredi miktarının tahmininde yapay sinir ağları yöntemi kullanılmıştır. Statistica 5.5 paket programı aracılığıyla gizli katman sayısı serbest bırakılarak; PNN, GRNN, RBF, Linear ve MLP yapay sinir ağı çeşitleri kullanılarak en düşük hataya ve en yüksek performansa sahip yapay sinir ağı kurulmaya çalışılmıştır. Değerlendirme sonucunda 1 girdi katmanına 13 gizli katmana sahip MLP yapay sinir ağı en iyi sonucu vermiştir. Kurulan bu ağda şubeler bazında hata miktarlarına bakıldığında İstanbul Kurumsal şubeye ait tahmindeki hata miktarının diğer şubelere göre oldukça yüksek olduğu gözlemlenmiştir. Bu sonuçtan yola çıkarak, İstanbul Kurumsal şubesinin değerleri veri setinden çıkartılarak tekrar yapay sinir ağı kurulmaya çalışılmıştır. Değerlendirme sonucunda 1 girdi katmana, 8 gizli katmana sahip MLP yapay sinir ağı en iyi sonucu vermiştir.

İstanbul Kurumsal şubesinin değerleri veri setinden çıkarıldığında yapay sinir ağının daha az deneme ile daha kolay kurulduğu, hata miktarının düştüğü ve performansının oldukça yükseldiği gözlemlenmiştir. Bu sonuçtan yola çıkarak; sapan değerlerin yapay sinir ağı yöntemini etkilediği sonucuna varılabilir.

Her iki yöntem karşılaştırıldığında; yapay sinir ağı yöntemi mevduat tutarlarını girdi katmanı olarak kullanarak %95 güven aralığında %92'lik gibi yüksek bir olasılıkla şubeler bazında kredi tahmininde bulunmuştur. Fakat mevduat tutarları ile kredi tutarları arasındaki ilişkinin yönü ve derecesi hakkında bir bilgi verememektedir. Regresyon analizi yöntemi ise mevduat tutarlarını bağımsız değişken olarak kullanarak %95 güven aralığında %45'lik bir belirginlik katsayısı ile kredi tahmininde bulunmuş olup, mevduat tutarları ile kredi tutarları arasında doğrusal bir ilişki olduğu ve mevduat birimindeki 1 birimlik bir artışın kredi tutarında 1,368'lik marjinal bir artışa neden olabileceği sonucunu vermiştir. Kullanılan bu iki yöntem karşılaştırıldığında yapay sinir ağlarının regresyon yöntemine kıyasla daha iyi öngörü performansı sağladığı söylenebilir.

KAYNAKLAR

Altun, H., Eminoglu, U. ve Tezekekici, B.S., "Mlp Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatistiksel Değişim Gösteren Giriş Verilerine Bağımlılığı", Niğde Üniversitesi Mühendislik-Mimarlık Fakültesi Elektrik-Elektronik Bölümü, Niğde

Bose, N.K.ve Liang P., (1996), Neural Network Fundamentals with Graphs, Algorithms and Applications, McGraw-Hill, New York

Demuth, H. ve Beale, M.,(2000), Neural Network Toolbox For Use with MATLAB, User's Guide, Math Works, Inc., USA, 822

Efe, M. ve Kaynak, O., (2004), Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul

Elmas, Ç., (2003), Yapay Sinir Ağları, Seçkin Yayınevi, Ankara

Ergezer, H., Dikmen, M. ve Özdemir, E., (2003), Yapay Sinir Ağları ve Tanıma Sistemleri, Pivolka, 2(6), 14-17

Genceli, M., (2001), Ekonometri ve İstatistik İlkeleri, Filiz Kitabevi, İstanbul

Gujarati D.N., (1999), Temel Ekonometri, Literatür Yayıncılık ,İstanbul

Hamzaçebi C. ve Kutay F., (2004), "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", Gazi Üniversitesi Müh. Mim. Fak. Der., Cilt 19 No: 3, 227-233

Haykin, S., (1999), Neural Networks: A Compreh. Foundation, Prentice-Hall NJ, 842

İleri, S.,(2006), "Yapay Sinir Ağları ve Uygulama Alanları", Türkiye'de ve Dünyada Otomasyon, 112498: sf: 82-87

Paredes, V. ve Vidal, E.A., (2000), Class-Dependent Weight Dissimilarity Measure for Nearest Neighbor Classification Problems, Pattern Recognition Letters, Vol. 21, pp 1027-1036

Parzen E., (1962), On Estimation of a Probability Density Function and Mode, Annals of

Mathematical Statistics, Vol 36, pp. 1065-1076

Ross, T.J., (1995), Fuzzy Logic with Engineering Applications, Mcgraw-Hill Co., USA, 600

Rumelhart, D.E. ve McClelland, J.L., (1986), Paralel Distributed Processing, 1, MIT Press, MA.

Snedecor, G.W. ve Cochran W., (1967), Statistical Analysis, Aowa State University Press, Aowa

Specht, D.F., (1991), A General Regression Neural Network, IEEE Transaction Neural Networks, 2(6): 568-576

Terzi, S. ve Karaşahin M., (2004), "Yapay Sinir Ağları Yöntemi ile Esnek Üstyapı Performans Tahmin Modeli Geliştirilmesi", 4. Ulusal Asfalt Sempozyumu, Ankara, sf. 334-357

Weisberg, S. (1985), Applied Linear Regresion, John Wiley & Sons, United States of America

Wong, H.S., Wu, M. ve Joyce, R.A., (2000), " A Neural Network Approach for Predicting Network Resource Requirements in Video Transmission Systems", Proc. IEEE Pasitic RIM Conference on Multimedia, Sydney, Australia

Yurtoğlu, H., (2005), Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi, DPT, İstanbul

İNTERNET KAYNAKLARI

[1] www.yapayzeka.org

EKLER

Ek 1 Şubeler Bazında Mevduat ve Kredi Tutarları

Ek 1 Şubeler Bazında Mevduat ve Kredi Tutarları

Çizelge EK 1.1 Şubeler bazında mevduat ve kredi tutarları

Şube	Mevduat	Kredi
ADANA	42146928	77817955
ALFUMUZADE	17787153	19903665
AND KURUMSAL	67450724	137873626
ANKARA	68523253	61801754
ANTAKYA	18000044	34823571
ANTALYA	13784211	72299600
AVCIKAT	17466001	29433070
BAKIRSAĞ	2270358	740078
BAYRAMPAŞA	17460002	21432948
BİRİNDİVA	1644275	3263254
BURSA	27764777	5680934
CAĞDERİSTAN	2302440	1607503
ÇAKIRIYUĞLAR	7470007	2483391
ÇORUM	1572702	3074423
GENİZİT	7744072	22600191
İZMİT	18819001	17281801
KUTLUK	24210194	3078780
KURUMSAL	19000702	24800221
GAZİANTEP	23065100	21008741

Ek 1 Şubeler Bazında Mevduat ve Kredi Tutarları

Çizelge Ek 1.1 Şubeler bazında mevduat ve kredi tutarları

Şube	Mevduat04	Kredi04
ADANA	42146998	77817959
ALTUNİZADE	17787153	19903665
AND.KURUMSAL	67090724	137873626
ANKARA	68525253	61801154
ANTAKYA	10690094	14073921
ANTALYA	13784211	22239000
AVCILAR	17456501	23428400
BAKIRKÖY	22990268	775534
BAYRAMPAŞA	17406489	21433903
BORNOVA	16445277	32553931
BURSA	25304477	56008534
CADDEBOSTAN	22021467	1607503
ÇİFTEHAVUZLAR	34710067	3522571
ÇORUM	13727202	3079423
DENİZLİ	27540977	42610101
ESKİŞEHİR	18819501	17285801
ETİLER	24216194	3078780
FINDIKZADE	19564707	25800222
GAZİANTEP	22065106	31008741

GEBZE	12957359	28364507
GÜNEŞLİ	67090724	137873626
HADIMKÖY	19942801	28501186
İKİTELLİ	24822695	33785187
İST.KURUMSAL	63804867	207190688
İZMİR	28856603	57201933
İZMİT	15790661	41587001
KARAKÖY	36853207	30126147
KARŞIYAKA	27789984	2067148
KARTAL	22084258	29639659
KAYSERİ	36160278	50653401
KONYA	11890927	29160713
LEVENT	18323734	37892627
MERTER	18977710	15482016
OSMANBEY	26571502	85800750
SAMSUN	21977596	23766276
SUADIYE	45500231	1311151
SULTANHAMAM	29274903	21512152
ŞANLIURFA	7251119	7875376
TAKSİM	34237937	21694786
TARABYA	20173465	1389093
TOPÇULAR	27691159	16975761
TRABZON	26974826	18813641

TUZLA	4216640	15672537
ÜMRANİYE	27789520	32103835
YEŞİLKÖY	28732847	1746300

Çalışmada kullanılan özel bir bankanın 2004 yılı için şubelerindeki mevduat ve kredi tutarları Çizelge Ek 1.1’de yer almaktadır.

ÖZGEÇMİŞ

Doğum tarihi 12.04.1980

Doğum yeri İstanbul

Lise 1994-1997 Fatih Vatan Lisesi

Lisans 1998-2003 Yıldız Teknik Üniversitesi Fen-Edebiyat Fak.
İstatistik Bölümü

Yüksek Lisans 2003-2006 Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü
İstatistik Yüksek Lisansı

Çalıştığı kurum(lar)

1997-1998 Printeks Tekstil ve San. Tic. A.Ş.
2003-2004 Xerox
2005-2006 Anadolubank A.Ş.

