

**OTOMOBİL SAHİPLİĞİNİN YAPAY  
SİNİR AĞLARIYLA  
MODELLENMESİ**

**Muhammed Yasin ÇODUR**

**Yüksek Lisans Tezi  
İnşaat Mühendisliği Anabilim Dalı  
Yrd. Doç. Dr. Ahmet TORTUM  
2007**

**Her hakkı saklıdır**

**ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**OTOMOBİL SAHİPLİĞİNİN YAPAY SİNİR AĞLARIYLA  
MODELLENMESİ**

**Muhammed Yasin ÇODUR**

**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**ERZURUM  
2007**

**Her hakkı saklıdır**

**Yrd. Doç. Dr. Ahmet TORTUM** danışmanlığında **Muhammed Yasin ÇODUR** tarafından hazırlanan bu çalışma **20.08.2007** tarihinde aşağıdaki jüri tarafından İnşaat Mühendisliği Ana Bilim Dalı'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Başkan : Doç. Dr. Yaşar TOTİK

İmza : 

Üye : Yrd. Doç. Dr. Ahmet TORTUM

İmza : 

Üye : Yrd. Doç. Dr. A. Cüneyt AYDIN

İmza : 

**Yukarıdaki sonucu onaylarım**

.....  
**Enstitü Müdürü**

## ÖZET

Yüksek Lisans Tezi

### OTOMOBİL SAHİPLİĞİNİN YAPAY SİNİR AĞLARIYLA MODELLENMESİ

Muhammed Yasin ÇODUR

Atatürk Üniversitesi  
Fen Bilimleri Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. Ahmet TORTUM

Otomobilin insan yaşamında tartışılmaz bir yeri vardır. İnsanlar otomobile başta kişisel olmak üzere kültürel ve soysal birçok alanda ihtiyaç duymaktadırlar. Ekonomik büyüme ve yaşam standartlarının gelişmesiyle birçok ülke ve şehrin otomobil sahipliğinde artış görülmüştür. Otomobil sayısının, kent ulaşım planlamalarını, altyapı iyileştirme çalışmalarını, trafik yönetimini ve ilgili diğer alanları etkileyen anahtar bir faktör olması, otomobil sahipliğinin hesaplanması çalışmalarını oldukça gerekli kılmıştır. Bu bağlamda, otomobil sahipliği öngörülerini planlama çalışmalarında önemli bir rol oynamaktadır. Otomobil kullanımındaki artış öncelikli olarak trafikteki tıkanmalara yol açmış, bu durum ise yeni yolların yapımı, tali yolların iyileştirilmesi ve toplu taşıma sistemlerindeki gelişmeleri zorunlu kılmıştır. Kavram, genel olarak bilinen ve çalışmalarda kullanılan tanımıyla; 1000 kişi başına düşen otomobil sayısı anlamına gelmektedir. Bu çalışmada nüfus, kişi başına gayri safi milli hasıla, benzin fiyatı, otomobil fiyatı ve yol uzunlukları verileri kullanılarak yapay sinir ağlarıyla (YSA) otomobil sahipliği modellenmeye çalışılmıştır. YSA modelinin, klasik modellere göre otomobil sahipliğinin doğrusal olmayan davranışını temsil etmede daha başarılı olduğu görülmüştür.

**2007, 69 sayfa**

**Anahtar Kelimeler:** Otomobil sahipliği, yapay sinir ağları

## **ABSTRACT**

Master Thesis

### **FORECAST MODEL OF CAR OWNERSHIP BASED ON ARTIFICIAL NEURAL NETWORK**

Muhammed Yasin ODUR

Atatürk University  
Graduate School of Natural and Applied Sciences  
Department of Civil Engineering

Supervisor: Asst. Prof. Dr. Ahmet TORTUM

The car has beyond all disputes an important place in human life. First and foremost, people need to use cars in their private lives, especially for cultural and social activities. Due to economic growth and improvement of living standards, car ownership in most countries and cities increase rapidly. Because the level of car ownership is one of the key factors influencing urban transportation planning, transportation infrastructure improvement, traffic management, as well as other automobile policies, forecasting car ownership is essential. In this respect, predictions on car ownership have an important place in the studies of forecast and model development. The increasing use of private cars causes more traffic congestion. These traffic jams necessitate the construction of new roads, restoration of secondary roads, and overall improvement of mass transportation. In engineering terminology, car ownership describes the number of cars per 1,000 people. In this study population, per capita GDP, petrol prices, car prices, and road lengths are used as key factors affecting urban car ownership. This paper tries to develop a model for car ownership in Turkey throughout the inputs of the above mentioned factors and Artificial Neural Network (ANN). The results show that ANN application model is more successful and reliable than the other classical models at non-linear reflection ability.

**2007, 69 pages**

**Keywords:** Car ownership, neural network

## TEŞEKKÜR

Yüksek Lisans Tezi olarak sunduğum bu çalışma, Atatürk Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü Ulaştırma Bilim Dalı'nda hazırlanmıştır.

Çalışmalarım süresince bilimsel ve her türlü alanda hiçbir zaman destek, teşvik ve yardımlarını esirgemeyen büyük fedakârlıklar gösteren çok kıymetli tez danışmanım Sayın Yrd. Doç. Dr. Ahmet TORTUM'a içtenlikle teşekkürlerimi sunarım.

İnşaat Mühendisliği Bölümü'nde görev yapan her türlü yardım ve destekte bulunan başta Bölüm Başkanımız Sayın Prof. Dr. Temel YETİMOĞLU sonra tüm Öğretim Üyesi hocalarıma ve Araştırma Görevlisi arkadaşlarıma teşekkür ederim.

Ayrıca hayatımın her anında yanımda olan, bütün çalışmalarımda olduğu gibi tez çalışmamda da yine maddi ve manevi hiçbir yardımdan kaçınmayan, desteklerini her an arkamda hissettiğim çok kıymetli aileme ve eşime şükranlarımı sunarım.

Muhammed Yasin ÇODUR

Ağustos 2007

## İÇİNDEKİLER

ÖZET .....	i
ABSTRACT .....	ii
TEŞEKKÜR .....	iii
SİMGELER DİZİNİ .....	v
ŞEKİLLER DİZİNİ .....	vii
ÇİZELGELER DİZİNİ .....	viii
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. KURAMSAL TEMELLER .....</b>	<b>8</b>
2.1 Otomobil Sahipliği Modelleri .....	8
2.1.1 S eğrisi modelleri.....	8
2.1.1.a Lojistik eğri modeli.....	10
2.1.1.b Üssel büyüme eğrisi modeli. ....	14
2.1.1.c Gompertz eğrisi modeli. ....	15
2.1.1.d İkili lojit model. ....	16
2.1.1.e Çoklu lojit model. ....	19
2.1.1.f Eşik gelir yaklaşımı .....	22
2.1.2 S eğrilerinin yapıları. ....	22
2.1.3 S eğrisi modellerinin değerlendirilmesi.....	23
2.1.4 Otomobil sahipliği doygunluk düzeyi .....	24
2.1.5 Çok değişkenli regresyon modelleri ve değerlendirilmesi .....	25
2.2 Yapay Sinir Ağlarının Ulaşım Mühendisliğinde Kullanım Alanları .....	26
<b>3. MATERYAL ve YÖNTEM.....</b>	<b>29</b>
3.1 Soft Hesaplama.....	29
3.2 Yapay Sinir Ağları.....	29
3.2.1 Yapay sinir ağlarının özellikleri. ....	32
3.2.2 Yapay sinir ağlarının uygulama alanları .....	34
3.2.3 Yapay sinir ağlarının temel yapısı .....	35
3.2.4 Temel işlem birimleri .....	36
3.2.5 İşlem birimleri arasındaki iletişim .....	37
3.2.6 Aktivasyon ve çıkış kuralları.....	37
3.2.7 Yapay sinir ağları modelleri. ....	40
3.2.8 Yapay sinir ağlarının eğitimi. ....	41
3.2.8.a Öğrenme işlemi.....	42
3.2.8.b Ağırlık katsayılarının eğitilmesi.....	42
3.2.9 Yapay sinir ağlarında öğrenme algoritmaları.....	43
3.2.9.a Geri yayımlı öğrenme yöntemi .....	44
3.2.9.b Levenberg-Marquardt algoritması.....	51
<b>4. ARAŞTIRMA BULGULARI .....</b>	<b>54</b>
4.1 Model Girdileri.....	54
4.1.1 Değişkenler arasında korelasyon ilişkisi .....	54
4.2 Modellerin Uygulanması.....	55
4.2.1 Çoklu regresyon modeli .....	55
4.2.2 YSA modeli.....	57
<b>5. SONUÇLAR .....</b>	<b>65</b>
KAYNAKLAR .....	66
ÖZGEÇMİŞ .....	

## SİMGELER ve KISALTMALAR DİZİNİ

$\Omega$	Omega dönüşümü
$t_{mi}$	Xi. gözlem değeri
$t_{gi}$	i.model değeri
$N$	Eğitilen veri sayısı
$m$	Modeldeki parametre sayısı (Ağ yapısında ağırlıklar ve sabitlerin toplam sayısıdır.)
$\mu$	Üyelik değeri
$\gamma$	Öğrenme oranı
$\varepsilon, e, \delta, E$	Hata
$a, b, c, d, h, n$	Katsayılar
$ce, de$	Hatadaki değişim
$\Theta$	Ayarlama katsayısı
$F$	Aktivasyon fonksiyonu
$K$	Ortalama otomobil maliyeti
$X_t$	X yılında otomobil sahipliğini etkileyen değişken
$TT$	Eğitim Zamanı
$\dot{U}F$	Üyelik fonksiyonu
$W$	Ağırlık Katsayıları
$X_1, X_2, X_3$	Parametreler
$\nabla E(x)$	Eğim
$Z_{ij}$	Lineer diskriminant fonksiyonu değeri
$\nabla^2 E(x)$	Hessian matrisi
$J(x)$	Jacobian matrisi
$A_i$ ve $B_i$	“i” sahiplik sınıfı değişkenleri
$t$	Yıl
$y$	Otomobil sahipliği
$S$	Doygunluk değeri
$Z_B$	Performans İstatistiği



## **Kısaltmalar**

<i>AIC</i>	Akaika Bilgi Kriteri
<i>BF</i>	Benzin Fiyatı
<i>DPT</i>	Devlet Planlama Teşkilatı
<i>EKK</i>	En Küçük Kareler
<i>KBGSMH</i>	Kişi Başına Gayri Safi Milli Hasıla
<i>LM</i>	Levenberg –Marquardt Algoritması
<i>LPA</i>	Yetişkin başına sürücü belgesi sayısı
<i>MSE</i>	Hata Kareler Ortalaması
<i>NMSE</i>	Normalize Edilmiş Hata Kareler Ortalaması
<i>OECD</i>	Organization for Economic Cooperation and Development
<i>OF</i>	Otomobil Fiyatı
<i>OS</i>	Otomobil Sahipliği
<i>RMSE</i>	Kök Hata Kareler Ortalaması
<i>TÜİK</i>	Türkiye İstatistik Kurumu
<i>YSA</i>	Yapay Sinir Ağları
<i>YU</i>	Yol Uzunluğu

## ŞEKİLLER DİZİNİ

Şekil 1.1. Bin Kişiye Düşen Otomobil Sayısı, 2004 ( <i>OECD Factbook 2006</i> ).....	3
Şekil 2.1. S Eğrisinin genel görünümü.....	9
Şekil 2.2. Lojistik eğri, üssel büyüme eğrisi ve Gompertz eğrisi (OECD,1982)..	23
Şekil 3.1. Soft hesaplamanın bileşenleri.....	29
Şekil 3.2. Basit bir sinir hücresi.....	31
Şekil 3.3. Yapay sinir ağının temel bileşenleri .....	36
Şekil 3.4.a) Eşik aktivasyon fonksiyonu .....	38
Şekil 3.4.b) Doğrusal aktivasyon fonksiyonu.....	39
Şekil 3.4.c) Logaritma sigmoid aktivasyon fonksiyonu.....	39
Şekil 3.5. İleri beslemeli yapı.....	40
Şekil 3.6. Geri beslemeli yapı.....	41
Şekil 3.7. Tabakalı bir ağ yapısı.....	44
Şekil 4.1. Otomobil sahipliği modeline ait YSA mimarisi.....	57
Şekil 4.2. Tahmin edilen değerler ile hataların dağılımı.....	61
Şekil 4.3. Hataların histogramı.....	61
Şekil 4.4. Hataların normal olasılık grafiği .....	62
Şekil 4.5. Tahmin edilen değerler ile gözlenen değerler arasındaki ilişki .....	62
Şekil 4.6. Tahmin edilen değerler ile hataların dağılımı .....	63
Şekil 4.7. Hataların histogramı.....	63
Şekil 4.8. Hataların normal olasılık grafiği.....	64
Şekil 4.9. Tahmin edilen değerler ile gözlenen değerler arasındaki ilişki.....	64

## ÇİZELGELER DİZİNİ

Çizelge 2.1. Çeşitli ülkeler için otomobil sahipliği doygunluk düzeyi (OECD, 1982).....	24
Çizelge 4.1. Değişkenlerin korelasyon matrisleri.....	54
Çizelge 4.2. Regresyon modeli ile ilgili parametreler ve testler.....	55
Çizelge 4.3. Türkiye’de otomobil sahipliğini etkileyen değişkenler.....	56
Çizelge 4.4. ( 5x2x1 ) Modelinin duyarlılık analizi sonucu.....	58
Çizelge 4.5. Ağın normalleştirme katsayıları.....	59
Çizelge 4.6. Modellere ait bilgi kriterleri.....	60

## 1. GİRİŞ

Ulaşım planlarında, alınan bir kararla yapılacak bir değişikliğin etkilerini niceliksel olarak değerlendirmek için yapılacak iş, uygulanması düşünülen kararları (yapılacak değişiklikleri), çeşitli ulaşım sunuları için, servis düzeyindeki değişiklikler kümesi şekline dönüştürmektir. Talep modeli bu yol ile karar değişikliklerinin talepte yaratacağı değişimi, ilgili değişkenlere bağlı olarak tahmin edebilir (Chiang *et al.* 1981).

Eylem planlarında alınan herhangi bir kararın, ulaşım talebi ile ilgili hangi birimler üzerinde etkili olacağı hususu da göz önünde bulundurulmalıdır. Kararların etkileri, aynı birimler üzerinde farklı etkiler yaratacağı gibi, belirli endüstrilere özgü de olabilir. Bu yüzden, bir talep modelinin, yukarıda sayılan tüm etkilerin analiz edilmesinde kullanılabilmesi için, kapsamlı bir model olması da gerekir (Keleş 1998).

Otomobilin insan yaşamında tartışılmaz bir yeri vardır. İnsanlar otomobile başta kişisel olmak üzere kültürel ve soysal birçok alanda ihtiyaç duymaktadırlar. Ekonomik büyüme ve yaşam standartlarının gelişmesiyle birçok ülke ve şehrin otomobil sahipliğinde artış görülmüştür. Otomobil sahipliğinin artmasıyla insanlar

- 1) Özgürlüklerine kavuşmuş,
- 2) İstedikleri yerlere rahat ve hızlı bir şekilde seyahat etmeye başlamış,
- 3) Yakın çevrelerine daha çok vakit ayırmış
- 4) Kent merkezinin dışında daha temiz havaya sahip ve gürültü kirliliğinden uzak yerlerde yaşamaya başlamışlardır.


Otomobil sahipliği karayolu geometrik standartlarının tespit edilmesinde ve yerel planlama kuruluşlarınca yapılan kentsel ya da kentler arası ulaştırma planlarında önemli bir veri olarak karşımıza çıkmaktadır.

Otomobil sayısının, kent ulaşım planlamalarını, altyapı iyileştirme çalışmalarını, trafik yönetimini ve ilgili diğer alanları etkileyen anahtar bir faktör olması, otomobil

sahipliğinin hesaplanması çalışmalarını oldukça gerekli kılmıştır. Bu bağlamda, otomobil sahipliği öngörülerini planlama çalışmalarında önemli bir rol oynamaktadır. Otomobil kullanımındaki artış öncelikli olarak trafikteki tıkanmalara yol açmış, bu durum ise yeni yolların yapımı, tali yolların iyileştirilmesi ve toplu taşıma sistemlerindeki gelişmeleri zorunlu kılmıştır.

Otomobil sahipliği genel olarak 1000 kişi başına düşen otomobil sayısı olarak tanımlanmaktadır. Türkiye bin kişi başına düşen 125 otomobil ile Organisation for Economic Co-operation and Development (OECD) ülkeleri arasında sonuncu sıradadır. Türkiye'den sonra en az otomobile sahip Macaristan'da (318) bile bu sayı Türkiye'den 2,5 kat fazladır. Portekiz ise, bin kişiye düşen 748 otomobil ile Avrupa Birliği içinde birinci sırada yer almaktadır.

Bu durum, ülkemizdeki otomotiv pazarının büyümesi ile ilgili fırsatlara işaret etmekle beraber, sosyoekonomik gelişme açısından ülkemizin kat etmesi gereken yolu da ortaya koymaktadır. Otomotiv sanayi, diğer sektörlerle olan yakın ilgisinden dolayı tüm gelişmiş ülkelerde ekonominin sürükleyicisi olarak kabul edilir. Ülkemizde de ithal otomobillerin satışının serbest bırakılması ve otomobil fabrikalarının açılmasıyla otomobil sahipliği önemli bir ulaştırma konusu olarak karşımıza çıkmıştır.



**Şekil 1.1.** Bin Kişiyeye Düşen Otomobil Sayısı, 2004(OECD, OECD Factbook 2006)

Otomobil sahipliği modelleri 1960'lı yılların başlarında ilk olarak İngiltere'de geliştirilmeye başlanmıştır. Ancak model çalışmalarında esas gelişme ve modellerde çeşitlilik 1980 yılından sonra görülmektedir. Bunun nedeni otomobil sahipliği model çalışmasında yararlanılacak sayım ve gözlemlerin bu tarihten sonra istenilen düzeye ulaşmasıdır (Öğüt 2000).

Otomobil sahipliği konusunda Fransız filozof Roland Barthes “otomobil modern çağın gotik katedralidir.” demiş ve nasıl katedral yalnızca bir sığınak değilse, otomobilin de yalnızca bir ulaşım türü olmadığını, toplumdaki önemi düşünüldüğünde otomobilin farklı algılanışları olduğunu belirtmiştir. Bu algılanışlar dört grupta toplanabilir:

1. Antropolojik algılanış: Otomobil statü, zenginlik ve gücün bir sembolüdür.
2. Politik algılanış: Otomobil özgürlüğün ve özelliğin sembolüdür.
3. Psikolojik algılanış: Otomobil genç görünmeyi ve kendine güvenmeyi sağlar.
4. Ekonomik algılanış: Otomobilin kullanımı ile rahat ve hızlı bir yolculuk olanağı elde edilir (Vasconcellos 1997).

Mühendislik hesaplarının tümünde amaç incelenen olayı en iyi temsil edebilecek modeli kurmaktır. Verilerin kesinliği arttığında ve sayısı çoğaldığında olayı temsil etmek için kullanılan modelin güvenilirliği atmaktadır. Ancak, gerçekte ölçüm hataları ve diğer etkenler verilerin güvenilirliğini düşürmektedir. Daha güvenilir veriler, daha fazla zaman ve daha yüksek maliyetler anlamına gelmektedir. Ulaştırma planlamasının temel hedeflerinden biri model kurarak, gelecekteki ulaşırma taleplerini tahmin etmek ve buna bağlı olarak ortaya çıkacak sorunları çözmek için alınması gereken önlemleri belirlemektir. Ulaştırma planlamasının ana sorunlarından biri değişik koşullar altında insan davranışının modellenmesidir. Bunun için özenli ve yoğun bir veri toplama çalışmasına gerek vardır. Yolculuk verileri genel olarak anketler yoluyla elde edilir ve pahalıdır. Modelin kurulması için en çok kullanılan yöntem ise regresyon analizidir. Ancak verilerin sayısının yetersiz olması ve olay parametreleri arasında korelasyon ilişkisinin bulunması durumunda regresyon analizi ile başarılı bir modelleme yapmak zorlaşmakta ve her zaman mantıklı sonuçlar alınamamaktadır (Demir 1997).

1965 yılında L.A. Zadeh'in bulanık kümeler teorisini ortaya atmasıyla, matematiğin bir handikabı olan “var ya da yok” mantığını esas alan klasik kümeler teorisi olmadan matematiksel modeller oluşturulabileceği görülmüştür. Bunun anlamı artık insan mantığına yakın modellerin yapılabilmesinin yanında dilsel ve kesin olmayan verilerin de işlenebileceğidir. Son on yıl zarfında biyolojik sınırların ve öğrenme sisteminin incelenmesi ve anlaşılması ile yapay sinir ağları kavramı ortaya çıkmıştır. Artık elimizde kendi kendine uyarılma sağlayabilen ve öğrenebilen, paralel hesaplama yetenekleri sayesinde hızlı hesaplama yeteneklerine sahip bir sistem vardır. Bulanık mantık kavramı sonraları yapay sinir ağları ile entegre edilmiş ve “bulanık sinir sistemleri” elde edilmiştir (Demir 1997).

Yapay sinir ağları son on yıl içerisinde oldukça ilgi gören bir modelleme tekniğidir. Biyolojik sinir sisteminin çalışma düzenini örnek alarak işler. Bir yapay zekâ tekniği olan Yapay Sinir Ağı (YSA); tanıma, sınıflandırma, tahmin etme ve eniyileme konularında kullanılan etkili bir tekniktir (Tortum 2003).

İnsan sinir hücresinin öğrenme ve sinyal transferi fonksiyonlarının modellenmesi gayreti ile ortaya çıkmış olan YSA'lar, doğrusal olmayan veriler arasındaki ilişkileri öğrenebilme ve çıkarsama yapabilme yetenekleri nedeniyle, klasik yöntemlere göre daha çok alanda uygulanmakta ve daha başarılı sonuçlar elde edilmektedir (Tortum 2003).

Geleneksel yöntemler, yanlış sonuçların elde edilmesi riski nedeniyle eksik ve/veya aşırı sapma içeren veriler için uygun değildir. Öte yandan, YSA yaklaşımı ise, verilere bağlı olmayıp; eksik, kısmen hatalı veya aşırı sapmalı verileri değerlendirebilir, hatta karmaşık ilişkileri öğrenebilir, genelleyebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilir (Tortum 2003).

YSA ile kaynak yönetimi (Raggad 1996), pazar belirleme (Venugopal and Beats 1994) gibi konularda yapılan çalışmalara ek olarak, otellerdeki oda devir hızının tahmini (Law 1998), uluslararası hava taşımacılığındaki yolcu sayısının tahmini (Faraway and Chatfield 1998), finansal analiz ve ev fiyat tahmini (Daniels and Kamp 1999), enflasyon



oranının tahmini (Aiken 1999), öğrenci akademik başarı ortalamasının tahmini (McLauchlan *et al.* 1999), zaman serileri tahmini (Oliveira *et al.* 2000), firma iflaslarının tahmini (Nasır *et al.* 2001) gibi bir dizi başarılı tahminleme çalışmaları gerçekleştirilmiştir (Özalp and Anagün 2003).

İlgilenilen problem(ler)in çözümünde klasik yöntemlerin kullanılması, kimi durumlarda; zaman, para, donanım veya personel yönüyle pahalı ve elde edilen hassasiyet yönüyle yetersiz olabilir. YSA'lar, klasik yöntemlerin olmadığı, uygulanmasının uygun olmadığı veya uygulanması halinde elde edilen sonuçların yeterli olmadığı durumlarda, ilgilenilen problem(ler)in çözümünde etkilidirler (Caudill 1993). Problemin yapısına olan bağımlılığın yanı sıra, YSA'lar aşağıda verilen yetenekleri nedeniyle klasik yöntemlere göre tercih edilmektedirler (Mimasauskas 1989; Fu 1994; Bose and Liang 1996; Özalp ve Anagün 2003).

- YSA'lar verilerden hareketle bilinmeyen ilişkileri veya veriler arasındaki içsel dinamikleri öğrenebilmekte ve kendilerini organize ederek yenileyebilmektedirler.
- Bellek ve işlem elemanı iç içe olup, paralel ve asenkronize bir çalışma söz konusudur.
- Bilgiler işlem elemanları arasındaki ağırlıklarda saklanır ve eğitim süreci uzun olmakla birlikte, test aşamasında reaksiyon zamanı oldukça kısadır.
- YSA'lar doğrusal olmadıkları için, karmaşık problemlere doğrusal tekniklerden daha iyi ve etkin biçimde çözüm üretirler.
- YSA'lar, işlem elemanları arasında yer alan ağırlıklardaki bozulma nedeniyle oluşacak hatayı tolere edecek, verilerde eksiklik olduğunda uygun sınıflandırmayı yapacak ve karar aşamasında bilginin yetersiz olması halinde birikimini kullanarak sonuç üretecek yetenektedirler.

Ülkemizde Otomobil sahipliği konusunda çok detaylı çalışmalar yapılamamıştır. Bunun nedeni, ülkemizde diğer gelişmiş ülkelere oranla gerekli ve yeterli verinin mevcut olmamasıdır.

Bu alıřmanın amacı lkemize ait nfus, kiři bařına gayri safi milli hasıla, benzin fiyatı, otomobil fiyatı ve yol uzunlukları verileri kullanılarak Otomobil Sahipliđi Yapay Sinir Ađlarıyla (YSA) modellenmeye alıřılmıřtır. YSA modellerinde Statistica programının Toolboxları kullanılmıřtır.

## 2. KURAMSAL TEMELLER

Otomobil sahipliğinin hesaplanması için yapılan çalışmalarda tartışmasız en önemli konu yeterli veri ve veri tabanıdır. Bu durum ilk yıllarda yapılan çalışmaların az veri kullanılarak ve basit modeller geliştirilerek iyi sonuçlar alınamamasına, daha sonraki yıllarda yapılan çalışmalarda ise veri tabanının genişlemesinden dolayı karmaşık modeller kurulmasına sebep olmuştur.

Bu güne kadar yapılan çalışmalar incelendiğinde “otomobil sahipliği” kavramı iki şekilde karşımıza çıkmaktadır.

1. Kişi Başına Otomobil Sayısı
2. Aile Başına Otomobil Sayısı

### 2.1. Otomobil Sahipliği Modelleri


Gelişmiş ülkeler için geliştirilen otomobil sahipliği modelleri genel olarak iki ana başlıkta toplanabilir. Bu modeller;

1. S eğrisi modelleri,
2. Çok değişkenli regresyon modelleridir.

#### 2.1.1 S eğrisi modelleri

S eğrisi modeli; kısaca temel yapısı üç bölgeden oluşan bir modeldir. Birinci bölge artışın yavaş olduğu, ikinci bölge artışın hızlandığı, üçüncü bölge ise artışın yavaşlayarak s doygunluk değerine ulaştığı kısımdır. Otomobil sahipliğinin modellenmesi için geliştirilen ilk S eğrisi modeli lojistik eğri modelidir. Bu eğrinin çok kısa süre içerisinde doygunluk noktasına yaklaşması farklı S eğrisi modellerinin kullanılmasına ve geliştirilmesine yol açmıştır. Lojistik Eğri Modelinden sonra, Üssel

Büyüme Eğrisi Modeli, Gompertz Eğrisi Modeli, İkili Lojit Model, Çoklu Lojit Model ve Eşik Gelir Yaklaşımı Modelleri de kullanılmıştır.



**Şekil 2.1.** S Eğrisinin genel görünümü

Otomobil sahipliği için geliştirilen S eğrisi modelleri şu şekilde sıralanabilir:

1. Lojistik Eğri Modeli.

- J. C. Tanner (1960)
- Güney Galler Uygulaması (1970)
- Finlandiya Uygulaması (1970)
- A.B.D. uygulaması (1973)
- Geliştirilmiş lojistik eğri modeli (1974)
- Gelişmekte olan ülkelerde yarı lojistik eğri modeli (1993)

2. Üssel Büyüme Eğrisi Modeli.

- J. C. Tanner (1977)
- Gecikmeli (lagged) üssel büyüme eğrisi modeli (1983).

3. Gompertz Eğrisi Modeli (1999)

4. İkili Lojit Model

- Yarı-lojistik eğri modeli ( 1970)
- Bates (1978)
- İngiltere Ulaştırma İdaresi uygulaması (1980)
- Probit fonksiyon modeli (1978)

#### 5. Çoklu Lojit Model

- Lerman ve B. Akiva (1976)
- K. Train (1978)
- Ayrık lojistik eğriler (1976)
- Çok boyutlu seçim modeli (1979)

#### 6. Eşik Gelir Yaklaşımı (1973)

#### 2.1.1.a. Lojistik eğri modeli.

##### • J. C. Tanner (1960)

Lojistik eğri modeli, İngiltere’de J.C.Tanner tarafından “Transport And Road Research Laboratory (TRRL)” da 1960’lı yılların başında geliştirilmiştir (Tanner 1974). Bu modelin özelliği otomobil sahipliğinin yalnızca zamanın bir fonksiyonu olarak belirlenmesidir.

$$y = \frac{s}{1 + b \cdot \exp[-a \cdot t]} \quad (2.1)$$

Burada a ve b katsayılarıdır.

y : t yılında kişi başına otomobil sayısı

s : Otomobil sahipliğinin doygunluk düzeyi

a : Katsayıdır.

Denklemden  $t = +\infty$  iken otomobil sahipliği  $y = s$  olmaktadır.

Lojistik eğri modelinde kilit noktayı, otomobil sahipliği doygunluk düzeyi (s) oynamaktadır.

• **Güney Galler uygulaması (1970)**

Tanner'in lojistik eğri modeli 1970 yılında Brain tarafından Yeni Güney Galler'de uygulanmıştır. 1950–1968 yılları arasındaki verilerin kullanıldığı bu uygulamada  $s=0,55$  otomobil/kişi olarak kabul edilmiştir.

$$y = \frac{0,55}{1 + 0,98198 \cdot \exp(-0,0855 \cdot t)} \quad (2.2)$$

Burada:

$y$  :  $t$  yılında kişi başına otomobil sayısı

$t$  : “Yıl–1968” (1975 yılı için  $1975-1968=7$ )

• **Finlandiya uygulaması (1970)**

1970 yılında Finlandiya'da, otomobil sahipliğinin öngörülmesi için Tanner tarafından 1960 yılında geliştirilen lojistik eğri modeline sosyo-ekonomik değişkenlerde dâhil edilmiştir (OECD 1982).

$$y = \frac{s}{1 + h \cdot \exp(a \cdot x_1 + b \cdot x_2 + c \cdot x_3)} \quad (2.3)$$

Burada:

$y$  : Kişi başına otomobil sahipliği

$s$  : Otomobil sahipliğinin doygunluk düzeyi

$x_1$  : Kişi başına gelir

$x_2$  : Nüfus yoğunluğu (kişi/km<sup>2</sup>)

$x_3$  : Çalışan nüfusun toplam nüfusa oranı

$a, b, c, h$  : Katsayılarıdır.

• **A.B.D. uygulaması (1973)**

Bu model, Tanner'in 1960 yılındaki lojistik eğri modelindeki kişi başına otomobil sahipliği yerine aile başına otomobil sahipliğini belirlemeye yöneliktir.

$$F_i = k_i \cdot [1 + \exp(A_i + B_i \cdot t)] \quad (2.4)$$

Burada:

- i : Sahiplik sınıfı 1, 2, 3 (aile başına otomobil sayısı)  
 k<sub>i</sub> : “i” sahiplik düzeyi için doygunluk değerleri, 0 < k<sub>i</sub> < 1  
 A<sub>i</sub> ve B<sub>i</sub> : “i” sahiplik sınıfı değişkenleri  
 t : Yıl

• **Geliştirilmiş lojistik eğri modeli (1974)**

Otomobil sahipliğinin yalnızca zamanın değil, kullanıcı gelirinin ve otomobil maliyetlerinin de bir fonksiyonu olduğu gerçeği, lojistik eğrinin geliştirilmesine neden olmuştur. Böylece 1960 yılında Tanner tarafından geliştirilen lojistik eğri modeli ekonomik değişkenlere duyarlı hale getirilmeye çalışılmıştır.

$$y = \frac{s}{1 + a \cdot \exp[-(b \cdot t + c \cdot \ln(i) + d \cdot \ln(p))]} \quad (2.5)$$

Burada:

- y : Kişi başına otomobil sayısı  
 i : Kişi başına gelir  
 p : Genelleştirilmiş otomobil maliyeti  
 t : Yıl  
 a,b,c,d : Katsayılarıdır.

Otomobil maliyeti olarak, satın alma maliyeti, işletme maliyeti ve zaman maliyeti hesaba katılmak suretiyle genelleştirilmiş otomobil maliyeti kullanılmıştır (Tanner 1974).

1973 yılına kadar kabul gören geliştirilmiş lojistik eğri modeli, özellikle;

- Otomobil sahipliği doygunluk düzeyinin çok yüksek olduğu,
- Modelin, gelecekteki ekonomik değişikliklere duyarlı olmadığı,
- Modelin “ kendini doğuran bir yapıda” olması konularında eleştiriler almıştır (Allanson 1982).

Geliştirilmiş lojistik eğri modelinin gelecekteki ekonomik gelişmelere duyarlı olmamasının sebebi; modelin kısa sayılabilecek bir zaman içinde doygunluk düzeyine ulaşıyor olmasıdır.

#### • Gelişmekte olan ülkelerde yarı lojistik eğri modeli (1993)

Çalışma kapsamında kişi başına yıllık milli geliri 3000 \$'ın altında olan 57 ülke, gelir ve otomobil sahipliğine göre beş gruba ayrılmıştır. Bu ülkelerin grupları aşağıda görülmektedir.

- A Grubu: Otomobil sahipliği 0,0022den az olan ülkeler.
- B Grubu : Otomobil sahipliği 0,002–0,01 arasında ve kişi başına milli geliri 450 \$'dan az olan ülkeler.
- C Grubu : Otomobil sahipliği 0,002–0,01 arasında ve kişi başına milli geliri 450 \$'dan fazla olan ülkeler.
- D Grubu: Otomobil sahipliği 0,01–0,02 arasında olan ülkeler.
- E Grubu: Otomobil sahipliği 0,02'den fazla olan ülkeler (Button *et al.* 1992).

Çalışmada, otomobil sahipliğinin belirlenmesinde her grup için farklı bir yarı lojistik eğri ve log doğrusal regresyon modeli geliştirilmiştir.

$$P = \frac{s}{1 + \exp(-a) \cdot X_1^{-b_1} \cdot X_2^{-b_2} \dots \cdot X_n^{-b_n}} \quad (2.6)$$

Burada:

P : Kişi başına otomobil sayısı

S : otomobil sahipliği doygunluk düzeyi



$X_1, X_2, X_3$  : Sosyo-ekonomik deęişkenler

$a, b_1, b_2, b_n$  : Katsayılarıdır.

### 2.1.1.b. Üssel büyüme eğrisi modeli

#### • J.C. Tanner (1977)

Tanner, 1977 yılında yapılan olumsuz eleştiriler üzerine, 1960'lardan beri sürdürdüğü "lojistik eğri" yaklaşımını terk ederek, "üssel büyüme eğrisi" modelinin geliştirmiştir. (Allanson 1982). Bunun sebebi, lojistik model ile öngörülerin fazla büyük olmasıdır (Button *et al.* 1980).

$$y = \frac{s}{1 + [a \cdot (t - T) + b \cdot \ln(i) + c \cdot \ln(p)]^{-n}} = \frac{s}{1 + [d + a \cdot t + b \cdot \ln(i) + c \cdot \ln(p)]^{-n}} \quad (2.7)$$

Burada:

$y$  : Kişi başına otomobil sayısı

$s$  : Otomobil sahipliği doygunluk düzeyi

$p$  : Sabit fiyatlarla otomobil maliyeti

$i$  : Sabit fiyatlarla kişi başına gayri safi milli hasıla

$a, b, c, d, T$  ve  $n$  : Katsayılarıdır (Tanner 1983).

Üssel büyüme modelinde eğri şeklini etkileyen en önemli katsayı "n" dir.  $n = \infty$  olduğunda üssel büyüme eğrisi, lojistik eğriye dönüşmektedir. "n" nin deęişik deęerler alması sonucu üssel büyüme modelinde doygunluk düzeyine yaklaşım süresi deęişmektedir.

#### • Gecikmeli üssel büyüme modeli

Gecikmeli üssel büyüme modeli, "t" yılındaki otomobil sahipliğinin hesaplanmasında, "t-1" yılındaki otomobil stoklarının belli bir oranda (j) hesaba katılması ilkesine dayanmaktadır. Model denklem (2.8.)' verilmiştir.

$$y_t = \frac{s}{1 + [a + b \cdot \ln(i_t) + c \cdot \ln(p_t)]^{-n}} + (1 - j) \cdot k \cdot y_{t-1} \quad (2.8)$$

Burada:

$y_t$  : t yılındaki otomobil sahipliği

$y_{t-1}$  : t-1 yılındaki otomobil sahipliğidir.

### 2.1.1.c. Gompertz eğrisi modeli

$$y_t^* = \gamma \cdot \exp[\alpha \cdot \exp(\beta \cdot x_t)] \quad (2.9)$$

$y_t^*$  : t yılında otomobil sahipliği

$\gamma$  : Otomobil sahipliği doyunluk düzeyi

$x_t$  : t yılında otomobil sahipliğini etkileyen değişken

$\alpha$  ve  $\beta$  : Katsayılarıdır. (Dargay and Gately 1999)

Modelde, otomobil sahipliğini etkileyen değişken (x), kişi başına milli gelir olarak alınmıştır. Kurulan modele dinamik bir yapı kazandırabilmek için, bir yıl önceki otomobil sahipliği değeri de modele dâhil edilmiştir. Buna göre;

$$y_t = y_{t-1} + \Theta \cdot (y_t^* - y_{t-1}) = \gamma \cdot \Theta \cdot \exp[\alpha \cdot \exp(\beta \cdot I_t)] + (1 - \Theta) \cdot y_{t-1} \quad (2.10)$$

Burada:

$y_t$  : t yılındaki otomobil sahipliği

$\Theta$  : Ayarlama katsayısı ( $0 < \Theta < 1$ )

$I_t$  : t yılında kişi başına milli hasıla (\$ olarak)

### 2.1.1.d. İkili lojit model

- Yarı lojistik eğri modeli (1970)

1970 yılında Bates, İngiltere’de, otomobil sahipliği için Tanner tarafından geliştirilen otomobil sahipliği modelinin ekonomik ve bölgesel değişiklikleri içermediği gerekçesiyle, bu değişiklikleri de model bünyesinde bulunduran yeni bir model geliştirmiştir. “Yarı-lojistik eğri modeli” olarak tanımlanan modeli aile başına otomobil sahipliğini, farklı gelir grupları için hesaplamaktadır.

Yarı lojistik eğri modeli, hiç otomobili olmayan ( $P_0$ ), tek otomobili olan ( $P_1$ ) ve birden çok otomobili olan ( $P_2$ ) aileler için üç farklı denklemden oluşmaktadır. (Ortuzar and Willumsen 1990).

$$\frac{P_0}{1 - P_0} = a_0 \cdot I^{-b_0} \cdot D^{c_0} \quad (2.11)$$

$$\frac{P_2}{P_1} = a_1 \cdot \exp(b_1 \cdot I) \cdot D^{-c_1} \quad (2.12)$$

$$P_0 + P_1 + P_2 = 1 \quad (2.13)$$

Burada:

$P_0$  : Otomobili olmayan ailelerin yüzdesi

$P_1$  : Tek otomobili olan ailelerin yüzdesi

$P_2$  : Birden fazla otomobili olan ailelerin yüzdesi

$I$  : Yıllık aile geliri (bin £ olarak)

$D$  : Nüfus yoğunluğu (acre = 0,404 hektar başına nüfus)

$A_0, a_1, b_0, b_1, c_0, c_1$  : Katsayılarıdır.

Yarı lojistik eğri modeli başlıca iki konuda eleştirilmiştir:

1. Otomobil sahipliğini etkilemesine rağmen, nüfus yoğunluğunun gelecekteki değerinin belirsizliği ve bu değeri belirleme çalışmalarının güçlüğü nedeniyle otomobil sahipliği belirlenirken bağımsız bir değişken olarak alınması.
2. Nüfus yoğunluğunun gelir ile yakın ilişkisinin olması (içsel bağımlılık) (Allanson 1982)

• **İkili lojit model (1978)**

Bu modelde otomobil sahipliği aile başına çeşitli gelir grupları için hesaplanmaktadır.

$$P_{1+}(I) = \frac{s_1}{1 + \exp[+(a_1 + b_1 \cdot \ln(I))]} \quad (2.14)$$

$$P_{2+/1+}(I) = \frac{s_2}{1 + \exp[+(a_2 + b_2 \cdot I)]} \quad (2.15)$$

Burada:

- $P_{1+}$  : (I) gelir düzeyinde en az 1 otomobile sahip olan aile yüzdesi  
 $P_{2+/1+}$  : (I) gelir düzeyinde en az 2 otomobile sahip olan aile yüzdesinin en az 1 otomobile sahip olan aile yüzdesine oranı  
 $s_1$  : Tek otomobil sahipliği için doygunluk düzeyi  
 $s_2$  : Birden fazla otomobil sahipliği için doygunluk düzeyi  
 $I$  : Ortalama haftalık aile geliri (£).  
 $a_1, a_2, b_1, b_2$  : Katsayılarıdır.

$$P_{1+}(I) = \frac{s_1}{1 + \exp\{-[a_1 + b_1 \cdot \ln(\frac{I}{PC})]\}} \quad (2.16)$$

$$P_{2+/1+}(I) = \frac{s_2}{1 + \exp[+[a_2 + b_2 \cdot \frac{I}{PC}]]} \quad (2.17)$$

Otomobil sahipliği modeli içinde bölgesel etkileri de hesaba katabilmek için “ulaşılabilirlik düzeyi” tanımlanmıştır.

$$A_i = \sum_j E_j \cdot f(t_{ij}) \quad (2.18)$$

Burada:

- $A_i$  : Ulaşılabilirlik düzeyi  
 $E_j$  : j bölgesinde çalışan sayısı  
 $t_{ij}$  : i-j arasında yolculuk süresi  
 $f$  : Negatif eksponansiyel fonksiyondur.

• İngiltere’de ulaştırma idaresi uygulaması (1980)

$$P_{1+}(I) = \frac{s_1}{(1 + \exp[a_1 + b_1 \cdot \ln(\frac{I}{RPI}) + c_1 \cdot \ln(LPA)])} \quad (2.19)$$

$$P_{2+/1+}(I) = \frac{s_2}{(1 + \exp[a_2 + b_2 \cdot \ln(\frac{I}{RPI}) + c_2 \cdot \ln(LPA)])} \quad (2.20)$$

Burada:

- $P_{1+}$  : “I” gelir düzeyinde ez az 1 otomobile sahip olan aile yüzdesi  
 $P_{2+/1+}$  : “I” gelir düzeyinde ez az 2 otomobile sahip olan ailelerin en az 1 otomobile sahip olan ailelere oranı  
 $s_1$  : Tek otomobil sahipliği için doygunluk düzeyi (0,95 olarak kabul edilmiştir)  
 $s_2$  : Birden fazla otomobil sahipliği için doygunluk düzeyi (0,60 olarak kabul edilmiştir)  
 $I$  : Aile geliri  
 $RPI$  : Perakende fiyat endeksi (1970 yılında =100)  
 $LPA$  : Yetişkin başına sürücü belgesi sayısı  
 $a_1, a_2, b_1, b_2, c_1, c_2$ : Katsayılarıdır.

- **Probit fonksiyon modeli (1978)**

Geliştirilen modelde aile başına otomobil sahipliği, tek otomobil ve birden fazla otomobil için iki probit fonksiyon kullanılarak hesaplanmaktadır.

$$\int_{-\infty}^{U_i \text{ veya } MU_i} \frac{1}{\sqrt{2 \cdot \Pi}} \cdot \exp\left(-\frac{1}{2} \cdot x^2\right) \cdot dx \quad (2.21)$$

Burada:

$U_T$  : Tek otomobili olan ailelerin probit fonksiyonu

$MU_T$  : İki ve daha fazla otomobili olan ailelerin probit fonksiyonu'dur.

$$U_T = -9,7518 + 2,4194 \cdot r - 0,1917 \cdot t + 0,0546 \cdot r \cdot t - 1,335 \cdot \log_{10} P_r \quad (2.22)$$

$$MU_T = -10,3438 + 0,03987 \cdot t + 1,9981 \cdot r - 2,0893 \cdot \log_{10} P_r \quad (2.23)$$

Burada:

$r$  : Gerçek aile gelirinin log 10 tabanına göre değeri (1959 fiyatları ile)

$t$  : Zaman (1960 yılında  $t=0$ )

$P_r$  : Yeni (0 km) otomobil fiyatı (1959 yılında  $P_r=1$ )'dir.

Yapılan çok değişkenli regresyon çalışması sonucunda,  $U_T$  ve  $MU_T$  için  $R^2$  sırasıyla 0,981 ve 0,825 olarak hesaplanmıştır (OECD 1982)

### 2.1.1.e. Çoklu lojit model

- **Lerman ve Ben-Akiva (1976)**

$$P(a, m) = \frac{\exp(V_{am})}{\sum_j \sum_k \exp(V_{jk})} \quad (2.24)$$

Burada:

- $V_{am}$  : Otomobile sahip olup iş yolculuğunda “m” türünün kullanılmasının faydası.  
a ve j : Alternatif otomobil sahipliği  
m ve k : Alternatif ulaşım türleri  
P(a,m) : Olasılıktır (Allanson 1982).

Model sonuçlarının güvenilirliği, öngörü süresi ve bölgesinde, ulaşım türleri arasındaki durumun aynı kalması ile mümkün olacaktır.

• **Train (1977)**

Train’in geliştirdiği çoklu lojit model denklemini;

$$P_i = \frac{\exp(\beta \cdot X_i)}{\sum_j \exp(\beta \cdot X_j)} \quad (2.25)$$

Burada:

- $P_i$  : i otomobile sahip olma olasılığı (0, 1, 2 ya da 3+ olabilir)  
 $X_i$  : i otomobile sahip olmayı etkileyen değişkenler vektörü  
B : Katsayılar vektörüdür.

• **Ayrık lojistik eğriler (1976)**

Downes 1976 yılında, otomobil sahipliğini belirlemek için lojistik eğri modeli ile hesaplanan “ortalama otomobil sahipliği” değerini kullanarak, aile başına 0, 1, 2 ve daha fazla otomobil sahipliğini belirlemek için “ayrık lojit eğriler” kullanılmıştır.

$$P(0) = 1 - C + \gamma \cdot C^2 \quad (2.26)$$

$$P(1) = C - 2 \cdot \gamma \cdot C^2 \quad (2.27)$$

$$P(2+) = \gamma \cdot C^2 \quad (2.28)$$

Burada:

C : ortalama otomobil sahipliği

$\gamma$  : Katsayıdır.

• **Çok boyutlu seçim modeli (multidimensional choice model) (1979)**

Çok boyutlu seçim modelinde üç sıralama kullanılmıştır:

1. Otomobili olmayan aileler/otomobili olan aileler (0/1+)
2. Tek otomobili olan aileler/birden çok otomobili olan aileler (1/2+)
3. İki otomobili olan aileler/ikiden çok otomobili olan aileler (2/3+)

$$P(\text{seçim}) = \frac{e^U}{1 + e^U} \quad (2.29)$$

Burada:

P(seçim) : Bir üst sıraya geçme olasılığı (yalnızca 1 ya da 0 değerini alabilir)

U : Dolaylı göreceli fayda (indirect relative utility)'dir.

Hutchinson, dolaylı göreceli faydayı (U) hesaplamak için çok değişkenli regresyon denklemini kullanılmıştır. Regresyon modeli;

$$U = \text{BIAS} + A * \text{GELİR} + B * \text{AİLE YAPISI} + C * \text{ÇALIŞANLAR} \quad (2.30)$$

Burada:

BIAS : A, B ve C Katsayılar

GELİR : Yıllık aile geliri (1000\$)

AİLE YAPISI : Aile büyüklüğü

ÇALIŞANLAR : Ailede tüm gün çalışanların sayısı (Hutchinson 1979)



### 2.1.1.f. Eşik gelir yaklaşımı (1973)

Eşik gelir yaklaşımı 1973 yılında Harrison tarafından geliştirilmiştir. Harrison, otomobil sahipliğini etkileyen kullanıcı gelirinin iki bölümden oluştuğunu belirlemiştir:

1. Temel ihtiyaçların karşılandığı gelir
2. Temel ihtiyaçların karşılanmasından sonra arta kalan gelir (Button *et al.* 1982)

$$P(1+) = 1 - \frac{1}{\exp\left(\frac{Y - Y_m}{K}\right)} \quad (2.31)$$

Burada:

$P(1+)$  : Ailenin bir otomobile sahip olma olasılığı

$Y$  : Gerçek gelir

$Y_m$  : Gelirin eşik seviyesi (bu değer altında otomobil sahipliği sıfıra eşit)

$K$  : Ortalama otomobil maliyetidir (Button *et al.* 1982).


### 2.1.2 S eğrilerinin yapıları

Otomobil sahipliği modellemesinde kullanılan S eğrileri; lojistik eğri, üssel büyüme eğrisi ve Gompertz eğrisidir. Bu eğriler Şekil 2.1.'de görülmektedir.

Lojistik eğrinin özelliği kısa sürede doyumluk değerine yaklaşmasıdır. Otomobil sahipliği modellemesinin ilk yıllarında kullanılan bu eğri yerine daha sonraları daha uzun sürede doyumluk değerine yaklaşan eğriler kullanılmaya başlamıştır.

Üssel büyüme eğrisi “n” katsayısının değerine göre diğer eğrilere dönüşmektedir. “n” sonsuza giderken üssel büyüme eğrisi lojistik eğriye dönüşmektedir.

Gompertz eğrisinin özelliği üst boyunun alt boyuna göre daha uzun olmasıdır. Başka bir deyimle eğrinin 2/4'ünden 3/4'üne kadarki bölüm, 1/4'ünden 2/4'üne kadarki bölümden daha uzundur (OECD 1982).



Şekil 2.2. Lojistik Eğri, Üssel Büyüme Eğrisi ve Gompertz Eğrisi (OECD 1982)

### 2.1.3 S eğrisi modellerinin değerlendirilmesi

Otomobil sahipliği modellenmesinde S eğrisi modelleri, belli bir doyumluk düzeyi içermesi ve zamanla bu noktaya azalan bir artış hızıyla yaklaşması bakımından literatürde önemli yer tutmaktadır.

S eğrisi modellerinin çeşitliliğinin bir nedeni de veri tipidir. Toplaştırılmış ve ayrık veriler için farklı S eğrisi modelleri geliştirilmiştir.

Toplaştırılmış verilerin kullanılması durumunda, lojistik eğrinin diğer S eğrilerine ( Üssel büyüme ve Gompertz) göre çok daha çabuk doyumluk düzeyine yaklaşıyor olması otomobil sahipliğinin davranışına pek uymamaktadır. Bunun en önemli sebebi

otomobilin yüksek satın alma maliyetidir. Kullanıcılar böylesi bir malı almak için çok daha zor karar verebilmektedirler.

Ayrık verilerle çalışıldığında, kullanılan S eğrisi modelleri diğer birçok alt modele gereksinim duymakta ve dolayısıyla modelleme süreci karmaşık bir yapı almaktadır.

İki tip veri içinde geliştirilen S eğrisi modellerinin bünyelerindeki bağımsız değişken sayısı 2–3 arasında değişmekte yani bu modellerde çok fazla bağımsız değişken kullanılmamaktadır. Bunun nedeni S eğrisi modellerinde yeni değişkenlerin eklenmesiyle kestirimlerin fazla farklılık göstermemesidir.

S eğrisi modelleri, belli bir doygunluk düzeyi içermesi bakımından özellikle uzun vadeli öngörü çalışmalarında kullanılmaktadır.

#### 2.1.4. Otomobil sahipliği doygunluk düzeyi

1960'lı yılların başında, otomobil sahipliğini modellemek için S eğrilerinin kullanılması ve bu eğrilerde doygunluk düzeyinin önemli bir değişken olması, bu değer belirlenebilmesi için çeşitli yöntemlerin geliştirilmesine neden olmuştur. Bu yöntemlerden bir kısmı belli bir hesap esasına dayanmakta, bir kısmı ise yalnızca kabullerden oluşmaktadır.

**Çizelge 2.1.** Çeşitli ülkeler için otomobil sahipliği doygunluk düzeyi (OECD 1982)

Ülke	S (Kişi/otomobil)
Finlandiya	0,70–0,75
Fransa	0,50
Batı Almanya	0,40–0,60
Hollanda	0,65–0,85
İsviçre	0,40–0,50
İngiltere	0,40–0,60
Gelişmekte olan 57 ülke için	0,30–0,45

Otomobil sahipliği doygunluk düzeyini belirlemek için bazı yöntemler kullanılmıştır. Bunlardan bazıları aşağıda verilmiştir.

1. Gelir Seviyesi Yöntemi
2. Ulusal Zaman Serisi Yöntemi
  - Doğrusal regresyon yaklaşımı
  - Doğrusal olmayan regresyon yaklaşımı
3. Kesişim Yöntemi
4. Nüfusun Yaş Dağılımı Yöntemi

#### **2.1.5. Çok değişkenli regresyon modelleri ve değerlendirilmesi**

Çok değişkenli regresyon modelleri otomobil sahipliğinin hangi değişkenlere bağlı olarak ne şekilde değişeceğini göstermektedir. Regresyon modellerinde en önemli konu, bağımlı değişken öngörüsü yapabilmek için öncelikle bağımsız değişkenlerin değerlerinin öngörülmesi gereksinimidir (Öğüt 2001),.

Otomobil sahipliğiyle ilgili olarak geliştirilen çok değişkenli regresyon modelleri aşağıdaki gibi sıralanabilir.

1. ABD (1964),(1966),(1975)
2. Kaliforniya Motorlu Araçlar İdaresi (1979)
3. İngiltere ve ABD (1979)
4. Türkiye (1981)
5. Gelişmekte Olan Ülkeler (1986)
6. Türkiye ve İstanbul (1992)
7. Bir Yıl Gecikmeli (lagged) (1990)
8. Bir ve İki Yıl Gecikmeli (1998)

Klasik yaklaşımla çok değişkenli regresyon modellerinde kullanılan değişken sayısı arttıkça model kestirimleri gerçeğe yaklaşmaktadır. Özellikle otomobil sahipliğine etki eden değişkenlerin zaman içinde birbirlerine göre yakın eğilimler göstermeleri, model

çalışmasında önemli bir sorun olarak ortaya çıkmaktadır. Bu yaklaşımla çok değişkenli regresyon modellerinde çok fazla sayıda bağımsız değişkenin kullanılması doğru sonuçlar vermemektedir.

Literatürde incelenen çalışmalarda, çoğunlukla bağımsız değişkenlerin içsel bağımlılıkları konusunda yeterli bilgi verilmemektedir.

Regresyon modellerinin bir zayıflığı, öngörülerdeki otomobil sahipliği değerlerinin zaman içinde bir değere yakınsamayıp sürekli artmasıdır. Bu durum özellikle otomobil sahipliğinin yüksek olduğu yerlerde yapılan çalışmalarda sorun yaratmaktadır. Bu nedenle gelişmiş ülkelerde, çok değişkenli regresyon modelleri S eğrisi modelleri kadar yaygın olarak kullanılmamaktadır. Bununla birlikte çok değişkenli regresyon modellerinin kısa dönemli öngörülerde daha başarılı sonuçlar verdiği görülmektedir (Öğüt 2001).

## 2.2 Yapay Sinir Ağlarının Ulaşım Mühendisliğinde Kullanım Alanları

Yapay sinir ağları, ulaşım mühendisliğinde son yıllarda pek çok kullanım alanı bulmuştur. İlk uygulamalar 1990'ların başlarında yapılmıştır.

Bu çalışmalardan bazıları şunlardır.

**Sürücü davranışları:** Bu çalışmalar rota seçimi, şerit değiştirme, kavşaklardaki sürücü davranışlarını modelleme üzerine yapılan çalışmalardır.

Yang *et al.* (1992), Dougherty and Joint (1992), Lyons and Hunt (1992), Hunt and Lyons (1993), Lyons (1994), Pant and Balakrishman (1994), Kornhauser (1991), Neusser *et al.* (1991) bu çalışmalara örnek verilebilir.

**Üstyapı yönetimi:** Üstyapı bakım ve onarım çalışmalarını planlama için yapılan çalışmaları içermektedir. Bu çalışmalara örnek ise Kaseko and Ritchie (1992, 1993),

Hua and Faghri (1993), Pant *et al.* (1993), Hajek and Hurdal (1993), Rewinski (1992) verilebilir.

Araç tanıma ve sınıflandırma: Kavşak sinyalizasyonu için gerekli bilgileri edinmek amacıyla yapılan çalışmalardır. Bazıları Mead *et al.* (1994), Bullock *et al.* (1992, 1993), Belgaroui and Blossville (1993), Margarita (1990) sayılabilir.

**Trafik görüntü analizi:** Ulaşım ağında seyreden gerek taşıtların hızları, hacimleri vs ve gerekse sürücülerle alakalı bilgilerin, trafik sisteminin davranışını modellemek için yapılan çalışmaları içerir. Bu çalışmalara örnek ise Kirby *et al.* (1993), Hua and Faghri (1993), Faghri and Hua (1992), Ritchie *et al.* (1992), Ritchie and Cheu (1993) verilebilir.

**Yük operasyonları:** Ağ rotalama ve çizelgelemesi optimizasyonu için yapılan çalışmalardır. Matsuyama (1991), Jwell *et al.* (1991), Potuin and Shen (1991), Ohba *et al.* (1989) bu çalışmalara birkaç örnektir.

**Trafik tahmini:** Trafiğin zaman serileri üzerine uygulanan çalışmalardır. Örnek olarak, Chin *et al.* (1992), Dougherty *et al.* (1994), Dougherty and Cobbett (1994), Clark *et al.* (1993) yaptığı çalışmalar verilebilir.

Nijkamp *et al.* (1996), İtalya şehirlerarası yolcu taşıması tür seçimini yapay sinir ağları ve klasik modelleri kullanarak analiz etmiştir. Tür olarak karayolu ve demiryolu alınmıştır. Model girdileri her bir türe ait fiyat, mesafe ve zaman, çıktı olarak ise demiryolu tür seçim oranı alınmıştır. Sonuçta, YSA'nın klasik modellere üstünlüğü görülmüştür.

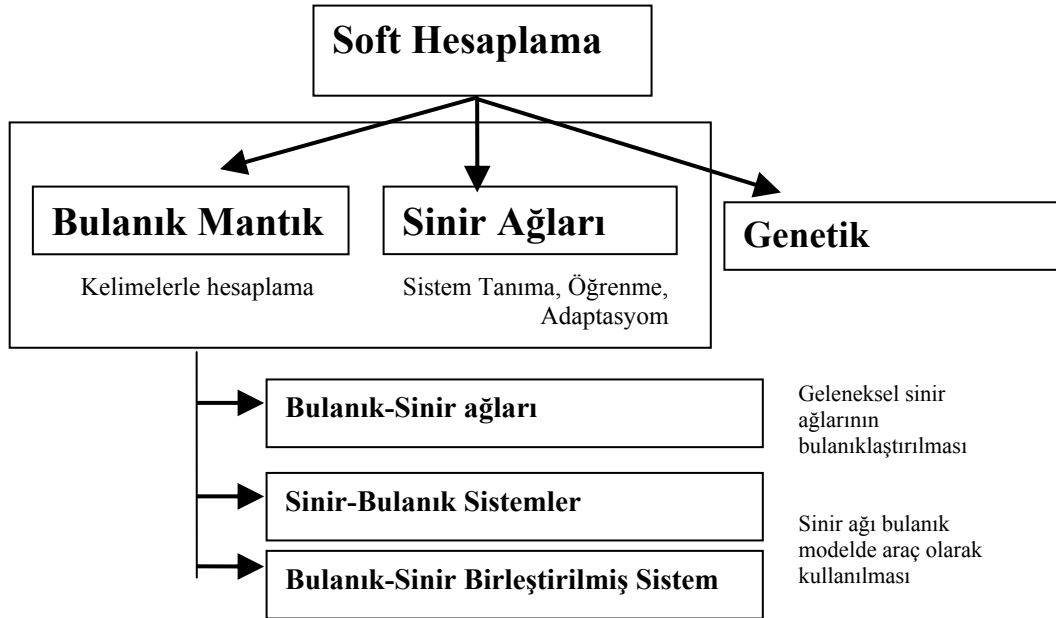
Subba Rao (1998) Mumbai Metrosu için, yolculuk talep tahminini geliştirmek amacıyla yaptığı çalışmada, alternatif türlerin (tren, otobüs, ticari taksi ve özel otomobil) seçim oranlarını modellemeye çalışmıştır. Modele girdi olarak, yolcuların cinsiyeti, yaşı, aile geliri, ailede fert sayısı, yürüme ile yolculuk zamanı, otobüsle ile yolculuk zamanı,

otomobil ile yolculuk zamanı, tren ile yolculuk zamanı, her bir türe ait yolculuk ücreti vb alınmıştır. YSA'nın çoklu lojit modellere göre tür seçim oranını tahminde çok daha başarılı olduğu görülmüştür.

### 3. MATERYAL ve YÖNTEM

#### 3.1. Soft Hesaplama

Son yıllarda, yeni bir saha (soft hesaplama) kontrol modelleme ve karar verme problemleri için ortaya çıktı. Bu yaklaşım insan beyninin kabiliyetini taklit eder ve kesin olmayan ve belirsiz çevrede öğrenir. Soft hesaplama çok tamamlayıcı araçlardan oluşur: Bulanık mantık, sinirsel hesaplama, genetik algoritma ve diğerleri. Soft hesaplamanın gücü ve ana bileşenleri Şekil 3.1’de sunulmuştur.



Şekil 3.1. Soft hesaplamanın bileşenleri

#### 3.2.Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), beynin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Literatürde 100’den fazla yapay sinir ağı modeli vardır. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise, beynin fonksiyonlarını kısmen yerine getiren birçok modelleri oluşturmaya çalışmışlardır (Anderson 1995).



YSA'ların öğrenme özelliği, arařtırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktıları arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder (Bernard 1992).

1943 yılında bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, "Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap" başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur (McCulloch and Pitts 1943). John Von Neumann bu makaleyi, "elektronik beyinler" için bir kopya olarak görmüştür. Yapay zekâ alanındaki arařtırmacılar içerisinde istisnai bir yeri olan Marvin Minsky, bu makaleden aldığı ilhamla makroskobik zeka fikrini ortaya atmış ve uzman sistemlerin doğmasına neden olmuştur. Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bu bilim adamları, öğrenmenin ve zekânın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zekâ konferansında tartışmışlardır (Grossberg 1990).

1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve "adaline" (Adaptive Linear Neuron) olarak adlandırılan bir adaptif lineer elemanı geliştirmiştir. Adaline ve iki tabakalı biçimi olan "madaline" (Multiple Adaline); ses tanıma, karakter tanıma, hava tahmini ve adaptif kontrol gibi çok çeşitli uygulamalar için kullanılmıştır. Daha sonraları adaline, ayrık bir çıkış yerine sürekli bir çıkış üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki ekoları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif lineer eleman algoritmasını kullanmıştır. Bununla ilk defa YSA'lar gerçek bir probleme uygulanmıştır.

Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, 1970'lerin ilk yıllarında adaptif öğrenme ve birleşik hafızalar üzerine temel çalışmalar yapmış ve bu çalışmalarını ile danişmansız öğrenme metotlarının gelişmesine ışık tutmuştur (Hencht-Nielsen 1990).

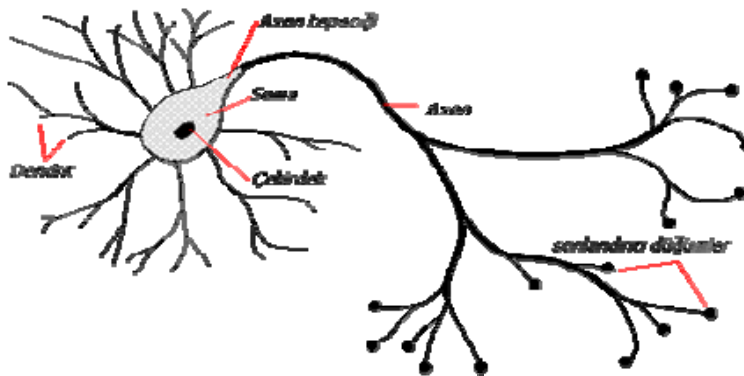
Minsky ve Papert'in perseptron isimli kitaplarında, YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri birçok arařtırmacının bu alanda çalışmaktan

vazgeçmelerine sebebiyet vermiştir. YSA konusunda çalışmaya devam eden Grossberg, YSA modellerini yapılandırmak için nörolojik verinin kullanılması, algı ve hafıza için YSA tabanlı mekanizmaların önerilmesi, belirgin eşitliklerle bütünleşen bir sinaptik model için bir ilişkilendirici kural üzerinde çalışmıştır (Pao 1989).

1982 yılında ilgi çeken bir başka gelişme, moleküller biyolojiden beyin kuramcılığına geçiş yapan Caltech fizikçisi Hopfield'in bir model sunmasıyla olmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve birçok alana uygulanmıştır.

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA'larla ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam edeceklerdir (Smith 1993).

Biyolojik sinir ağının temel inşa bloğu olan basit bir sinir hücresi nöron olarak adlandırılır. Şekil 3.2' de şematik diyagramı gösterilen tipik sinir hücresi üç ana bölümden oluşur. Soma olarak adlandırılan hücre gövdesi, akson ve dendritler. Dendritler dendritik ağaç biçimindedir, nöron gövdesi civarında uzun çalılar görünümündedirler. Dendritler üzerinden girişler alınır, soma tarafından girişler işlenir. Nörondaki sinyalleri taşıyan uzun bir sinirsel bağlantı halindeki akson ise, işlenen girişleri çıkışa aktarır. Akson dendrit bağlantısı ise synapse olarak adlandırılır. Synapse nöronlar arasında elektrokimyasal bağlantıyı sağlamaktadır.



Şekil 3.2. Basit bir sinir hücresi

Bir insanın beyin korteksinde yaklaşık 10 milyar nöron ve yaklaşık 60 trilyon synapse veya bağlantının bulunduğu tahmin edilmektedir. Sonuçta beyin son derece verimli bir yapıdır. Özellikle beynin enerjik verimliliği, her saniyede bir işlem için yaklaşık  $10^{-16}$  joule'dur, bu değer bugünün en iyi bilgisayarlarında yaklaşık  $10^{-6}$  joule'dur. Beyin son derece kompleks, doğrusal olmayan ve paralel bir bilgisayardır. Beynin nöronları organize etme yeteneği böylece kesin hesaplamaları gerçekleştirme (örüntü tanıma, algılama gibi) bugünün en hızlı sayısal bilgisayarlarından daha hızlıdır. Diğer taraftan bir sinir hücresinin tepki hızı günümüzün bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir (Pao 1989).

Bir hipoteze göre nöronlar birbirleriyle elektriksel sinyaller aracılığıyla haberleşmektedir. Ayrıca, nöronlar kimyasal bir ortamda çok yoğun beyinsel faaliyetleri yerine getirmektedirler. Böylece beynin, biyokimyasal işlemlerin gerçekleştiği son derece yoğun bir elektriksel ağ gibi düşünebilir. Çok büyük sinir ağı çok karmaşık ve ayrıntılı bir yapıyla bir birine bağlıdır. Ağa giriş duyarlı algılayıcılar (reseptörler) ile sağlanır. Reseptörler uyarıyı gövdeye götürürler. Uyarım elektriksel sinyaller biçimindedir. Nöron ağının içine bilgi taşınması ve merkezi sinir sisteminde bilginin işlenmesi sonucu efektörler kontrol edilir. Bundan sonra insan cevabını çeşitli eylemler şeklinde verir.

### **3.2.1. Yapay sinir ağlarının özellikleri**

Yukarıda verilen açıklamalardan, YSA'nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de YSA'nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA'nın karmaşık problemleri çözebilme yeteneğini gösterir. Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur.

**Doğrusal olmama:** YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

**Öğrenme:** YSA'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

**Genelleme:** YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

**Uyarlanabilirlik:** YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

**Hata toleransı:** YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

**Donanım ve hız:** YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.

**Analiz ve tasarım kolaylığı:** YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, Bölüm 3.2.'de açıklandığı gibi bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir.

### 3.2.2. Yapay sinir ağlarının uygulama alanları

Son yıllarda YSA'lar, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmiştir. YSA'lar çok farklı alanlara uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla birlikte genel bir sınıflandırma ile YSA'nın uygulama alanları aşağıdaki gibi 6 grup içerisinde toplanabilir.

**Arıza analizi ve tespiti:** Bir sistemin, cihazın ya da elemanın düzenli (doğru) çalışma şeklini öğrenen bir YSA yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı vardır. Bu amaçla YSA, elektrik makinelerinin, uçakların ya da bileşenlerinin, entegre devrelerin v.s. arıza analizinde kullanılmıştır.

**Tıp alanında:** EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu vs gibi uygulama yeri bulmuştur.

**Savunma sanayi:** Silahların otomasyonu ve hedef izleme, nesnelere/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme vs. gibi alanlara uygulanmıştır.

**Haberleşme:** Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.s gibi alanlarda uygulama örnekleri vardır.

**Üretim:** Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin (entegre, kağıt, kaynak vs.) kalite analizi ve kontrolü, planlama ve yönetim analizi vs alanlarına uygulanmıştır.

**Otomasyon ve kontrol:** Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü vs gibi yaygın bir uygulama yeri bulmuştur.

### 3.2.3. Yapay sinir ağlarının temel yapısı

Bir yapay sinir ağı; çok sayıdaki ağırlıklı bağlantılar üzerinden birbirlerine işlenmiş işaretleri göndererek haberleşen, basit işlem birimlerinin birleşiminden oluşan yapıdır. Bu paralel dağılımlı model, temelde ifade edildiği bir kümeyle diğerlerinden ayrılır. Bu kümede:


- İşlem birimleri kümesi (neuronlar ve hücreler)
- Herbir birimin çıkışına karşılık düşen  $y_k$  aktivasyonunun durumu
- Birimler arasındaki bağlantı, bu bağlantı  $k$  birimindeki  $j$  biriminin işaretinin etkisini tanımlayan  $w_{jk}$  ağırlıkları ile ifade edilmektedir.
- İletişim kuralı
- Çalışılan andaki aktivasyon  $y_k(t)$  ile efektif giriş  $s_k(t)$  ye dayalı yeni aktivasyon seviyesini belirleyen aktivasyon fonksiyonu  $F_k$
- Herbir birime ait harici girişleri (eşik, offset) gösteren  $\theta_k$
- Bilgi toplama metodu (öğrenme kuralı)
- Giriş ve hata işaretlerini sağlayan ve sistemin çalışacağı çevre bulunur.

Yukarıda tanımlanan ve her bir işlem birimine göre farklılıklar gösteren model kümeleri sinir ağları için bir temel niteliği taşımaktadır (Erentürk 2002).

### 3.2.4. Temel işlem birimleri

Her bir birim Şekil 3.3'de gösterildiği gibi harici kaynaklardan veya komşu birimlerden gelen giriş işaretlerini alarak diğerlerine iletmek üzere hesaplanmış çıkış işaretlerini üreten oldukça basit bir işlem gerçekleştirir. Bu işlemden sonra ikinci işlem olarak ağırlıkların uydurulması işlemi yapılır. Sistemin paralel doğasından dolayı pek çok işlem birimi kendilerine ait hesaplamaları aynı anda çıkışlarına taşıyabilir.

Sinir sistemlerinde üç farklı işlem birimi vardır. Bunlar; sinir ağının dışından verileri alan ve  $i$  ile gösterilecek olan giriş birimleri, sinir ağından dışarıya veri gönderen ve  $o$  ile gösterilecek olan çıkış birimleri ile giriş-çıkış işaretleri sinir ağının içerisinde kalan ve  $h$  ile gösterilecek olan ara veya gizli birimlerdir.



Şekil 3.3. Yapay sinir ağının temel bileşenleri

Çalışma sırasında birimler eş-zamanlı veya eş-zamansız olarak güncellenebilirler. Eş-zamanlı güncellemeyle, tüm birimler aktivasyonlarını eş-zamanlı olarak değiştirirler. Eş-zamansız güncellemede ise her bir birim bir  $t$  anındaki aktivasyonuna ait güncelleme olasılığına sahiptir ve bu  $t$  anında sadece bir birim kendini güncelleyebilir. Eş-zamanlı

güncelleme daha iyi görünse de bazı durumlarda eş-zamansız güncelleme daha büyük avantajlara sahiptir (Erentürk 2002).

### 3.2.5. İşlem birimleri arasındaki iletişim

$k$  biriminin toplam girişi; bir bias veya offset terimi  $\theta_k$  ile, bağlantılı olduğu herbir birime ait çıkış değerlerinin ayrı ayrı ağırlıklı toplamıdır. Yani:

$$s_k(t) = \sum_j w_{jk}(t)y_j(t) + \theta_k(t) \quad (3.1)$$

Pozitif  $w_{jk}$  uyarıcı veya artırıcı (excitation), negatif  $w_{jk}$  ise dizginleyici veya azaltıcı ağırlıklar olarak tanımlanır. Bazı durumlarda her iki ağırlık özelliklerini de kullanan daha karmaşık durumlar vardır. Bu durumlarda bazı ağırlıklar artırıcı yönde katkıda bulunurken bazı ağırlıklar da azaltıcı yönde katkıda bulunmaktadır. Yukarıda eşitlik (3.1) ile verilen bir birime ait toplam ifadesi sigma birimi iletişim kuralı olarak isimlendirilir.

Feldman ve Ballard (Feldman and Ballard 1982) tarafından önerilen bir diğer iletişim kuralı da sigma-pi birimi iletişim kuralı olarak tanımlanmış ve:

$$s_k(t) = \sum_j w_{jk}(t) \prod_m y_{jm}(t) + \theta_k(t) \quad (3.2)$$

ile ifade edilmiştir. Bu ifadede  $y_{jm}$  çarpım işleminden önce ağırlıklaştırılmaktadır ve işlemler bir kural tablosuna bağlı olarak gerçekleştirilmektedir.

### 3.2.6. Aktivasyon ve çıkış kuralları

Bir birimin aktivasyonunda o birime ait toplam girişlerin etkisini belirleyen bir kurala ihtiyaç vardır. Bu kural ile çalışılan andaki aktivasyon  $y_k(t)$  ve toplam giriş değeri  $s_k(t)$




ye bağı olarak  $k$  biriminin yeni aktivasyon değeri  $y_k(t+1)$  bir  $F_k$  fonksiyonu ile belirlenir.

$$y_k(t+1) = F_k(y_k(t), s_k(t)) \quad (3.3)$$

Genellikle aktivasyon fonksiyonu, incelenen birime ait toplam girişlerin bir fonksiyonudur:


$$y_k(t+1) = F_k(s_k(t)) = F_k\left(\sum_j w_{jk}(t)y_j(t) + \theta_k(t)\right) \quad (3.4)$$

Aşağıdaki şekilde eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun -1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini verir.



**Şekil 3.4. a)** Eşik aktivasyon fonksiyonu


Aşağıdaki şekilde doğrusal aktivasyon fonksiyonu görülmektedir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir.



**Şekil 3.4. b)** Doğrusal aktivasyon fonksiyonu

$f(x) = x$  şeklinde ifade edilir.

Aşağıdaki şekilde logaritma sigmoid transfer fonksiyonu görülmektedir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir böylece daha sonraki bölümlerde görülecek olan geri yayımlı ağlarda kullanmak mümkün olabilmektedir.



**Şekil 3.4. c)** Logaritma sigmoid aktivasyon fonksiyonu

Lojistik fonksiyonu,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)}$$

şeklinde ifade edilir. Buradaki  $\beta$  eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer

olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir.

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$


Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir. Yukarıda verilen fonksiyonlar en genel aktivasyon fonksiyonlarıdır.

### 3.2.7. Yapay sinir ağları modelleri

En basit ve en genel yapay sinir ağları tek yönlü sinyal akışını kullanırlar. Yapay sinir ağı modelleri temel olarak iki grupta toplanmaktadır. İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları. İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenir.

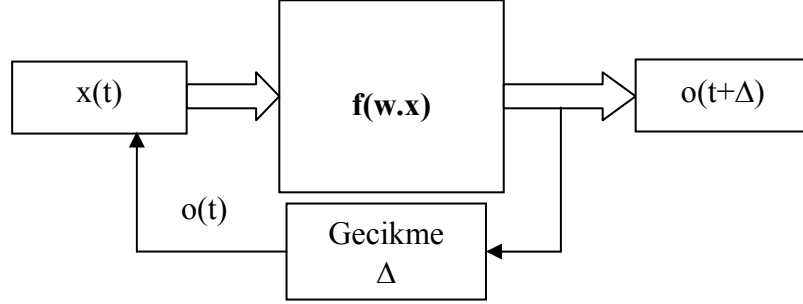
Geri beslemeli yapay sinir ağlarında ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli nöral ağ, çıkışlar girişlere bağlanarak ileri beslemeli bir ağdan elde edilir. Ağın  $t$  anındaki çıkışı  $o(t)$  ise,  $t+\Delta$  anındaki çıkışı ise  $o(t+\Delta)$ 'dır. Buradaki  $\Delta$  sabiti sembolik anlamda gecikme süresidir. İleri beslemeli yapay sinir ağları notasyonu kullanılarak  $o(t+\Delta)$  şöyle yazılabilir.

$$o(t+\Delta) = f [W.o(t)]$$



Şekil 3.5. İleri beslemeli yapı

Dikkat edilmesi gereken nokta başlangıç anında  $x(t)$ 'ye ihtiyaç duyulmasıdır. Başlangıç anında  $o(0) = x(0)$ 'dir.



Şekil 3.6. Geri beslemeli yapı

### 3.2.8. Yapay sinir ağlarının eğitimi

İnsan beyni doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. Yaşadıkça beyin gelişir ve tecrübelenir. Artık olaylar karşısında nasıl tepki göstereceğini çoğu zaman bilmektedir. Fakat hiç karşılaşmadığı bir olay karşısında yine tecrübesiz kalabilir. Yapay sinir ağlarının öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır, bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi yapay sinir ağında da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Bu çalışma süresince yenilenen yapay sinir ağının ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilenerek amaca ulaşılmaya çalışılır. Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer yapay sinir ağı verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir. Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilir, sinir ağı çıkışıyla gerçek çıkışı yaklaşımı incelenir. Eğer yeni verilen örneklere de doğru yaklaşıyorsa sinir ağı işi öğrenmiş demektir. Sinir ağına verilen örnek sayısı optimum değerden fazla ise sinir ağı işi

öğrenmemiş ezberlemiştir. Genelde eldeki örneklerin yüzde sekseni ağa verilip ağ eğitilir, daha sonra geri kalan yüzde yirmilik kısım verilip ağın davranışı incelenir diğer bir deyişle ağ böylece test edilir.

### 3.2.8.a. Öğrenme işlemi

Öğrenme işlemleri iki ayrı grupta sınıflandırılabilir.

- **Danışmanlı veya çağrışimli öğrenme:** Bu tür öğrenme yapısında ağ, girişlere göre çıkış örüntülerinin uydurulması ile eğitilir. Bu giriş-çıkış çiftleri harici bir öğretici tarafından veya ağ yapısı içerisinde bulunan ve kendisinin danışmanı olarak isimlendirilen bir sistem tarafından sağlanır.
- **Danışmansız veya kendi kendini düzenleyen öğrenme:** Girişteki verilere bağlı olarak önemli istatistiksel özellikleri belirleyen ve çıkıştaki örüntüleri sınıflandıran bir yöntemdir. Danışmanlı öğrenmenin aksine öncelikli bir giriş bilgisi yoktur.

### 3.2.8.b. Ağırlık katsayılarının eğitilmesi

Temel ifadeleri yukarıda verilen her iki öğrenme işlemi için birimler arasındaki bağlantılara ait ağırlıkların bazı düzenleme kurallarına bağlı olarak güncellenmesi gerektiği açıktır. Bütün ağ yapıları için geçerli olan tüm öğrenme kuralları, Organization of Behavior kitabında Hebb tarafından 1949 yılında önerilen Hebb öğrenme kuralının değişik türevleridir. Bu öğrenme yapısındaki temel düşünce,  $j$  ve  $k$  birimleri eş-zamanlı olarak aktif hale geliyorlar ise aralarındaki bağlantının canlanacağıdır. Eğer  $j$ ,  $k$ 'dan giriş alıyor ise Hebb öğrenmesine göre  $w_{jk}$  ağırlığı:

$$\Delta w_{jk} = \gamma y_j (d_k - y_k) \quad (3.5)$$

ile yeniden düzenlenecektir. Burada  $\gamma$  öğrenme oranını gösteren pozitif sabit bir sayıdır.  $d_k$  ise öğretici tarafından sağlanan ve arzulanan veya istenilen aktivasyon seviyesidir.

### 3.2.9. Yapay sinir ağlarında öğrenme algoritmaları

1990'lı yıllardan bugüne gelinceye kadar birçok öğrenme algoritması geliştirilmiştir. Öğrenme algoritmaları temelde üç grupta toplanmaktadır. Eğitici öğrenme, eğitici öğrenme ve takviyeli öğrenme algoritmaları.

Eğitici (supervised) öğrenmede, her bir örnekleme zamanında giriş uygulandığında sistemin arzu edilen cevabı  $y$  eğitici tarafından sağlanır. Arzu edilen çıkış  $y$  ile sinir ağı çıkışı  $\hat{y}$  arasındaki fark hata ölçüsüdür ve ağ parametrelerini güncellemekte kullanılır. Ağırlıkların güncellenmesi süresince eğitici ödüllendirme-cezalendirme şemasını ağa uygulayarak hatayı azaltır. Bu öğrenme modelinde giriş ve çıkış örnekleri kümesi eğitim kümesi olarak adlandırılır.

Eğitici öğrenmede, eğitici öğrenmedeki gibi arzu edilen  $y$  çıkışları bilinmemektedir. Bu yüzden kesin bir hata bilgisini ağın davranışını değiştirmekte kullanmak mümkün değildir. Cevabın doğruluğu veya yanlışlığı hakkında bilgi sahibi olunmadığı için öğrenme, girişlerin verdiği cevaplar gözlenerek başarıya ulaşılır. Aslında eğitici öğrenme demek doğru değildir, çünkü eğitici öğrenme gerçekte mümkün değildir. Eğitcinin her öğrenme adımında dahil olmamasına rağmen, amaçları ayarlamaktadır (Lieberman 1990).

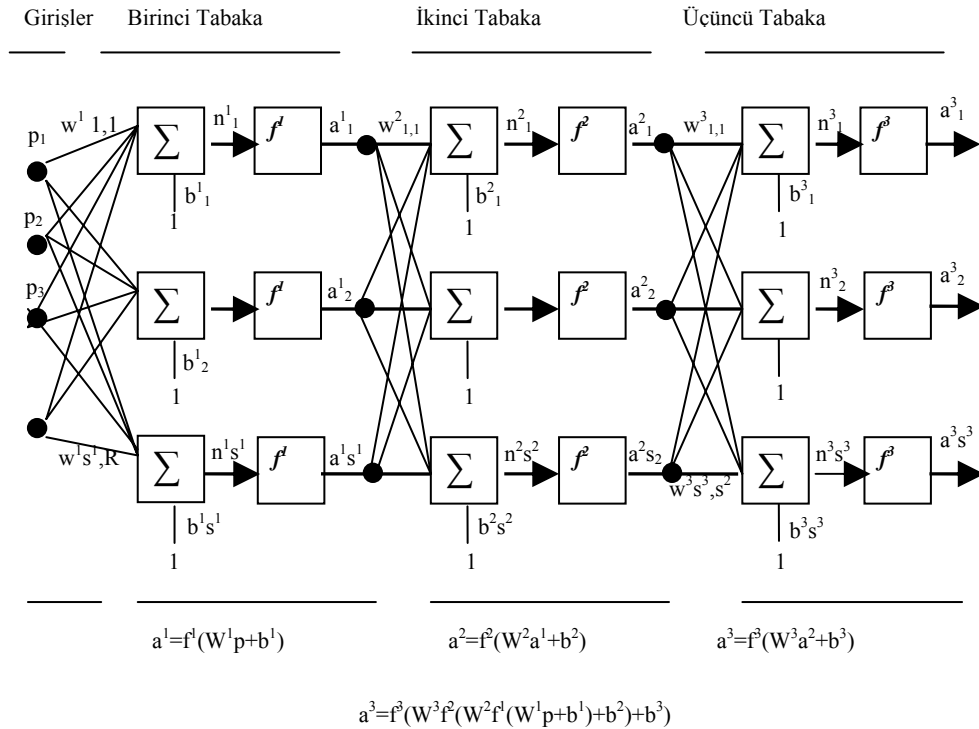
Takviyeli öğrenmede, ağın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir.

Birçok öğrenme algoritmasının bulunmasından dolayı bu kısımda sadece en popüler öğrenme algoritması olan Geri Yayınım Algoritması ve Levenberg-Marquardt öğrenme algoritmaları (Narendra and Parthasarathy 1991) anlatılacaktır.

Geri yayınım algoritması eğitici öğrenmede kullanılan en genel algoritmadır. Basit olması ve iyi bir öğrenme kapasitesine sahip olması birçok alana uygulanmasını sağlamıştır.

### 3.2.9.a. Geri yayımlı öğrenme yöntemi

Geril yayılım ağı, Geoffrey Hinton ve James McClelland tarafından geliştirilmiştir. Geril yayımlı öğrenen ağlar hiyerarşik yapıdadır. Giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşurlar. Gizli katman ve gizli katmandaki düğüm sayısı değiştirilebilir. Düğüm sayısının artması ağın hatırlama yeteneğini artırmakla birlikte öğrenme işleminin süresini uzatmaktadır. Giriş katmanındaki her bir düğüm gizli katmandaki her düğüme, gizli katman birden fazla ise bu katmandaki her bir düğüm kendisinden sonra gelen katmandaki her düğüme ve gizli katman çıkışındaki her düğüm çıkış katmanındaki her düğüme bağlıdır. Bir katmandaki hiçbir düğüme kendi katmanındaki diğer bir düğüme bağlı değildir. Her katmanın çıkış değerleri bir sonraki katmanın giriş değerleridir. Geriye yayılma ortalama bir steepest descent algoritmasıdır. Amaç hata karelerini minimuma indirmektir. Şekil 3.7’de tabakalı bir ağ görülmektedir.



**Şekil 3.7.** Tabakalı bir ağ yapısı

Üç tabakalı bir ağ şekilde gösterilmiştir. Çok tabakalı ağlarda bir tabakanın çıkışı sonraki tabakanın girişi olabilir. Bu aşağıdaki gibi ifade edilebilir.

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad m=0,2,\dots,M-1 \quad (3.6)$$

Burada;

M: ağdaki tabakaların sayısıdır. İlk tabakadaki işlem elemanları dış girişleri alır.

$$a^0 = p \quad (3.7)$$

son tabakadaki işlem elemanlarının çıkışı ağ çıkışıdır.

$$a = a^M \quad (3.8)$$

Çok tabakalı ağlar için geriye yayılmalı algoritma (LMS) en küçük ortalama karesi algoritmasının genelleştirilmiş halidir. Her iki algortmada aynı performans indeksi (ortalama hata karesi) dir.

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (3.9)$$

burada;  $p_q$  ağa giriş ve  $t_q$  ise ona karşılık gelen çıkıştır. Her bir giriş ağa uygulandığı zaman, ağ çıkışı gerçek çıkışla karşılaştırılır. Algoritma ortalama hata karesini minimize etmek için ağ parametrelerinin ayarlaması gerekir.

$$F(x) = E[e^2] = E[(t - a)^2] \quad (3.10)$$

burada;  $x$  ağın bias ve ağırlıklar vektörüdür.

$$F(x) = E[e^T e] = E[(t - a)^T (t - a)] \quad (3.11)$$

Ortalama hata karesini

$$F(x) = (t(k) - a(k))^T (t(k) - a(k)) = e^T(k)e(k) \quad (3.12)$$



ile tahmin edebiliriz. Burada hataların karesinin bekleneni  $k$  iterasyonundaki hataların karesiyle yer değiştirir. Tahmini ortalama hata karesi için Steepest descent algoritması;

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial F}{\partial w_{i,j}^m}, \quad (3.13)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial F}{\partial b_i^m}, \quad (3.14)$$

dir. Burada  $\alpha$  öğrenme oranıdır. Şimdiye kadar, bu gelişme en küçük ortalama karesi algoritmasıyla aynıdır. Zor kısım kısmi türevlerin hesaplanmasıdır. Tek tabakalı lineer ağlarda bu kısmi türevler basitçe hesaplanabilir. Çok tabakalı ağlar için hata, gizli tabakadaki ağırlıkların açık bir fonksiyonu değildir. Bundan dolayı bu türevlerin hesaplanması o kadar da kolay değildir. Hata gizli tabakadaki ağırlıkların direkt olmayan bir fonksiyonu olduğu için, türevleri hesaplamak için zincir kuralını uygulanır.

Zincir kuralını (3.13) ve (3.14) denklemindeki türevleri bulmak için uygularsak;

$$\frac{\partial F}{\partial w_{i,j}^m} = \frac{\partial F}{\partial n_i^m} x \frac{\partial n_i^m}{\partial w_{i,j}^m} \quad (3.15)$$

$$\frac{\partial F}{\partial b_i^m} = \frac{\partial F}{\partial n_i^m} x \frac{\partial n_i^m}{\partial b_i^m} \quad (3.16)$$

$m$  tabakasına net giriş o tabakadaki bias ve ağırlıkların açık bir fonksiyonu olduğu için bu denklemlerdeki ikinci terimler kolayca hesaplanabilir.

$$n_i^m = \sum_{j=1}^{s^{m-1}} w_{i,j}^m a^{m-1}_j + b_i^m \quad (3.17)$$

bundan dolayı

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a^{m-1}_j, \frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (3.18)$$

buradan

$$s_m^i \equiv \frac{\partial F}{\partial n_i^m} \quad (3.19)$$

olduğundan dolayı, (3.15) ve (3.16) denklemler aşağıdaki gibi basitleştirilmiş olur.

$$\frac{\partial F}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad , \quad (3.20)$$

$$\frac{\partial F}{\partial b_i^m} = s_i^m \quad (3.21)$$

tahmini steepest descent algoritması

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (3.22)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (3.23)$$

olur. Bunu matris formunda yazarsak

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad , \quad (3.24)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad , \quad (3.25)$$

olur. Burada

$$s^m \equiv \frac{\partial F}{\partial n^m} = \begin{bmatrix} \frac{\partial F}{\partial n_1^m} \\ \frac{\partial F}{\partial n_2^m} \\ \vdots \\ \frac{\partial F}{\partial n_{s^m}^m} \end{bmatrix} \quad (3.26)$$

olur. Hassaslıklar için tekrar eden ilişkilerin türevini almak için, aşağıdaki Jacobian matrisini kullanılır.

$$\frac{\partial n^{m+1}}{\partial n^m} = \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (3.27)$$

matrisin ifadesini bulmak için matrisin  $i, j$  elamanını göz önünde bulundurulur.

$$\begin{aligned} \frac{\partial n_i^{m+1}}{\partial n_j^m} &= \frac{\partial \left( \sum_{i=1}^{s^m} w_{i,1}^{m+1} a_i^m + b_i^{m+1} \right)}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} \\ &= w_{i,j}^{m+1} \frac{\partial f^m(n_j^m)}{\partial n_j^m} = w_{i,j}^{m+1} f^m(n_j^m) \end{aligned} \quad (3.28)$$

burada

$$f^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m} \quad (3.29)$$

bundan dolayı Jacobian matrisi

$$\frac{\partial n^{m+1}}{\partial n^m} = W^{m+1} F^m \cdot (n^m), \quad (3.30)$$

yazılabilir. Burada

$$F^m(n^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \cdot & 0 \\ 0 & f^m(n_2^m) & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & f^m(n_{s^m}^m) \end{bmatrix} \quad (3.31)$$

olur. Matris formunda zincir kuralı uygulayarak hassaslık için tekrarlı ilişki yazılabilir.

$$\begin{aligned} s^m &= \frac{\partial F}{\partial n^m} = \left( \frac{\partial n^{m+1}}{\partial n^m} \right) \frac{\partial F}{\partial n^{m+1}} = F^m(n^m)(W^{m+1})^T \frac{\partial F}{\partial n^{m+1}} \\ &= F^m(n^m)(W^{m+1})^T s^{m+1} \end{aligned} \quad (3.32)$$

Hassaslıklar son tabakadan ilk tabakaya doğru yayılırlar.

$$s^M \rightarrow s^{M-1} \rightarrow \dots \rightarrow s^2 \rightarrow s^1 \quad (3.33)$$

Geriye yayılma algoritması tahmini steepest descent algoritmasını kullanır. Mesele, ilk hassaslıkları geriye yaymada ihtiyaç duyulan gradyanti hesaplamaktır. Geriye yayılma algoritmasını tamamlamak için bir veya birkaç adıma daha ihtiyaç duyulur. Denklem (3.32)'nin tekrarlı ilişkisi için başlama noktası ( $s^M$ ) kullanılır.

$$s_i^M = \frac{\partial F}{\partial n_i^M} = \frac{\partial((t-a)^T(t-a))}{\partial n_i^M} = \frac{\partial \sum_{j=1}^{s^M} (t_j - a_j)^2}{\partial n_i^M} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (3.34)$$

ve

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial f^M(n_j^M)}{\partial n_i^M} = f^M(n_j^M) \quad (3.35)$$

olduğu için

$$s_i^M = -2(t_i - a_i) f^M(n_j^M) \quad (3.36)$$

yazılabilir. Bu matris formunda ifade edilirse

$$s^M = -2F^M(n^M)(t - a) \quad (3.37)$$

şeklinde ifade edebiliriz.

Yukarıda açıklanan geriye yayımlı algoritmayı özetleyecek olursak:

İlk adım girişten ağa doğru yaymaktır.

$$a^0 = p \quad (3.38)$$

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \quad m=0,2,\dots,M-1 \quad (3.39)$$

$$a = a^M \quad (3.40)$$

sonraki adım hassaslıkları ağdan geriye doğru yaymaktır.

$$s^M = -2F^M(n^M)(t - a) \quad (3.41)$$

$$s^m = F^m(n^M)(W^{m+1})^T s^{m+1} \quad m=M-1,\dots,2,1 \quad (3.42)$$

Son olarak tahmini steepest descent algoritması kullanarak ağırlıklar ve biasların güncellenmesidir.

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (3.43)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (3.44)$$

momentum terimini eklenirse

$$\Delta W^m(k) = \gamma \Delta W^m(k-1) - (1-\gamma) \alpha s^m (a^{m-1})^T \quad (3.45)$$

$$\Delta b^m = \gamma \Delta b^m(k-1) - (1-\gamma) \alpha s^m \quad (3.46)$$

elde edilir.

### 3.2.9.b. Levenberg- Marquardt algoritması

Geri yayılım algoritması (GYA) çok kullanılmasına rağmen bazı dezavantajları bulunmaktadır. GYA sonuca çok yavaş olarak yaklaşmaktadır. Ayrıca yerel minimuma yakalanma riski de vardır. Geri yayılım, bir adım düşme algoritmasıyken, Levenberg - Marquardt (LM) algoritması Newton metoduna bir yaklaşımdır. LM algoritması, Newton metodunun hızıyla, adım düşme metodunun sağlamlığının bileşkesidir.

LM öğrenme algoritması minimumu araştırma metotlarının ikincisidir. Her bir iterasyon adımında hata yüzeyine parabolik yaklaşımla yaklaşılar ve parabolün minimumu o adım için çözümü oluşturur.  $E(x)$  fonksiyonuna sahip olduğumuzu ve  $\underline{x}$  parametresine göre minimize etmek istediğimizi düşünelim. Newton metodunda şöyle olacaktır.

$$\Delta \underline{x} = -[\nabla^2 E(\underline{x})]^{-1} \nabla E(\underline{x}) \quad (3.47)$$

burada  $\nabla^2 E(\underline{x})$  ifadesi Hessian matrisidir ve  $\nabla E(\underline{x})$  ise eğimdir.  $E(\underline{x})$ 'in karelerin toplamı fonksiyonu olduğunu farz edelim.

$$E(\underline{x}) = \sum_{i=1}^N e_i^2(\underline{x}) \quad (3.48)$$

bundan sonra şöyle gösterilebilir.

$$\nabla E(\underline{x}) = J^T(\underline{x}) e(\underline{x}) \quad (3.49)$$

$$\nabla^2 E(\underline{x}) = J^T(\underline{x}) J(\underline{x}) + S(\underline{x}) \quad (3.50)$$

burada  $J(x)$  Jacobian matristir.

$$J(\underline{x}) = \begin{bmatrix} \frac{\partial e_1(\underline{x})}{\partial x_1} & \frac{\partial e_1(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_1(\underline{x})}{\partial x_n} \\ \frac{\partial e_2(\underline{x})}{\partial x_1} & \frac{\partial e_2(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_2(\underline{x})}{\partial x_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_N(\underline{x})}{\partial x_1} & \frac{\partial e_N(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_N(\underline{x})}{\partial x_n} \end{bmatrix} \quad (3.51)$$

ve

$$S(\underline{x}) = \sum_{i=1}^N e_i(\underline{x}) \nabla^2 e_i(\underline{x}) \quad (3.52)$$

Gauss-Newton metodu için  $S(\underline{x}) \approx 0$  kabul edilir ve (16) güncellenerek şu hale gelir.

$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x})]^{-1} J^T(\underline{x})e(\underline{x}) \quad (3.53)$$

Levenberg-Marquardt modifikasyonuyla Gauss-Newton metodu şöyle olur.

$$\Delta \underline{x} = [J^T(\underline{x})J(\underline{x}) + \mu I]^{-1} J^T(\underline{x})e(\underline{x}) \quad (3.54)$$

$\mu$  parametresi, bir adımda  $E(\underline{x})$  artımı sonucunda bir faktörle ( $\beta$ ) ile çarpılır, bir adım  $E(\underline{x})$  azaltışında,  $\mu$  parametresi  $\beta$ 'ya bölünür.  $\mu$  büyükse algoritma adım düşümü ( $1/\mu$  adımı ile) olur, küçük  $\mu$  parametresi için algoritma Gauss-Newton olur.

Bu algoritmadaki anahtar adım Jacobian matrisinin hesaplanmasıdır. Yapay sinir ağı tasarım probleminde Jacobian matristeki terimler geri yayılım algoritmasının basitçe değiştirilmesiyle hesaplanabilir. Bu, (3.48)'deki eşitlikte kolayca görülebilir. Burada

$\underline{x} = [w^1(1,1)w^1(1,2)...w^1(S1,R)b^1(S1)w^2(1,1)...b^M(SM)]^T$  ve  $N=Qx$  SM. Standart geri yayılım algoritması terimleri şöyle hesaplanır;

$$\frac{\partial E}{\partial w^k(i,j)} = \frac{\partial \sum_{m=1}^{SM} e_q^2(m)}{\partial w^k(i,j)} \quad (3.55)$$

Levenberg-Marquardt algoritması için Jacobian matrisin elemanları şöyle hesaplanabilir.

$$\frac{\partial e_q(m)}{\partial w^k(i,j)} \quad (3.56)$$

bu terimler standart geri yayılım algoritması kullanılarak son katmanda bir değişiklik hesaplanabilir.

$$\Delta^M = -\dot{F}^M(n^M) \quad (3.57)$$

(3.51)'deki matrisin her bir kolonu bir vektördür, Jacobianın bir satırını üretmek için ağ geri yayınılmalıdır.

Sonuç olarak Levenberg-Marquardt algoritması çok hızlı olarak çözüme ulaşmasına rağmen çok fazla bellek gerektirmektedir. Geri yayılım algoritması ise sonuca yavaş ulaşmakta ve daha az bellek gerektirmektedir.



## 4. ARAŞTIRMA BULGULARI

### 4.1 Model Girdileri

Çalışmada kullanılan veriler Çizelge 4.3.'de çeşitli kaynaklardan yararlanarak oluşturulmuştur (TÜİK, 1998; DPT 1998; OECD, 1982; 2006). Nüfus (N), kişi başına gayri safi milli hasıla (KBGSMH), ortalama otomobil fiyatı (OOF), normal benzin fiyatı (NBF), ve yol uzunlukları (YU) bağımsız değişken olmak üzere beş açıklayıcı değişkenden otomobil sahipliği modellenmeye çalışılmıştır. Açıklayıcı değişkenler için çoklu regresyon ve YSA modelleri oluşturulmuştur.

#### 4.1.1 Değişkenler arasında korelasyon analizi

**Çizelge 4.1.** Değişkenlerin korelasyon matrisleri

	Nüfus	Kbgsmh	OOF	NBF	YU	OS
Nüfus	1,00					
Kbgsmh	0,95	1,00				
OOF	0,39	0,43	1,00			
NBF	0,78	0,67	0,71	1,00		
YU	0,96	0,88	0,26	0,75	1,00	
OS	0,94	0,95	0,43	0,72	0,89	1,00

Çizelge 4.1. korelasyon matrisi incelenirse bağımlı değişken otomobil sahipliği bağımsız değişkenler ise ( nüfus, kişi başına gayri safi milli hasıla, ortalama otomobil fiyatı, normal benzin fiyatı ve yol uzunlukları ) arasında pozitif bir ilişki bulunmaktadır. Bu da ilişkilerin normal olduğu anlamına gelir. En yüksek ilişki yol uzunluğu ( $r = 0,96$ ) ve nüfus ( $r = 0,95$ ) olduğu görülmektedir. Bağımsız değişkenler arasındaki korelasyon katsayıları çoklu doğrusal bağlantıya neden olacak kadar büyüktür.

## 4.2. Modellerin Uygulanması

### 4.2.1 Çoklu regresyon modeli

Modelde çoklu regresyon analizinden yararlanılmıştır. Çizelge 4.2.'den de görüldüğü gibi model parametreleri en-küçük kareler (EKK) metodu yardımıyla tahmin edilmiştir. Model parametrelerinin anlamlılığı t testi, modelin genel anlamlılığı F testi, %5 önem düzeyinde test edilmiştir. Açıklayıcı değişkenlerin otomobil sahipliğini açıklama derecesi R (Korelasyon Katsayısı) hesaplanmıştır. İstatistikî analizler Statistica paket programı yardımıyla yapılmıştır.

**Çizelge 4.2.** Regresyon modeli ile ilgili parametreler ve testler

Parametreler	Standardize olmamış katsayılar		Standardize edilmiş katsayılar		t-değeri	p-değeri
	Beta	Standart hata	Beta	Standart hata		
Sabitler			-63,0216	7,2811	-8,65551	0,000000
Nüfus	0,205325	0,381366	0,0000	0,00000	0,53839	0,596247
KBGSMH	0,756016	0,256300	0,0001	0,00002	2,94973	0,007922
OOF	-0,072098	0,146010	-0,0003	0,00067	-0,49379	0,626834
NBF	0,183037	0,205913	12,7256	14,31603	0,88891	0,384620
YU	-0,098532	0,285921	-0,0000	0,00006	-0,34461	0,733984

Regresyon model tipi aşağıda belirtildiği gibidir.

Model

Bağımlı Değişken (Çıktı) : Otomobil Sahipliği

Bağımsız Değişkenler (Girdiler) : Nüfus, Kişi Başına Gayri Safi Milli Hasıla, Otomobil Fiyatı, Benzin Fiyatı ve Yol Uzunluklarıdır.

Çizelge 4.3. Türkiye’de otomobil sahipliğini etkileyen değişkenler

YILLAR	NÜFUS	KBGSMH	OOF <sup>1</sup>	NBF <sup>1</sup>	OTOYOL, İL, DEVLET;	OTOMOBİL SAHIPLİLİĞİ
					KÖY YOLU	
1970	35.605.176	968.079		0,11	221.508	2
1971	36.506.845	1.010.697	3.588	0,1	221.524	3
1972	37.431.349	1.076.083	4.103	0,1	221.503	3
1973	38.379.264	1.100.985	4.343	0,1	229.482	4
1974	39.351.185	1.108.815	4.767	0,19	231.629	6
1975	40.347.719	1.146.915	5.163	0,19	231.199	7
1976	41.189.686	1.224.529	5.484	0,19	231.745	9
1977	42.049.222	1.235.322	6.638	0,22	231.537	10
1978	42.926.696	1.224.929	11.101	0,34	231.848	11
1979	43.822.480	1.194.003	16.793	0,65	232.189	12
1980	44.736.957	1.137.089	10.961	0,53	232.891	13
1981	45.864.201	1.162.494	7.832	0,57	329.556	14
1982	47.019.848	1.168.936	6.928	0,53	295.126	14
1983	48.204.615	1.188.247	6.239	0,51	303.708	14
1984	49.419.234	1.241.416	4.884	0,44	310.402	15
1985	50.664.458	1.262.998	5.230	0,46	316.891	16
1986	51.776.292	1.319.424	5.470	0,47	320.792	18
1987	52.912.526	1.417.800	6.575	0,33	328.184	19
1988	54.073.694	1.407.489	7.101	0,36	330.500	21
1989	55.260.344	1.399.689	7.621	0,44	356.291	23
1990	56.473.035	1.497.913	9.809	0,62	368.006	26
1991	57.344.826	1.480.292	9.539	0,69	368.210	29
1992	58.230.074	1.551.132	9.828	0,68	387.121	34
1993	59.128.989	1.651.924	10.598	0,6	388.093	41
1994	60.041.780	1.527.820	7.660	0,51	381.028	44
1995	60.968.663	1.624.248	9.558	0,62	381.300	46
1996	61.909.854	1.713.456	9.841	0,66	381.740	49
1997	62.865.574	1.827.299	9.201	0,71		53
1998		1.870.064	10.317	0,73		56

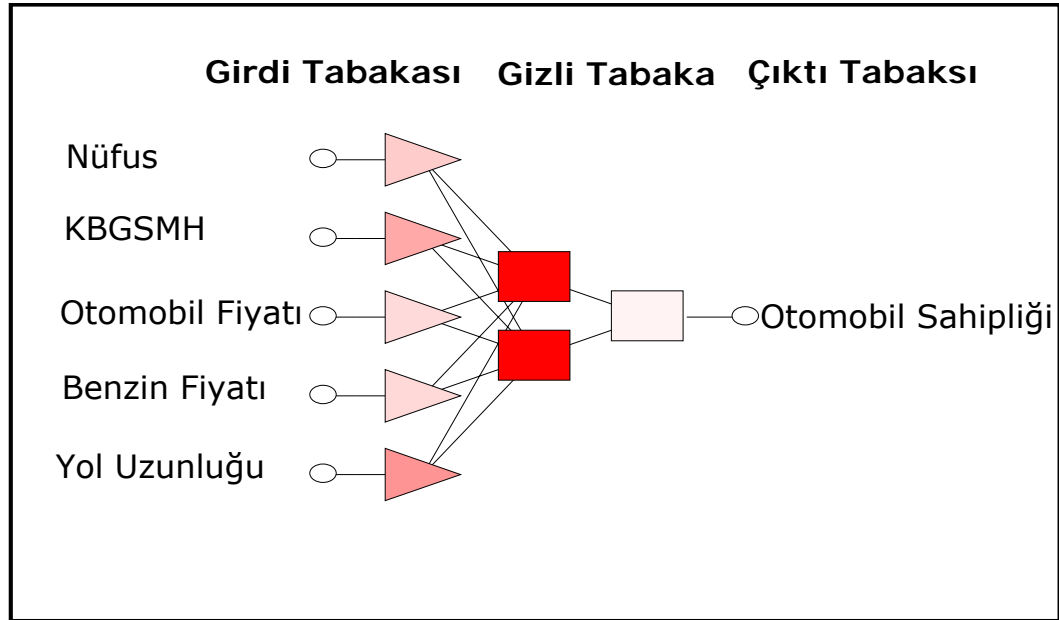
#### 4.2.2 YSA modeli

YSA modelinde, bağımsız değişkenler girdi, bağımlı değişkenler ise çıktı olarak isimlendirilir. Bu çalışmada kullanılan model için girdiler ve çıktılar aşağıdaki gibidir:

Model

Bağımlı Değişken (Çıktı) : Otomobil Sahipliği

Bağımsız Değişkenler (Girdiler) : Nüfus, Kişi Başına Gayri Safi Milli Hasıla, Otomobil Fiyatı, Benzin Fiyatı ve Yol Uzunluklarıdır.



**Şekil 4.1.** Otomobil sahipliği modeline ait YSA mimarisi

Türkiye'nin otomobil sahipliği verileri ile oluşturulan YSA modelinde verilerin yetersizliğine istinaden tek bir gizli tabakaya sahip ağ mimarisi düşünülmüştür. Gizli tabakada, en iyi performansı gösteren iki işlem (sinir) elemanı kullanılmış ve oluşturulan modele ait YSA mimarisi Şekil 2'de gösterilmiştir. İşlemler statistica programının neural network toolbox'ları kullanılarak yapılmıştır. Performans ölçütü olarak aşağıda 2,3 ve 4 denklemleri ile verilen bilgi kriterleri kullanılmıştır. Verilerin %80'i eğitimde, %20'side teste kullanılmıştır. Eğitim algoritması olarak Levenberg-Marquardt algoritması kullanılmıştır. Aktivasyon fonksiyonu olarak log sigmoid

fonksiyonu kullanılmıştır. Eğitimden sonraki ağın performans değerleri ve ağırlık katsayıları bulunmuştur.

$$AIC = \log ( MSE ) + 2 * ( m+1 ) / N \quad (4.1)$$

$$MSE = 1 / N * \sum_{i=1}^n (t_{mi} - t_{gi})^2 \quad (4.2)$$

$$RMSE = \sqrt{\frac{1}{N} MSE} \quad (4.3)$$

Burada;

MSE = Hata Kareler Ortalaması

$t_{mi}$  = i. Gözlem değeri

$t_{gi}$  = i. Model değeri

N = Eğitilen veri sayısı

m = Modeldeki parametre sayısı (Ağ yapısında ağırlıklar ve sabitlerin toplam sayısıdır.)

Duyarlılık analizi, parametrelerin ağdaki etkinliğini araştırır. Bu çizelgeden, en önemli parametrenin nüfus (N) olduğu, daha sonra sırasıyla; kişi başına gayri safi milli hasıla (KBGSMH), ortalama otomobil fiyatı (OOF), yol uzunlukları (YU) ve normal benzin fiyatının (NBF) olduğu görülmektedir.

**Çizelge 4.4.** ( 5x2x1 ) Modelinin duyarlılık analizi sonucu

	Nüfus	KBGSMH	OOF	NBF	YU
ORAN	26,07751	22,01492	10,96588	10,93908	8,681509
DERECE	1	2	3	4	5

Ağ eğitilmeden önce, giriş ve çıkış verileri normalleştirilmiştir. Her bir giriş ve çıkışın normalleştirilirken kullanılan çarpım katsayıları ve sabitleri Çizelge 4.5.'de verilmiştir.

**Çizelge 4.5.** Ağın normalleştirme katsayıları

İSİM	SABİT	ÇARPIM KATSAYISI
NUFÜS	-1,55118	4,25E-08
KBGSMH	-1,57619	1,56E-06
OOF	-0,2717	7,57E-05
NBF	-0,1695	1,694915
YU	-1,32963	6E-06
OTOMOBİL SAHİPLİĞİ	-0,07317	0,02439

Modelin genel denklemi aşağıdaki gibidir.

$$OS = f_2 \left( [W_2] f_1 \left( [W_1] \begin{bmatrix} N \\ KBGSMH \\ OOF \\ NBF \\ YU \end{bmatrix} + [b_1] \right) + [b_2] \right) \quad (4.4.)$$

$W_1$ ,  $W_2$ ,  $b_1$ , ve  $b_2$  matrislerinin değerleri (4.7., 4.8.,4.9.,4.10.)'dan alınabilir. Transfer fonksiyonları da aşağıdaki gibidir. Ağırlık katsayıları ve biaslar, normalleştirilmiş veriler için elde edilen değerlerdir. Bir noktadaki gerilme artışını belirlemek için, her bir değişkenin Çizelge 4.4.'de gösterilen çarpım katsayıları ve sabitler kullanılarak normalleştirilmesi gerekmektedir. Daha sonra bu değerlerin denklem 4.4. de yerine konularak sonucun bulunup Çizelge 4.4.'deki çıkış tabakası için verilen çarpım katsayısı ve sabit değeri kullanılarak ters dönüşüm yapılmalıdır.

$$f_1 = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (4.5.)$$

$$f_2 = \frac{1}{1 + e^{-n}} \quad (4.6.)$$

(5x2x1) mimariye sahip ağın ağırlık katsayıları ve biasları

$$W_1 = \begin{pmatrix} -1,90622 & -0,2287 & 1,63044 & -0,771 \\ -2,10107 & -0,7623 & 1,545896 & -0,4706 \end{pmatrix} \quad (4.7.)$$

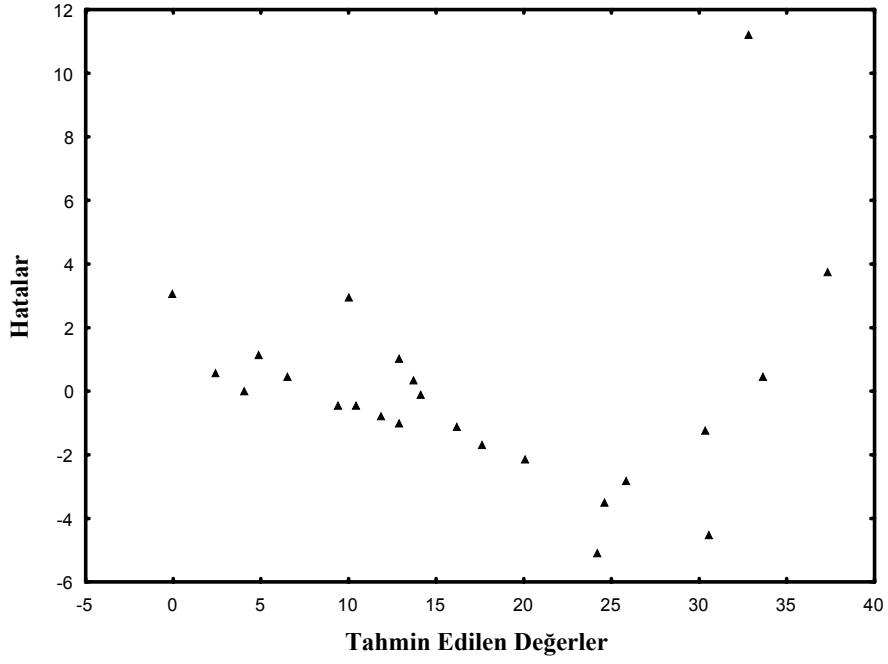
$$W_2 = (86,98549 \quad -98,1205) \quad (4.8.)$$

$$b_1 = (-4,99356 \quad -5,53618) \quad (4.9.)$$

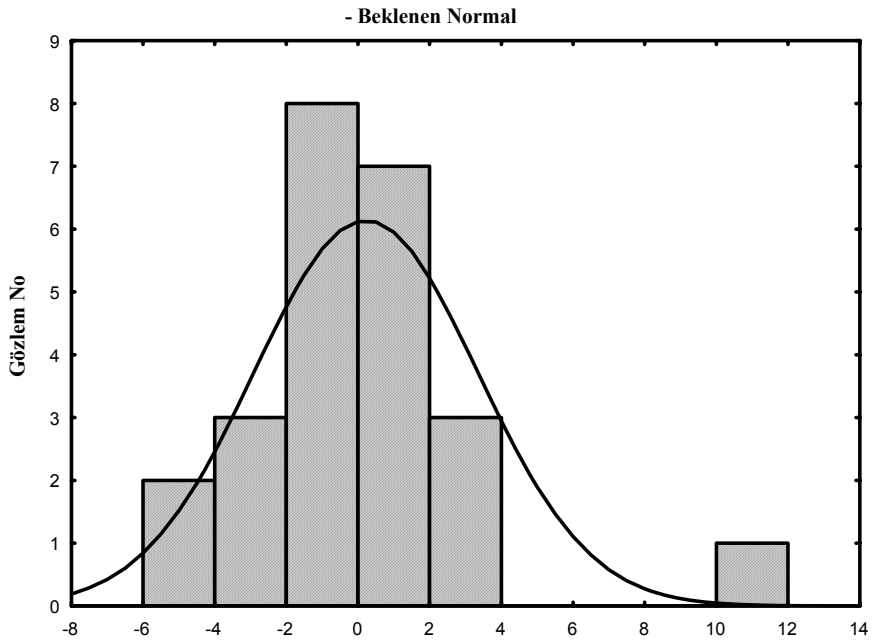
$$b_2 = (-11,3317) \quad (4.10)$$

**Çizelge 4.6.** Modellere ait bilgi kriterleri

Modeller	AIC	RMSE	R
YSA	1,12	0,75	0,99
Regresyon	1,50	3,17	0,91




Şekil 4.2. Tahmin edilen değerler ile hataların dağılımı




Şekil 4.3. Hataların histogramı

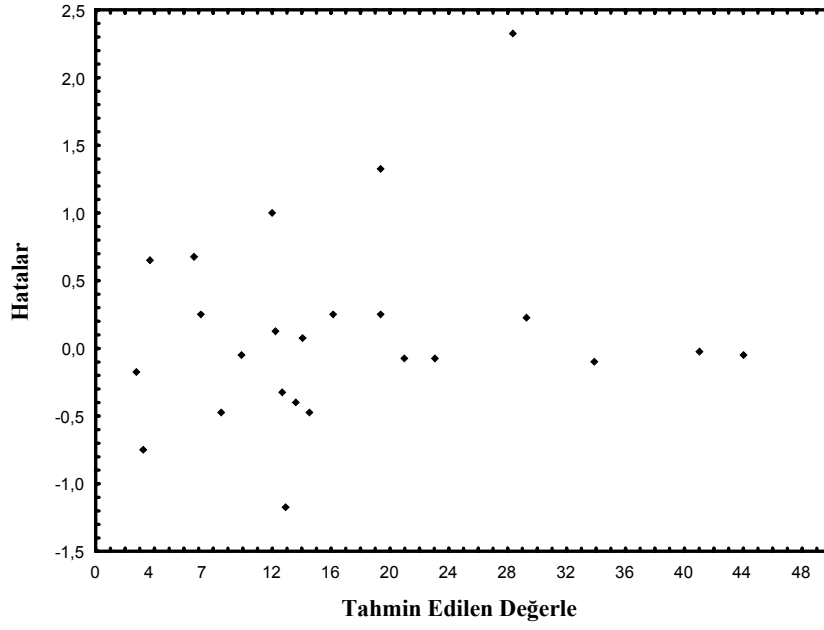





Şekil 4.4. Hataların normal olasılık grafiği




Şekil 4.5. Tahmin edilen değerler ile gözlenen değerler arasındaki ilişki



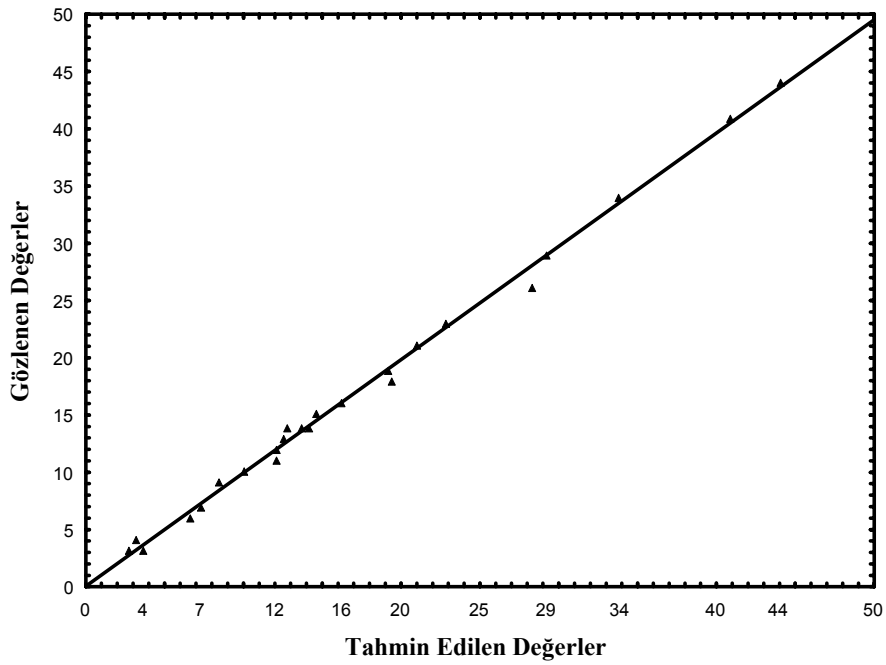
Şekil 4.6. Tahmin edilen değerler ile hataların dağılımı



Şekil 4.7. Hataların histogramı



Şekil 4.8. Hataların normal olasılık grafiği



Şekil 4.9. Tahmin edilen değerler ile gözlenen değerler arasındaki ilişki

## 5. SONUÇ

Bu çalışmada Otomobil Sahipliğinin Yapay Sinir Ağları (YSA) ve Çoklu Regresyon Analizi ile modellenmesi yapılmıştır.

YSA kullanılarak gerçekleştirilen otomobil sahipliği modelinden elde edilen sonuçlar; çoklu regresyon model sonuçları ile karşılaştırılmıştır. Çoklu regresyon modelinin katsayıları istatistikî test sonuçlarına göre anlamlı bulunmamıştır. Modele ait R (korelasyon katsayısı) değeri çok düşük olması modeldeki açıklayıcı değişkenlerin bağımlı değişkeni açıklama oranının yeterli olmadığını göstermiştir. Modelin hatalarının tam normal dağılım göstermediği, tahmin edilen değerler ile hataların dağılımının 0 (sıfır) çizgisi üzerinde olmadığı, standardize hata histogramlarının sağa ve sola doğru çok açık olduğunu, sıfır hata frekansının düşük olduğu ve tahmin edilen değerler ile gözlenen değerler arasında iyi bir uyum olamadığı görülmektedir. Çoklu regresyon modeli otomobil sahipliği olayını açıklayamamaktadır.

YSA modelinin hatalarının normal dağılım göstermediği, modelde tahmin edilen değerler ile hataların dağılımının 0 (sıfır) çizgisi üzerine yakın olduğu görülmüştür. Modele ait korelasyon katsayısı değeri yüksek bulunmuş ve modeldeki açıklayıcı değişkenlerin bağımlı değişkeni açıklama oranının yeterli olduğuna kanaat getirmiştir.

YSA modelinin daha küçük RMSE ile yüksek korelasyon katsayılarının yanı sıra, çoklu regresyon modeline göre AIC'lerinin da düşük olduğu göz önüne alındığında, modelin üstünlüğü göze çarpmaktadır. Sonuç olarak otomobil sahipliğinin doğrusal olmayan davranışını temsil etmede YSA modeli başarılı olmuştur.

**KAYNAKLAR**

- Aiken, M., 1999. Using A Neural Network to Forecast Inflation. *Industrial Management and Data Systems*, 99(7), 296–301.
- Allanson, E. W., 1982. *Car Ownership Forecasting*, Gordon & Breach.
- Anderson, J. A., 1995. *An Introduction to Neural Networks*. Cambridge, MA: MIT Press.
- Barnard, E., 1992. Optimization for training neural nets. *IEEE Transactions on Neural Networks*, 3(2), 232–240.
- Bullock, D., Garrett, J. and Hendrickson, C., 1993. A neural network of image-based vehicle detection. *Transpn.Res.-C*, 1, 235-247.
- Button, K. J., Fowkes A. S. and Pearman A. D., 1980. Disaggregate and Aggregate Car Ownership Forecasting in Great Britain, *Transportation Research A*, Vol 14 A, pg: 263–273.
- Button, K. J., Pearman A. D. and Fowkes A. S., 1982. *Car Ownership Modelling and Forecasting*, Gower.
- Button, K. J., Hine, J. and Ngoe, N., 1992. Car Ownership Forecasts for Low Income Countries, *Traffic Engineering & Control*, December, pg: 666-671.
- Chiang, Y.S., Roberts, P.O. and Ben-Akiva, M., 1981. Development of a Policy Sensitive Model Forecasting Freight Demand. Final Report, Center for Transportation Studies, Massachusetts Institute of Technology, Cambridge, Massachusetts.
- Chin, S. M., Hwang, H. L. and Miaou, S. P., 1992. Transportation demand forecasting with a computer-simulated neural network model. *Proc. Int Conf. on Artificial Intelligence Applications in Transportation Engineering San Buenaventura. CA.*
- Clark, S. D., Dougherty, M. S. and Kirby, H. R., 1993. The use of neural network and time series modes for short term forecasting: a comparative study. *Proc. PTRC Summer Meeting, Manchester.*
- Daniels, H. and Kamp, B., 1999. Application of MLP Networks to Bond Rating and House Pricing. *Neural Computation and Applications*, 8, 226-234.
- Demir, Y.K., 1997. *Yapay Sinir Ağları İle Ulaştırma Taleplerinin Modellenmesi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Dargay, J. and Gately D., 1999. Income's Effect on Car and Vehicles Ownership, Worldwide: 1960-2015, *Transportation Research A*, no: 33, pg: 101–138.
- DPT, (1950–1998). *Devlet Planlama Teşkilatı ve Sosyal Göstergeler*, Ankara.
- Dougherty, M. S. and Joint, M., 1992. A behavioural model of driver route choice using neural networks. *Proc. Int. Conf. on Artificial Intelligence Applications in Transportation Engineering, San Buenaventura, CA.*
- Dougherty, M. S., Kirby, H. R. and Boyle, R. D., 1994. Using neural networks to recognise predict and model traffic. *Artificial Intelligence Applications to Traffic Engineering* (Bielli, Ambrosino and Boero, Eds). VSP, Utrecht.
- Dougherty, M. S. and Cobbett, M., 1994. Short term inter-urban traffic forecasts using neural networks. *Proc. 2<sup>nd</sup> DRIVE-II Workshop tm Shorn-Term Forecasting, Delft. The Netherlands.*

- Erentürk, K., 2002. Güç Sistemleri İçin Akıllı Bir Koruma Rölesi. Doktora Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Faghri ,A. and Hua, J. , 1992. Evaluation of artificial neural network applications in transportation engineering. *Transportation Research Record*, 1358, 71-80.
- Faraway, J., Chatfield, C. , 1998. Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data. *Application Statistics*, 47 (2) , 231–250.
- Grossberg, S., 1990. *Neural networks: From foundations to applications*, Short-Course Notes, Boston University, Boston, MA, 6-11.
- Hajek, J. and Hurdal, B., 1993. Comparison of rule-based and neural network solutions for a structured selection problem. *Transportation Research Record*, 1399, 1-7.
- Hencht-Nielsen, R Fowkes A. S., 1990. *Neurocomputing*, Reading, MA: Addison-Wesley.
- Hua, J. and Faghri, A., 1993. Dynamic traffic pattern classification using artificial neural networks. *Transportation Research Record*, I 399, 14-19.
- Hutchinson, M. J., 1979. Multi-variable Models of Car Ownership, *Traffic Engineering & Control*, September, pg: 399–402.
- Kaseko, M. S. and Ritchie, S. G., 1992. A neural network-based methodology for automated distress classification of pavement images. *Proc Int. Conf. on Artificial Intelligence Applications in Transportation Engineering*. San Buenaventura. CA.
- Kaseko, M. S. and Ritchie, S. G. ,1993. A neural network-based methodology for pavement crack detection and classification. *Transpn. Res.-C*, 1, 275-291.
- Keleş, H.E., 1998. Kentlerarası Yük Taşımacılığında Talep Modellerinin İncelenmesi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Kirby, H. R., Boyle, R. D. and Dougherty, M. S. , 1993. Recognition of road traffic patterns using neural networks. *Conf. on Informing Technologies for Construction*. Civil Engineering and Transport, Brunei.
- Kornhauser, A., 1991. Neural network approaches for lateral control of autonomous highway vehicles. *Proc. Vehicle Navigation and Information Systems Con/.*, 1143-1151.
- Law, R., 1998. Room Occupancy Rate Forecasting: A Neural Network Approach. *International Journal of Contemporary Hospitality Management*, 10 (6) , 234-239.
- Lyons, G. and Hunt, J., 1993. Traffic modelling—a role for neural networks? *Proc. Third Int. Conf. on the Application of Artificial Intelligence to Civil and Structural Engineering*, Edinburgh, U.K.
- Lyons, G. , 1994. Calibration and validation of a neural network driver decision model. *Traff. Engng Contr.*, 36,10-15.
- Matsuyama ,Y., 1991. Self-organization via competition, cooperation and categorization applied to extended vehicle routing problems. *Proc. Int. Joint Conf. on Neural Networks*, Seattle.
- McCulloch, W. S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 3, 115-133.
- Mead, W. C., Fisher, H. N., Jones, R. D., Bisset, K. R., and Leopold, A. L., 1994. Application of adaptive and neural network computational techniques to traffic

- volume and classification monitoring. Preprints of Transport Research Board Conf., Washington, DC.
- Nasır, M.L., John, R.I., Bennett, S.C., Russell, D.M. , 2001. Selecting the Neural Network Topology for Student Modelling of Prediction of Corporate Bankruptcy, *Campus Wide Information Systems*, 18 (1) , 13-22.
- Neusser, S., Hoefflinger, B., Nijhuis J., Siggelhow, A. and Spaanenburg, L., 1991. A case study in car control by neural networks. 24th I SAT A Int. Symp. on Automotive Technology and Automation, Florence.
- OECD, 1982. Forecasting Car Ownership and Use, Road Research, May, France
- Oliveria, K.A., Vannucci, A., Sjlva, E.C., 2000. Using Artificial Neural Networks to Forecast Chaotic Time Series. *Physica A*, 284, 393-404.
- Ortuzar, J. D. and Willumsen, L. G., 1990. *Modelling Transport*, John Wiley and Sons.
- Öğüt, K. S., 2000. Türkiye’de Otomobil Sahipliğinin Modellenmesi, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimler Enstitüsü, İstanbul, Türkiye.
- Öğüt K. S., 2001. Türkiye’de Otomobil Sahipliğinin Modellenmesi, 5. Ulaştırma Kongresi, İstanbul.
- Pant, P. D. and Balakrishman, P., 1994. Neural network for gap acceptance at stop-controlled intersections. *J. Transpn. Engng.*, 120(3), 432-446.
- Pant ,P. D., Zhou, X., Arudi ,R. S., Bodocsi, A. and Aktan, A. E. , 1993. Neural-network-based procedure for condition assessment of utility cuts in flexible pavements. *Transportation Research Record*, 1399, 8-13.
- Pao, Y. H., 1989. *Adaptive Pattern Recognition and Neural Network.*, Reading, MA: Addison-Wesley.
- Potuin, J.-Y. and Shen ,Y. , 1991. A neural network approach to the vehicle dispatching problem. *IEEE Int. Conf.on Neural Networks*. Singapore.
- Raggad, B.G., 1996. Neural Network Technology for Knowledge Resource Management. *Management Decision*, 34 (2) , 20-24.
- Rewinski ,S., 1992. The neural designing in pavement management. *Proc. Int. Conf. on Artificial Intelligence Applications in Transportation Engineering*, San Buenaventura, CA.
- Ritchie, S. G. and Cheu ,R. L., 1993. Simulation of freeway incident detection using artificial neural networks. *Transpn. Res.-C* , I , 203-217.
- Smith, M., 1993. *Neural Networks for Statistical Modeling*. New York: Van Nostrand Reinhold.
- Subba Rao, P. V., Sikdar, P. K., Krishna Rao, K. V., and Dhingra, S. L., 1998. Another Insight Into Artificial Neural Network Through Behavioural Analysis of Access Mode Choice. *Comput., Environ. And Urban Systems*, 22 (5), 485-496.
- Tanner, J., 1974. *Forecasts of Vehicles and Traffic in Great Britain*.
- Tanner, J. C., 1983. *A Lagged Model for Car Ownership Forecasting TRRL-1072*.
- Tortum A. , Yayla N. , Gökdağ M., 2005. Yapay Sinir Ağları ve Birleştirilmiş Sinirsel Bulanık Sistemler ile Şehirlerarası Yük Taşımada Tür Seçiminin Modellenmesi, 6. Ulaştırma Kongresi, İMO İstanbul Şubesi, İstanbul.
- TÜİK, (1970–1998). *Türkiye İstatistik Kurumu*.
- Vasconcellos E. A., 1997. The Demand for Cars in Developing Countries, *Transportation Research A Vol: 31, No: 3, Pg: 245-258*.

- Venugopal, V., Beats, W., 1994. Neural Networks and Statistical Techniques in Marketing Research: Conceptual Comparison, Marketing Intelligence and Planning, 12 (7) , 30-38.
- Yang, H., Akiyama, T. and Sasaki, T., 1992. A neural network approach to the identification of real time origin-destination flows from traffic counts. Proc. Int. Conf. on Artificial Intelligence Applications in Transportation Engineering, San Buenaventura, CA.



## ÖZGEÇMİŞ

Yazar 1980 yılında Erzurum'da doğdu. İlk, orta ve lise öğrenimini Erzurum'da tamamladı. 1999 yılında kazandığı Atatürk Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü'nden 2003 yılında başarılı bir şekilde mezun oldu. 2003–2004 yılında Bakû–Tbılısı–Ceyhan Crude Oil Pipeline Project–Lotb Streicher–Haustadt & Timmermann–Günsayıl–Alarko Jo firmasında saha mühendisi olarak görev yaptı. Eylül 2005'de askerlik görevini tamamladı. 2005–2006 öğretim yılında Atatürk Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı'nda Yüksek Lisans öğrenimine başladı

Atatürk Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği Bölümü'nde Aralık 2005 tarihinden beri Araştırma Görevlisi olarak çalışmaktadır.