

**ANKARA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**TÜRKİYE ELEKTRİK Dengeleme ve Uzlaştırma Piyasasındaki  
Sistem Gün Öncesi Fiyatının Yapay Sınır Ağları  
Kullanılarak Modellenmesi**

**Mehmet Ali KÖLMEK**

**ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**ANKARA  
2012**

**Her hakkı saklıdır**

## TEZ ONAYI

Mehmet Ali KÖLMEK tarafından hazırlanan “Türkiye Elektrik Dengeleme ve Uzlaştırma Piyasasındaki Sistem Gün Öncesi Fiyatının Yapay Sinir Ağları Kullanılarak Modellenmesi” adlı tez çalışması 27/12/2012 tarihinde aşağıdaki jüri tarafından oy birliği ile Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

**Danışman** : Yrd. Doç. Dr. İsa NAVRUZ

### Jüri Üyeleri:

**Başkan:** Yrd. Doç. Dr. Süleyman TOSUN  
Ankara Üniversitesi, Bilgisayar Mühendisliği A.B.D.

**Üye** : Yrd. Doç. Dr. İsa NAVRUZ  
Ankara Üniversitesi, Elektronik Mühendisliği A.B.D.

**Üye** : Yrd. Doç. Dr. Fikret ARI  
Ankara Üniversitesi, Elektronik Mühendisliği A.B.D.

**Yukarıdaki sonucu onaylarım.**

**Prof. Dr. İbrahim DEMİR**  
Enstitü Müdürü

## ÖZET

Yüksek Lisans Tezi

### TÜRKİYE ELEKTRİK DENGELEME VE UZLAŞTIRMA PİYASASINDAKİ SİSTEM GÜN ÖNCESİ FİYATININ YAPAY SİNİR AĞLARI KULLANILARAK MODELLENMESİ

Mehmet Ali KÖLMEK

Ankara Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektronik Mühendisliği Anabilim Dalı

Danışman: Yrd. Doç. Dr. İsa NAVRUZ

Elektrik enerjisinin son kullanıcı fiyatının belirlenmesinde özellikle ikili anlaşmalar yoluyla ortaya çıkan fiyat bilgisi etkili olmaktadır. Ancak piyasa fiyatının belirlenmesi tamamen spot piyasada (gün öncesi ve gerçek zamanlı dengeleme piyasaları) gerçekleşmektedir. Bu bağlamda gün öncesi piyasası fiyatları temel birer gösterge niteliğindedir ve ikili anlaşmaların fiyatlarının belirlenmesinden yatırım kararlarının alınmasında kadar birçok konuda referans teşkil etmektedir. Özellikle gün öncesi piyasasına aktif olarak katılıp alış ve satış teklifi veren şirketler için gün öncesi piyasası fiyatının güvenilir şekilde tahmin edilebilmesi büyük önem arz etmektedir. Fiyat tahmini araştırmalarında yapay sinir ağları sıklıkla kullanılan bir yöntemdir. Bu çalışmada, yapay sinir ağları yöntemiyle Türkiye elektrik piyasasında oluşan sistem gün öncesi fiyatları tahmin edilmektedir. Bu tahmini belirlemek üzere farklı yapay sinir ağları konfigürasyonları denenmiş ve hata oranı üzerinden performans analizleri yapılmıştır. Böylece, gün öncesi elektrik piyasası fiyatlarını en iyi kestirebilen ağ topolojileri ve parametreleri belirlenerek uygun konfigürasyona ulaşılmaya çalışılmıştır.

**Aralık 2012, 88 sayfa**

**Anahtar Kelimeler:** Yapay Sinir Ağları, Türkiye Elektrik Piyasası, Dengeleme ve Uzlaştırma Piyasası, Sistem Gün Öncesi Fiyatı, Çok Katmanlı Ağ, Ortalama Mutlak Yüzde Hata.

## **ABSTRACT**

Master Thesis

### **MODELLING THE DAY AHEAD PRICE AT ELECTRICITY BALANCING AND SETTLEMENT MARKET OF TURKEY BY USING ARTIFICIAL NEURAL NETWORKS**

Mehmet Ali KÖLMEK

Ankara University  
Graduate School of Natural and Applied Sciences  
Department of Electronics Engineering

Supervisor: Asst. Prof. Dr. İsa NAVRUZ

On determination of end-user electricity energy price, mostly price information coming from bilateral contracts is effective. However, market price of electricity is mainly determined in the spot market (day-ahead and real-time balancing markets). In this regard, day-ahead market prices are basic indicators and used as a reference in many cases from determination of bilateral contract prices to investment decisions. Specifically, for companies that actively participate in the day-ahead market via purchase and sale bids, reliable forecasting of day-ahead market prices is vital. Artificial neural network is a frequently used method in price forecasting researches. In this study, day-ahead prices in Turkish electricity market are forecasted using artificial neural networks method. In this context, different artificial neural network configurations are examined and performance analyses are made based on error rate. Hence, it is tried to determine best network topologies & parameters for estimation of day-ahead electricity market prices, and reach a suitable configuration.

**December 2012, 88 pages**

**Key Words:** Artificial Neural Networks, Turkish Electricity Market, Balancing and Settlement Market, the Day Ahead Price, Multilayer Network, Mean Absolute Percentage Error.

## TEŐEKKÖR

Çalıőmalarım süresince deęerli yardımlarını, düzeltmelerini ve görüşlerini aldıęım danışmanım Yrd. Doç Dr. İsa NAVRUZ'a, yüksek lisans öğrenimimde bana destekte bulunan TÜBİTAK'a, tez yazım sürecinde beni cesaretlendirerek çalıőmalarıma destek olan ağabeyime ve aileme, özellikle de sevgili eşime teşekkür etmeyi bir borç bilirim.

Mehmet Ali KÖLMEK

ANKARA, Aralık 2012

## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT .....	ii
TEŞEKKÜR .....	iii
KISALTMALAR DİZİNİ .....	vi
ŞEKİLLER DİZİNİ .....	vii
ÇİZELGELER DİZİNİ .....	viii
1. GİRİŞ .....	1
2. YAPAY SİNİR AĞLARINA GİRİŞ .....	2
2.1 Yapay Sinir Ağları .....	2
2.2 Yapay Sinir Ağlarının Genel Özellikleri.....	2
2.4 Basit Tek Katmanlı Algılayıcı (Perseptron) .....	9
2.5 Yapay Sinir Ağlarında Öğrenme.....	13
2.5.1 Öğretmenli öğrenme .....	13
2.5.2 Destekleyici öğrenme .....	13
2.5.3 Öğretmensiz öğrenme .....	13
2.5.4 Karma stratejiler.....	14
2.5.5 Öğrenme kuralları .....	14
2.5.5.1 Hebb kuralı.....	15
2.5.5.2 Korelasyon kuralı.....	15
2.5.5.3 Instar kuralı.....	16
2.5.5.4 Kazanan hepsini alır kuralı.....	16
2.5.5.5 Outstar kuralı.....	17
2.5.5.6 Widrow-Hoff (Delta) kuralı .....	18
2.5.5.7 Hafıza tabanlı öğrenme kuralı .....	19
2.5.5.8 Boltzmann öğrenme kuralı.....	19
2.6 Çok Katmanlı Yapay Sinir Ağları.....	21
2.6.1 Çok katmanlı ağ için çalışma prosedürü .....	24
3. TÜRKİYE ELEKTRİK PİYASASI .....	28
3.1 Elektrik Piyasasının İşleyişi .....	28
3.2 Türkiye Elektrik Piyasasının Yapısı .....	29
3.2.1 Dengeleme ve uzlaştırma piyasası (DUP).....	31
3.2.2 Gün öncesi planlama (piyasası) .....	32
3.3 Sistem Gün Öncesi Fiyatının Oluşumu .....	33
3.3.1 Saatlik alış - satış teklifleri .....	34
3.3.2 Blok alış - satış teklifleri .....	35
3.3.3 Çoklu teklif ile sistem gün öncesi fiyatı oluşum örneği.....	35
4. SİSTEM GÜN ÖNCESİ FİYATININ MODELLENMESİ .....	38
4.1 Uygulanan Fiyat Tahmin Modeli Türleri .....	38
4.2 Yapay Sinir Ağları ile Yapılan Çalışmalar.....	39
4.3 Sistem Gün Öncesi Fiyatının Modelleme için Yapay Sinir Ağı Uygulaması.....	42
4.3.1 Girdilerin türü ve kapsamı.....	42
4.3.2 Uygun yapay sinir ağı modelleme ve ağ topolojisi .....	44
4.3.3 Kurulan yapay sinir ağı ve çalışma prensibi .....	48
4.4 Nümerik Çalışmalar.....	49
4.4.1 Sadece geçmiş SGÖF verileri kullanılarak modelleme .....	49

4.4.1.1 Gizli katmandaki nöron sayısına ve katman sayısına göre performans .....	52
4.4.1.2 Aktivasyon fonksiyonuna göre performans.....	57
4.4.1.3 Eğitim metodunda göre performans .....	58
4.4.2 Geçmiş SGÖF verileri ve diğer verileri kullanarak modelleme .....	60
4.4.3 Yüksek değerleri kırparak oluşturulan girdi ile modelleme.....	62
4.5 ARIMA ile Modelleme .....	65
5. SONUÇ ve TARTIŞMA .....	72
KAYNAKLAR .....	76
EK- NEWTON VE LEVENBERG-MARQUARDT METODLARI .....	81
ÖZGEÇMİŞ.....	88

## KISALTMALAR DİZİNİ

AIC	Akaike bilgi kriteri (Akaike information criterion)
AR	Otoregresyon (Autoregression)
ARCH	Otoregresif koşullu heteroskedastisite (Autoregressive conditional heteroskedasticity)
ARIMA	Otoregresif bütünleşik hareketli ortalama (Autoregressive integrated moving average)
ARMA	Otoregresif hareketli ortalama (Autoregressive moving average)
ART	Adaptif rezonans teorisi
BIC	Bayesian bilgi kriteri (Bayesian information criterion)
ÇKYSA	Çok katmanlı yapay sinir ağı
DUY	Dengeleme ve Uzlaştırma Yönetmeliği
EPDK	Enerji Piyasası Düzenleme Kurumu
EÜAŞ	Elektrik Üretim A.Ş.
GARCH	Genelleştirilmiş otoregresif koşullu heteroskedastisite (Generalised Autoregressive conditional heteroskedasticity)
HKT	Hata kareleri toplamı
KHA	Kazanan hepsini alır
MYTM	Milli Yük Tevzi Merkezi
NET	Proses elemanına giren net girdi değeri
OH	Ortalama hata
OKH	Ortalama karekök hatası
OMH	Ortalama mutlak hata
OMYH	Ortalama mutlak yüzde hata
OYH	Ortalama yüzde hata
PMUM	Piyasa Mali Uzlaştırma Merkezi
PYS	Piyasa Yönetim Sistemi
SGÖF	Sistem gün öncesi fiyatı
TEDAŞ	Türkiye Elektrik Dağıtım A.Ş.
TEİAŞ	Türkiye Elektrik İletim A.Ş.
TEK	Türkiye Elektrik Kurumu
TETAŞ	Türkiye Elektrik Ticaret ve Taahhüt A.Ş.
TKA	Tek katmanlı algılayıcı
YH	Yüzde hata
YSA	Yapay sinir ağı



## ŞEKİLLER DİZİNİ

Şekil 2.1 Biyolojik nöron modeli .....	3
Şekil 2.2 Matematiksel nöron modeli .....	4
Şekil 2.3 Farklı $\lambda$ 'lar için hiperbolik tanjant fonksiyonunun çıktısı .....	9
Şekil 2.4 Basit TKA modeli .....	10
Şekil 2.5 İkili sınıflandırmanın düzlem üzerinde gösterimi .....	11
Şekil 2.6 Kazanan hepsini alır algoritması .....	17
Şekil 2.7 Çok katmanlı yapay sinir ağı .....	21
Şekil 2.8 Çok katmanlı ağda veri akışı .....	22
Şekil 2.9 Çok katmanlı yapay sinir ağının çalışma prensibi .....	24
Şekil 2.10 Örnek çok katmanlı algılayıcı .....	25
Şekil 3.1 Elektrik Piyasasının İşleyişi .....	28
Şekil 3.2 Elektrik sisteminin fiziksel yapısı .....	29
Şekil 3.3 Elektrik piyasasının ticari yapısı .....	30
Şekil 3.5 SGÖF fiyatının arz-talep ile oluşumu .....	37
Şekil 4.1 Fiyat tahmin metotları .....	38
Şekil 4.2 Kurulan ağ yapısı ve girdi kümesi .....	49
Şekil 4.3 Geçmiş beş haftalık SGÖF verisi için öz ilinti fonksiyonu .....	51
Şekil 4.4 Gizli katmandaki nöron sayısına göre performans .....	54
Şekil 4.5 Çift katmanlı ağ performansları .....	55
Şekil 4.6 11x11x1'lik ağ ile tahmin sonucu ve gerçekleşen değerler .....	56
Şekil 4.7 Aktivasyon fonksiyonuna göre ağın performansı .....	58
Şekil 4.8 Eğitim metoduna göre hata performansı .....	60
Şekil 4.9 Farklı veriler kullanıldığında ağın performansı .....	62
Şekil 4.10 Geçmiş SGÖF verilerinin dağılımı (01/12/2009-31/12/2010) .....	63
Şekil 4.11 Yüksek fiyat değerlerini kırmanın performansa etkisi .....	65
Şekil 4.12 Örnek birim kök testi .....	67
Şekil 4.13 Otokorelasyon ve kısmi otokorelasyon fonksiyonları .....	68
Şekil 4.14 ARIMA ile tahmin edilen SGÖF ile gerçekleşen SGÖF .....	70
Şekil 5.1 Yüksek fiyat değerlerini kırmanın tahmine etkisi .....	73

## ÇİZELGELER DİZİNİ

Çizelge 2.1 Toplama fonksiyonu türleri.....	6
Çizelge 2.2 Aktivasyon fonksiyonu türleri .....	7
Çizelge 3.1 Örnek bir piyasa katılımcısı .....	36
Çizelge 3.2 Alış ve satış yönünde tüm teklifler .....	36
Çizelge 4.1 Wang ve Ramsay'in (1997) girdi kümesi .....	40
Çizelge 4.2 Girdi ve çıktılarının açıklamaları .....	41
Çizelge 4.3 Gizli katmandaki nöron sayısına göre performans .....	53
Çizelge 4.4 Çift katmanlı ağ performansları .....	54
Çizelge 4.5 Aktivasyon fonksiyonuna göre performans .....	57
Çizelge 4.6 Eğitim metodunda göre performans .....	59
Çizelge 4.7 Farklı veriler kullanıldığında ağın performansı .....	61
Çizelge 4.8 Yüksek fiyat değerlerini kırpmanın performansa etkisi.....	64
Çizelge 4.9 Kırpılmış SGÖF girdileri ile eğitim .....	65
Çizelge 4.10 Model katsayıları .....	69
Çizelge 4.11 Üç hafta için OMYH'ler .....	70
Çizelge 4.12 Üç hafta için OMYH'ler (birinci ve ikinci gecikme ile).....	71
Çizelge 5.1 Yapay sinir ağları için sonuç tablosu .....	74
Çizelge 5.2 Başarılı olan ağ seçimi .....	74
Çizelge 5.3 YSA ile ARIMA OMYH kıyaslaması .....	75

## 1. GİRİŞ

Bu çalışmanın başlıca amacı, Türkiye Elektrik Dengeleme ve Uzlaştırma Piyasasında oluşan saatlik Sistem Gün Öncesi Fiyatının, yapay sinir ağları kullanılarak modellenmesidir.

Tüm kurumların devlet elinde bulunduğu süre zarfında Türkiye elektrik piyasası bir serbest piyasa modelinden ziyade, elektrik enerjisi fiyatlarının yine devlet eliyle belirlendiği bir model olarak benimsenmiştir. Serbestleşmenin getirdiği yeniliklerden biri de elektrik enerjisi fiyatının piyasa şartları içinde, serbest piyasa koşulları altında iktisadi modellerle belirlenmesidir. Günümüzde elektrik enerjisinin fiyatı ikili anlaşmalar ve spot piyasa fiyatı yolu ile ortaya çıkmaktadır.

Elektrik enerjisinin fiyatının belirlenmesinde çoğunlukla ikili anlaşmalar yoluyla ortaya çıkan fiyat bilgisi etkili olmakla beraber spot piyasa(havuz piyasası) fiyatının etkisi de yadsınmamaktadır. Bilhassa spot piyasaya aktif olarak katılıp alış ve satış teklifi verecek şirketler için spot piyasa fiyatının tahmin edilmesi büyük bir önem arz etmektedir.

Yapılan literatür taramasına göre, ülkemizde Sistem Gün Öncesi fiyatının (spot piyasa) tahmini ve modellenmesi hususunda sınırlı sayıda çalışma yapıldığı, bulunan az sayıdaki çalışmanın ise genel itibari ile sadece zaman serisi analizleri (AR, ARMA, ARIMA) ile yapılmış olduğu gözlemlenmektedir.

Bu çalışmada sırasıyla yapay sinir ağları ve Türkiye elektrik piyasası anlatılmakta, daha sonra yapay sinir ağları ile fiyat tahmini için modelleme yollarına değinilmektedir. Nümerik örnekler üzerinden kurulan ağların farklı parametrelere göre performansları kıyaslanmakta, hangi topolojide ne tür verinin daha iyi sonuçlar ortaya çıkardığı irdelenmektedir.

Yapay sinir ağları kullanılarak yapılan bu çalışma bu alanda öncü bir niteliğe sahiptir.

## 2. YAPAY SİNİR AĞLARINA GİRİŞ

### 2.1 Yapay Sinir Ağları

Yapay sinir ağları (YSA); insan beynindeki sinir hücreleri (nöron) esas alınarak modellenen matematiksel hücrelerin yapay bir şekilde ağırlıklandırılarak farklı paralel ve seri bağlanması ile oluşturulan sistemler olarak ele alınabilir. Başka bir tanımda ise Yapay Sinir Ağları, insan beyнинin özelliklerinden olan öğrenme yolu ile yeni bilgileri türetebilme, oluşturabilme ve ortaya çıkarma gibi yetenekleri kendiliğinden otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleri olarak açıklanmıştır (Öztemel 2006). Klasik tekniklerle çözümü çok zor olan ve genellikle doğrusal davranmayan zor problemlerin çözümünde YSA'lar önemli bir alternatif olarak göze çarpmaktadır.

Özetle bir YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir (Civalek ve Calayır 2007). Yapay sinir ağı, nöronların birbirleri ile ağırlıklar vasıtası ile çeşitli şekillerde bağlanmasından oluşur. Ağ ayrıca bu nöron bağlantılarının oluşturduğu katmanlar şeklinde sıralanır. Beynin öğrenme sürecine uygun olarak YSA, bir öğrenme algoritması eşliğinde kendisine sunulan veriyi derleme, bu verilerden bir çıkarım yapma, öğrenmiş olduğu bu çıkarımı nöronlar arasındaki ağırlıklar vasıtası ile saklama ve bunu tüm veri uzayı için genelleme yetisine sahip bir işlemci olarak gösterilebilir.

### 2.2 Yapay Sinir Ağlarının Genel Özellikleri

Uygulanan yapay sinir ağı türüne göre değişmekle beraber yapay sinir ağlarının bazı ortak özellikleri vardır. Bu özelliklerin başlıcaları aşağıdaki gibi sıralanabilir (Öztemel 2006, Hamzaçebi 2011):

**Doğrusal Olmama:** Yapay sinir ağları içinde kullanılan aktivasyon fonksiyonuna göre doğrusallık arz etmeyebilir. Yapay sinir ağları ile çözülebilecek birçok problemin doğrusal olmadığı düşünüldüğünde bu özelliğin önemi anlaşılabilir.

**Bilginin Saklanması:** Yapay sinir ağlarında ağ bağlantılarının değerleri ölçülüp bu değerler bağlantılarda saklanmaktadır.


**Örnekleri Kullanarak Öğrenme:** İnsan sinir sistemini taklit eden yapay sinir ağlarının öğrenme işlemi gerçekleştirebilmesi için ilgili olay veya problem hakkında örnek verilerin belirlenip ağa sunulması gerekmektedir. Örnekleri kullanan ağ ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşur.

**Nümerik Bilgi İle Çalışma:** Yapay sinir ağları yalnızca nümerik bilgiler ile çalışmaktadır. Nümerik olmayan ifadeler de nümerik gösterime çevrilerek ağa sunulmaktadır.

Bu özelliklerin yanı sıra yapay sinir ağlarının örüntü (pattern) oluşturma ve ilişkilendirme, eksik bilgi ile çalışabilme, hata toleransına sahip olma gibi başka özellikleri de vardır.

### 2.3 Yapay Sinir Hücresinin Modellenmesi


Sinir sisteminin temel taşı olan nöronlardan tüm vücutta yaklaşık yüz milyar bulunmaktadır. Her bir hücre başına hücreler arası bağlantı sayısı ise on bin civarındadır. Vücut içinde bilginin dağılımı ve alışverişi nöron hücreleri vasıtasıyla yapılmaktadır (Çetin 2006). Aşağıdaki şekil 2.1’de basit bir nöron hücresinin modeli gösterilmektedir:



Şekil 2.1 Biyolojik nöron modeli (Anonim 2012)

Nöron temelde, hücre gövdesi olan soma, bu gövdenin kıvrımlı uzantıları olan dendrit ve iki nöronu birbirine bağlayan ve tek sinir fiberli aksondan oluşmaktadır. Dendrit üzerinden hücre gövdesine aktarılan bilgi işaretleri hücre içinde değerlendirilerek herhangi bir çıkış darbesi (impulse) üretilip üretilmeyeceğine karar verilir. Eğer herhangi bir bilginin iletilmesine karar verildi ise bu bilgi darbe olarak akson üzerinden başka bir sinir hücresine veya ilgili organa aktarılır. Aksonun bir başka sinir hücresinin dendritine bağlandığı yere sinaps ve bu bağa sinaptik bağ denilmektedir. Vücut içerisinde yer alan milyarlarca sinir hücresi sinaptik bağlarla birbirlerine bağlanarak sinir ağını oluşturmaktadır.

Matematiksel anlamda kullanılan nöron modeli ise şekil 2.2’de gösterilmektedir:



Şekil 2.2 Matematiksel nöron modeli

Temel bir yapay sinir hücresi yukarıdaki şekilde de görüldüğü üzere biyolojik bir sinir hücresine göre çok daha basit bir yapıya sahiptir. Yapay sinir hücresi şu kısımlardan oluşmaktadır:

- Girdiler
- Ağırlıklar
- Toplama Fonksiyonu
- Aktivasyon Fonksiyonu
- Çıktı

**Girdiler:** Yapay sinir hücresine gelen girdiler ağıın öğrenmesi istenen örnekler tarafından belirlenir. Giriş verileri, dış ortamdan girilen bilgiler olabildiği gibi başka hücrelerden veya kendi kendisinden de gelen bilgiler olabilir.

**Ağırlıklar:** Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Her bir giriş kendine ait bir ağırlığa sahiptir. Ağırlıklar pozitif, negatif, sıfır, sabit veya değişken değerler olabilir.

**Toplama Fonksiyonu:** Birleştirme fonksiyonu (Hamzaçebi 2011) olarak da adlandırılan bu fonksiyon bir hücreye gelen net girişi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. Genellikle deneme-yanılma yolu ile toplama fonksiyonu belirlenir. En yaygın olanı “ağırlıklı toplamı” bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır, ağa giren net girdi bulunmuş olur. Toplama fonksiyonunu şu şekilde formülize edilebilir:

$$NET = \sum_i^n G_i A_i \quad (2.1)$$

Burada G girdileri, A ağırlıkları, n ise bir hücreye gelen toplam girdi (proses elemanı) sayısını göstermektedir.

Yapay sinir ağları için farklı toplama fonksiyonları zaman içinde yapılan çalışmalarda ortaya çıkmıştır. Sıklıkla kullanılan bu toplama fonksiyonların bazıları Çizelge 2.1’de gösterilmektedir. Yapay sinir ağları tasarımı süreci içerisinde her bir proses elemanı aynı toplama fonksiyonuna sahip olabileceği gibi farklı farklı toplama fonksiyonuna sahip olabilmektedir. Bu durum tamamen tasarımcının kendi öngörüsüne ve ağın performansına bağlı olarak şekillenebilmektedir.

Çizelge 2.1 Toplama fonksiyonu türleri (Öztemel 2006)

Net Giriş	Açıklama
<p><i>Çarpım</i></p> $Net\ Girdi = \prod_i G_i A_i$	Ağırlık değerleri ile girdi değerlerinin birbirleriyle çarpılmasıyla elde edilir.
<p><i>Maksimum</i></p> $Net\ Girdi = Max(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en büyük olan değer sistemin net girdisi olur.
<p><i>Minimum</i></p> $Net\ Girdi = Min(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en küçük olan değer sistemin net girdisi olur.
<p><i>Çoğunluk</i></p> $Net\ Girdi = \sum_i sgn(G_i A_i)$	Ağırlıklarla çarpılmış olan girdilerin işaret fonksiyonu alınır, bu değerler toplanır ve net girdi olarak sisteme sunulur.
<p><i>Kümülatif Toplam</i></p> $NET\ Girdi = Net(eski) + \sum_i^n G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Ayrıca tüm girdilerin sıfır olduğu durumlarda ağ çıktısının “0” olmaması için eşik değeri kullanılabilir. Şekil 2.3’te gösterildiği üzere toplama fonksiyonuna dahil edilen b değeri bu eşiği ifade etmektedir. Eşik değerinin kullanımı, pratikte +1 ya da -1 değerine sahip sabit bir girdinin “b” ağırlığına sahip bir bağlantı ile toplama fonksiyonuna girişi şeklinde ele alınır (Efe ve Kaynak 2000).

**Aktivasyon Fonksiyonu:** Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller



kullanılmaktadır. Yine toplama fonksiyonunda olduğu gibi, her bir proses elemanı aynı toplama fonksiyonuna sahip olabileceği gibi farklı farklı toplama fonksiyonuna sahip olabilmektedir. Bu durum tamamen tasarımcının kendi öngörüsüne ve ağıın performansına bağlı olarak şekillenebilmektedir. Uygun fonksiyonu gösteren bir formül halihazırda literatürde bulunmamaktadır.

Günümüzde en yaygın olarak kullanılan Çok Katmanlı Algılayıcı modelinde genel olarak sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyon

$$F(NE\text{T}) = \frac{1}{1 + e^{-NE\text{T}}} \quad (2.2)$$

olarak formülize edilebilir.

Burada NET, proses elemanına gelen NET girdi değerini göstermektedir. Bu değer toplama fonksiyonu kullanılarak belirlenmektedir.

Literatürde sıklıkla kullanılan diğer aktivasyon fonksiyonları Çizelge 2.2’de gösterilmektedir:


Çizelge 2.2 Aktivasyon fonksiyonu türleri (Öztemel 2006)

Aktivasyon fonksiyonu	Açıklama
<i>Linear fonksiyon</i> $F(NE\text{T}) = NE\text{T}$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
<i>Step fonksiyonu</i> $F(NE\text{T}) = \begin{cases} 1 & \text{eğer } NE\text{T} > \text{eşik değeri} \\ 0 & \text{eğer } NE\text{T} \leq \text{eşik değeri} \end{cases}$	Gelen NET girdi değerinin belirlenen eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır.
<i>Sinüs fonksiyonu</i> $F(NE\text{T}) = \sin(NE\text{T})$	Sinüs fonksiyonu

Çizelge 2.2 Aktivasyon fonksiyonu türleri (devam)

Aktivasyon fonksiyonu	Açıklama
<p><i>Eşik değer fonksiyonu</i></p> $F(NE\text{T}) = \begin{cases} 0 & \text{eğer } NE\text{T} \leq 0 \\ NE\text{T} & \text{eğer } 0 < NE\text{T} < 1 \\ 1 & \text{eğer } NE\text{T} > 1 \end{cases}$	<p>Gelen bilgilerini 0 veya 1'den büyük veya küçük olmasına göre bir değer alır. Ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.</p>
<p><i>Hiperbolik tanjant fonksiyonu</i></p> $F(NE\text{T}) = \frac{e^{NE\text{T}} + e^{-NE\text{T}}}{e^{NE\text{T}} - e^{-NE\text{T}}}$	<p>Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.</p>

Hiperbolik tanjant fonksiyonunu bir  $\lambda$  değeri atayarak sinaptik ağırlıkların kazandırdığı esnekliğin ötesinde, değişik eşleştirmelerin yapılabilmesini mümkün kılan bir esneklik sağlanabilmektedir. Aktivasyon fonksiyonunun şekli  $\lambda$  parametresi değiştirilerek değiştirilebilir ve sistemin çıktısına dolayısıyla ağırlıkların güncellenmesine farklı etkileri Şekil 2.3'te görüldüğü gibi olabilir (Efe ve Kaynak 2000).



Şekil 2.3 Farklı  $\lambda$ 'lar için hiperbolik tanjant fonksiyonunun çıktısı


Sigmoid fonksiyonu, lineer fonksiyon, ters lineer fonksiyon, basamak fonksiyonu gibi fonksiyonlar çoğunlukla kullanılan aktivasyon fonksiyonları türlerindedir.

**Çıktı:** Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya bir başka hücreye giriş olarak gönderilebilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir.

#### 2.4 Basit Tek Katmanlı Algılayıcı (Perseptron)

Bu tip ağlar sadece girdi ve çıktı katmanlarından oluşur. Her ağın bir veya daha fazla çıktısı(Ç) vardır. Çıktı üniteleri bütün girdi ünitelerine (G) bağlanmaktadır. Girdi ile ağ arasındaki her bağlantı için bir ağırlık (A) değeri vardır. Ayrıca yukarıda da değinildiği üzere proses elemanlarının değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını

engelleyen eşik değeri “b” bulunmaktadır. Basit bir tek katmanlı ağ şekil 2.4’te gösterilebilir:



Şekil 2.4 Basit TKA modeli

Toplama fonksiyonu ağırlıklı toplam olarak belirlenirse çıktı;

$$\zeta = f(G_1A_1 + G_2A_2 + b) \quad (2.3)$$

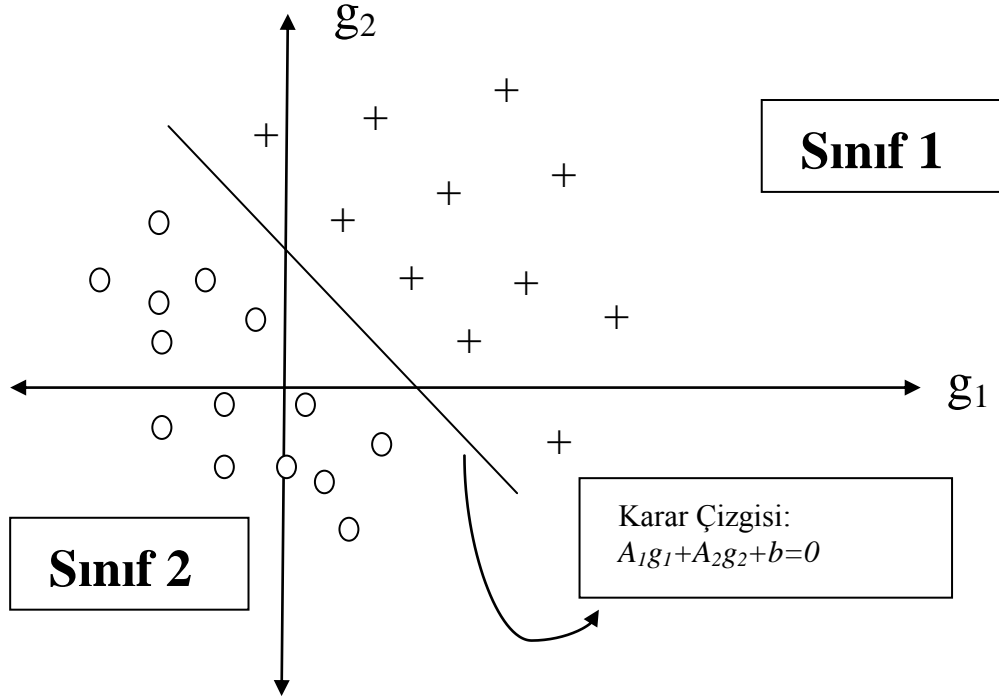
şeklinde hesaplanmaktadır.

Girdi sayısının N tane olması halinde ise çıktı;

$$\zeta = f\left(\sum_{i=1}^N G_iA_i + b\right) \quad (2.4)$$

şeklinde formülize edilebilir.

Basit algılayıcı olarak da adlandırabilen tek katmanlı ağlar ilk olarak 1958 yılında Rosenblat tarafından örüntü (bkz. Şekil 2.5) sınıflandırma amacı ile geliştirilmiştir. Burada sınıflandırmadan kasıt iki tipte bilgiyi bir karar sınırı ile birbirlerinden ayırmaktır. Başka bir deyişle tüm girdiler kümesi (uzayı) hakkında optimizasyon teknikleri uygulayarak girdilerin önceden belirlenmiş olan hangi sınıfa ait olduğuna karar verilmesidir.



Şekil 2.5 İkili sınıflandırmanın düzlem üzerinde gösterimi

Basit algılayıcı yukarıdaki şekilden de görüldüğü üzere eğitilebilen tek bir yapay sinir hücresinden oluşmaktadır. Eğitim ağırlıkların güncellemesiyle gerçekleştirilir. Öncelikler tüm girdi elemanları ağa gösterilir. Toplama fonksiyonundan geçen girdiler eşik değeri ile beraber aktivasyon fonksiyonuna sokulur. Oluşan çıktı ile olması gereken veya arzulanan çıktı birbirleriyle kıyaslanarak ağa “öğrenme kuralı” yolu ile aktarılır. Basit algılayıcı da çıktı mantıksal (boolean) olarak 1 yada 0 değerlerini almaktadır. Basit algılayıcı da kullanılan eşik değeri çıktının 1 yada 0 olmasına etki eder. Basit algılayıcının hesaplama adımlarını iki girdi için gösterirsek:

1. Adım: Girdiler sisteme sunulur;  $G_1$  ve  $G_2$
2. Adım: Toplama fonksiyonuna girdiler sokulur:

$$NET = G_1A_1 + G_2A_2 \quad (2.5)$$

3. Adım: Çıktının hesaplanması: Net girdinin eşik değerinden büyük veya küçük olmasına göre çıktı değeri 0 ve 1 değerinde birini alır,

$$\zeta = \begin{cases} 1 & \text{eğer } NET > b \\ 0 & \text{eğer } NET \leq b \end{cases} \quad (2.6)$$

Nihayetinde gerçekleşen çıktı beklenen “B” değeriyle aynı ise ağırlıklar olduğu gibi kalır. Ağ istenenden farklı bir çıktı üretmiş ise o zaman iki durum söz konusudur:

i) Ağın beklenen çıktı değerinin 0, gerçekleşen çıktı değerinin 1 olması durumunda ağırlık değerleri azaltılmalıdır. Burada öğrenme kuralı devreye girer:

$$A_{1,m} = A_{1,m-1} - \lambda G \quad (2.7)$$

$$A_{2,m} = A_{2,m-1} - \lambda G \quad (2.8)$$

Burada  $A_{1,m}$ ,  $A_1$ 'in m'inci iterasyondaki değeri olup,  $\lambda$  öğrenme katsayısı ağırlıkları girdi değerlerinin belli oranlarıyla güncellenmesini sağlamaktadır.

ii) Ağın beklenen çıktı değerinin 1, gerçekleşen çıktı değerinin 0 olması durumunda ağırlık değerleri artırılmalıdır. Yani;

$$A_{1,m} = A_{1,m-1} + \lambda G \quad (2.9)$$

$$A_{2,m} = A_{2,m-1} + \lambda G \quad (2.10)$$

olacaktır.

Çıktı değeri beklenen çıktı değerine eşit olana kadar yukarıdaki adımlar iterasyon şeklinde tekrarlanır.

## **2.5 Yapay Sinir Ağlarında Öğrenme**

Yapay sinir ağları gibi örneklerden öğrenen sistemlerde farklı öğrenme stratejileri uygulanmaktadır. Bu öğrenme stratejilerini dört başlık altında toplayabiliriz:

### **2.5.1 Öğretmenli öğrenme**

Bu strateji türünde ağın olayı öğrenebilmesi için bir öğretmen yardımcı olmaktadır. Öğretmen ağa belirli girdiler için beklenen çıktı değerlerini ağa verir. Ağın görevi girdileri öğretmenin belirlediği çıktılara haritalamaktır. Yukarıda gösterilen basit algılayıcı örneğinde de olduğu gibi sistemin girdileri ile çıktıları arasındaki ilişkiler ağırlıklar yolu ile öğrenilmektedir.

### **2.5.2 Destekleyici öğrenme**

Burada da ağa bir öğretmen yardımcı olmaktadır. Ama öğretmen, öğretmenli öğrenme de olduğu gibi belirli girdi setlerine karşılık olarak olması gereken çıktıları sisteme göstermek yerine, ağın çıktı üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretmektedir. Ağ, öğretmenden gelen bu sinyali değerlendirerek öğrenme sürecini devam ettirir.

### **2.5.3 Öğretmensiz öğrenme**

Bu strateji türünde ise ağa yardımcı olan bir öğretmen mekanizması bulunmamaktadır. Daha çok sınıflandırma problemleri için kullanılan bu stratejide sisteme yalnız girdi değerleri verilir ve çıktının üretilmesi beklenir. Sistemin öğrenme işlemi bittikten sonra ise kullanıcı tarafından çıktıların anlamlandırılmasını sağlayan etiketleme işlemi yapılır.

### 2.5.4 Karma stratejiler

Yukarıdaki sayılan stratejilerin birlikte kullanılarak öğrenmenin gerçekleştirildiği ağlardır. Kısmen öğretmenli, kısmen ise öğretmensiz olarak öğrenme işlemi gerçekleştirilir.

### 2.5.5 Öğrenme kuralları

Yapay sinir ağlarında öğrenme işlemi yukarıda belirtilen stratejilerden hangisinde çalışırsa çalışsın, ağın eğitimi bir kurala göre dayandırılmaktadır. Bu öğrenme kuralı temelde aşağıda yer aldığı şekilde iki grupta incelenebilmektedir:

a) Çevrimiçi Öğrenme Kuralları: Gerçek zamanlı olarak çalışabilen bu tip kurallar uygulanırken sistemde bir taraftan işlem fonksiyonları yerine getirilirken diğer taraftan öğrenmeye devam edilmektedir. ART ağlarının öğrenme kuralı ile Kohonen öğrenme kuralı bu sınıfa örnek olarak verilebilir.

b) Çevrimdışı Öğrenme Kuralları: Bu tip öğrenmede öncelikle ağ eğitilir, daha sonra ağ gerçek hayatta kullanıma alınır. Ağ kullanımdayken öğrenme gerçekleşmemektedir. Yeni verilerin ve durumların ağa öğretilmesi istendiğinde ağ hizmetten çıkarılır ve çevrimdışı halde yeniden eğitilip tekrar kullanıma sunulur.

Yapay sinir ağlarında sıklıkla kullanılan öğrenme kuralları şu başlıklar altında sıralanabilir:

1. Hebb Kuralı
2. Korelasyon Kuralı
3. Instar Kuralı
4. Kazanan Hepsini Alır Kuralı
5. Outstar Kuralı
6. Widrow-Hoff (En Küçük Kareler-Delta) Kuralı
7. Hafıza Tabanlı Öğrenme Kuralı



## 8. Boltzmann Kuralı

### 2.5.5.1 Hebb kuralı

Hebb tarafından 1949 yılında geliştirilen bu kural şu iki temel esasa dayanmaktadır:

- \* Eğer iki komşu nöron (sinaptik bir bağla birbirlerine bağlı) eşanlı olarak aktif veya pasif hale getiriliyor ise aralarındaki ağırlığın büyüklüğü artırılmalıdır.
- \* Eğer eşanlı olarak iki komşu nörondan biri aktif diğeri pasif halde getiriliyor ise aralarındaki ağırlığın büyüklüğü azaltılmalıdır (Williamowski 2003, 2011).

Hebb kuralında bu iki sinir hücresi arasındaki korelasyon önem kazanmaktadır. Matematiksel olarak Hebb kuralı şu şekilde ifade edilebilmektedir:

$$\Delta A_{ij} = c g_i \zeta_j \quad (2.11)$$

burada  $\Delta A_{ij}$  i nöronu ile j nöronu arasındaki sinaptik ağırlık değişim miktarını,  
c öğrenme katsayısını,  
 $g_i$  i'nci girdideki sinyali,  
 $\zeta_j$  bu girdiye karşılık gelen çıkış sinyalini göstermektedir.

Öğrenme işlemi genelde tüm ağırlıklar sıfır iken başlatılır. Bu öğrenme türü ağa herhangi bir beklenen çıktı gösterilmediği için “öğretmensiz” bir öğrenme türüdür.

### 2.5.5.2 Korelasyon kuralı

Korelasyon kuralının temelleri Hebb kuralına dayanmaktadır. Hebb kuralından farklı olarak sisteme istenen çıktı sinyali gösterilir. Bu yönden bu kural “öğretmenli” bir öğrenme türüdür. Matematiksel olarak korelasyon kuralı şu şekilde ifade edilebilmektedir:

$$\Delta A_{ij} = c g_i d_j \quad (2.12)$$

burada  $\Delta A_{ij}$  i nöronu ile j nöronu arasındaki sinaptik ağırlık değişim miktarını,  
c öğrenme katsayısını,  
 $g_i$  i'nci girdideki sinyali,  
 $d_j$  bu girdiye karşılık gelen **beklenen** çıkış sinyalini göstermektedir.

### 2.5.5.3 Instar kuralı

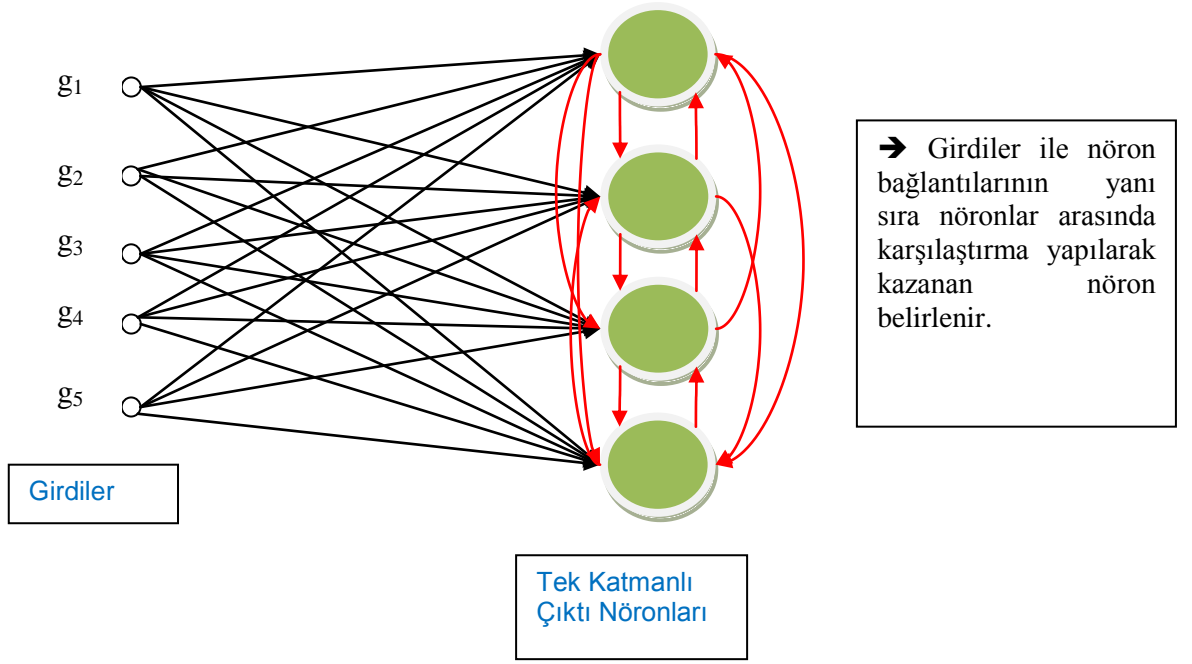
Eğer girdi ve ağırlık vektörleri normalize edilirse, veya sadece ikili bipolar değerlere (-1 ya da +1) sahip ise toplama fonksiyonunun çıktısı olan “net” değeri girdi sinyalleri ile ağırlıklar aynı olduğu zaman en yüksek pozitif değeri alır. Bundan dolayı ağırlıklar eğer girdilerden farklı ise güncellenir:

$$\Delta A_i = c(g_i - A_i) \quad (2.13)$$

Grosberg (1969) tarafından önerilen bu öğrenme türünde ağırlık güncelleme ile ilgili bilgi sadece girdi sinyallerinden alındığı için “öğretmensiz” bir öğrenme türüdür (Hagan vd. 1996).

### 2.5.5.4 Kazanan hepsini alır kuralı

Instar kuralının farklı bir uygulaması olan ve Yarışmacı Öğrenme olarak da literatürde yer alan (Haykin 1999), Kazanan Hepsini Alır (KHA) kuralına göre ağırlıklar en yüksek “net” değerine sahip nöron için güncellenir, diğer nöronlara bağlı ağırlıklar değiştirilmez. Bu kuralı bazı uygulamalarda tek bir nöron güncellemesi yerine “en yüksek” net değerler sahip birkaç nöron için güncelleme yapılması olarak ele alınır. Kohonen tarafından geliştirilen KHA algoritması ağa herhangi bir beklenen çıktı gösterilmediği için “öğretmensiz” bir öğrenme türü olmasına karşın bu algoritmada kazanan nöronun belirlenmesi için bir kıstas değer kullanılmaktadır.



Şekil 2.6 Kazanan hepsini alır algoritması

### 2.5.5.5 Outstar kuralı

Yine Grosberg (1969) tarafından öngörülen bu algorithmada beklenen çıktı değeri ile ağırlıklar arasındaki farka göre ağırlık güncellemesi yapılır:

$$\Delta A_{ij} = c(d_j - A_{ij}) \quad (2.14)$$

Burada  $c$  öğrenme katsayısını,  
 $d_j$  beklenen nöron çıktısını göstermektedir.

Bu kural ağa beklenen çıktı değeri gösterildiği için “öğretmenli” bir öğrenme türüdür.

### 2.5.5.6 Widrow-Hoff (Delta) kuralı

İstenen çıktıya göre eğitilen öğretmenli öğrenme türü olan bu kuralı Widrow ve Hoff geliştirmiştir. Bu kuralda net değeri ile beklenen çıktı değeri arasındaki farkın karesinin minimize etmek esastır. Örneğin,  $j$  nöronu için tanımlanan  $Hata_j$ :

$$Hata_j = \sum_{p=1}^P (net_{jp} - d_{jp})^2 \quad (2.15)$$

Burada  $P$  örüntü (pattern) sayısını  
 $d_{jp}$   $p$ 'nci örüntü uygulandığı zaman  $j$ 'nci nöronun çıktısını gösterirken, toplama fonksiyonunun çıktısı olan "net" ise

$$net = \sum_{i=1}^n A_i g_i \quad (2.16)$$

olarak gösterilebilir.

2.15'in  $A_{ij}$ 'ye göre türevi alındığı zaman ise ağırlık değişim miktarı için:

$$\frac{\partial Hata_j}{\partial A_{ij}} = 2A_{ij} \sum_{p=1}^P (d_{jp} - net_{jp}) \quad (2.17)$$

yani

$$\Delta A_{ij} = cA_{ij} \sum_{p=1}^P (d_{jp} - net_{jp}) \quad (2.18)$$

olarak yazılabilir.

Her bir örüntü uygulandıktan sonra nöron çıktısına göre ağırlıkları güncellenebildiği gibi tüm örüntüler tamamlandıktan sonra ağırlıklar topluca güncellenebilmektedir. Bu yöntemlerden ilkinde *artırımlı güncelleme* değerine *birikimli (kümülatif) güncelleme* denilmektedir.

#### 2.5.5.7 Hafıza tabanlı öğrenme kuralı

Hafıza tabanlı öğrenme kuralı geçmiş deneyimlere dayalı bir öğrenme türüdür. Bu tür ağlar girdi/çıkı örneklerini daha sonra kullanmak için hafızada tutar. Hafıza tabanlı öğrenme yapan sistemler; girdileri yerel komşuluklarını tanımlayan kriter (genelde Öklid mesafesi baz alınır) ile bu komşulukta eğitim kümelerine uygulanacak olan öğrenme kuralı olmak üzere iki ana unsur içermektedir. Daha çok sınıflandırma problemlerinde kullanılan bir kuraldır (Haykin 1999).

#### 2.5.5.8 Boltzmann öğrenme kuralı

Boltzmann'ın istatistiksel mekaniğinden etkilenerek onun adına geliştirilen stokastik bir algoritmadır. Boltzmann öğrenme kuralını esas alan yapay sinir ağlarına “Boltzmann makinesi” denmektedir (Haykin 1999).

Bir Boltzmann makinesinde nöronlar aktif ve pasif olmak üzere iki durum olarak işaretlenirler. Aktif nöron +1 ile pasif nöron ise -1 ile gösterilir. Makinenin davranışı bir “enerji” fonksiyonuna göre şekillenmektedir. Bu enerji fonksiyonu E nöronların durumuna göre hesaplanmaktadır:

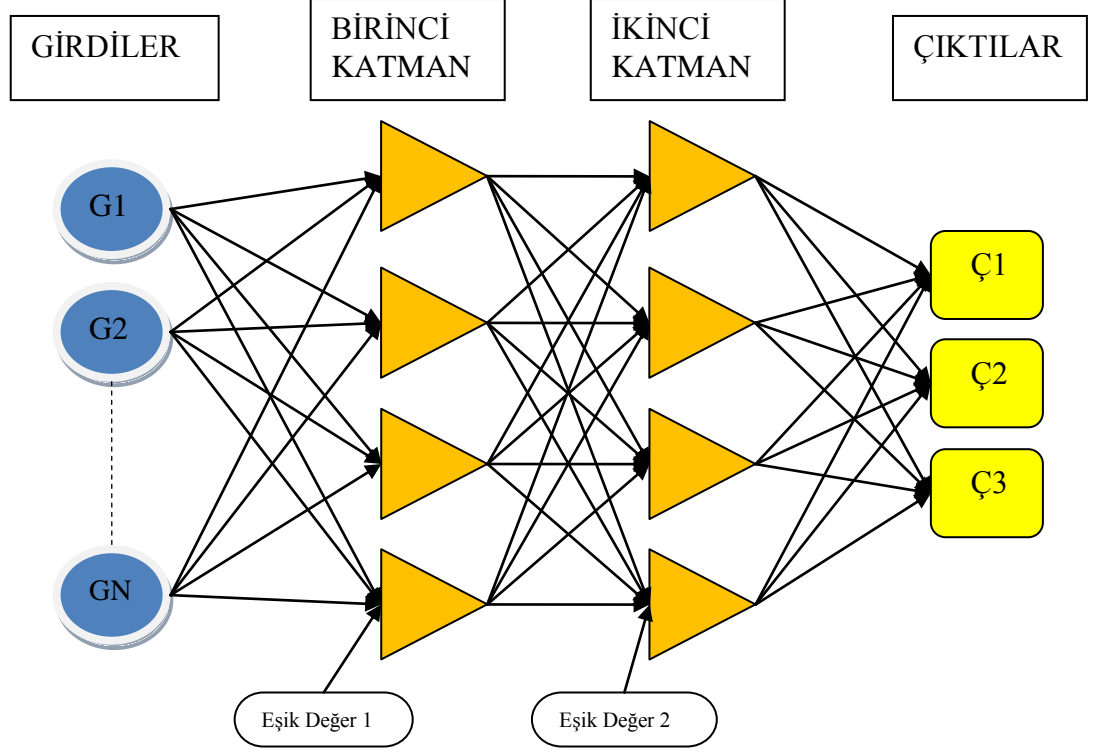
$$E = -\frac{1}{2} \sum_j \sum_{\substack{k \\ j \neq k}} A_{kj} x_k x_j \quad (2.19)$$

Burada  $x_j$  j nöronunun durumunu,

$A_{kj}$  nöron j ile nöron k arasındaki sinaptik ağırlığı göstermektedir.

Makine öğrenme sürecinin ortasında rastgele bir nöronu seçerek-örneğin nöron k- bu nöronun durumunu olasılık hesabına göre (psödo-termal denge) ters yöne çevirir (aktif ise pasif, pasif ise aktif hale getirir ), ve nihayetinde nöronda oluşan enerji değişimi  $\Delta E$  'ye bakar. Daha sonra j ve k nöronlarının sistemin sabitlenmiş çalışmasındaki durumları ile serbest çalışmasındaki durumları arasında korelasyon kurup, ağırlıkları bu korelasyona göre günceller.

## 2.6 Çok Katmanlı Yapay Sinir Ağları




Şekil 2.7 Çok katmanlı yapay sinir ağı

Çok katmanlı yapay sinir ağları (ÇKYSA) bir ya da daha fazla gizli katmanı olan ileri beslemeli sinir ağlarıdır. Genelde bu ağ bir girdi katmanı, en az bir gizli katman ve bir de çıkış katmanından oluşur.

**Girdi Katmanı:** Bilgi işlemenin olmadığı ve dışarıdan gelen verilerin derlenerek gizli katmana iletiildiği katmandır. Bu katmandaki her bir sinir hücresine atanmış bir girdi verisi bulunmaktadır.

**Ara Katmanı:** Ara katmanda girdi katmanından gelen bilgiler değerlendirilir, işlenir ve bir sonraki katmana gönderilir. Çok katmanlı bir yapay sinir ağında birden çok ara katman bulunabilir.

**Çıkış Katmanı:** Üretilen çıktıların dışarıya sunulduğu katmandır. Bu katmandaki her bir sinir hücresi bir çıktıya bağlıdır.



Şekil 2.8 Çok katmanlı ağda veri akışı

Çok katmanlı yapay sinir ağlarının üç tane ayırt edici belirgin özelliği vardır (Haykin 1999, Hamzaçebi 2011). Bunlar;

1. Ağın içindeki her bir nöronun bağlandığı ve doğrusal olmayan (nonlinear) bir aktivasyon fonksiyonu vardır. Sıklıkla kullanılan sigmoid fonksiyonu bu aktivasyon fonksiyonuna örnek verilebilir. Doğrusal olmamak çok katmanlı ağı basit bir algılayıcıdan ayıran önemli bir özelliktir.
2. Ağı daha kompleks bir hale getiren ve karmaşık girdileri çözümlemede işe yarayan ve girdi ile çıktı katmanından bağımsız en az bir tane gizli katman mevcuttur.
3. Ağ sinaptik bağlantılarla güçlü bir şekilde birbirine bağlı nöronlardan oluşur. Yeni bağlantı oluşumları için bağlantı noktaları ve ağırlıklarının yeniden ele alınması gerekmektedir.

Çok katmanlı yapay sinir ağı temelde iki temelde öğrenme işlemini gerçekleştirir. Bunlar *İleri Doğru Besleme* (Feedforward) algoritması ve *Geri Doğru Yayılım* (Back propagation) algoritmalarıdır. İleri doğru besleme algoritması denetli bir öğrenme




algoritmasıdır ve bir sinir ağının girdi katmanından çıktı katmanına doğru “bilgi akışı”nı açıklar. Geri yayılım, genellikle çok katmanlı perseptronların, ağın gizli katmanlarına bağlı olan ağırlıklarını değiştirmek için kullanılan denetli bir öğrenme algoritmasıdır. Geri yayılım algoritması ağırlıkları ters yönde değiştirmek için hesaplanmış hata değerleri kullanır.

Geri yayılım algoritması sürecini başlatmadan önce aşağıdaki verilerin/koşulların belirlenmiş olması gerekmektedir (Hamzaçebi 2011):

- a) Ağa sunulacak olan eğitim kümesi
- b) Öğrenme parametreleri
- c) Algoritmayı sonlandırma kriterleri
- d) Ağırlıkları düzenleme metodolojisi
- e) Aktivasyon fonksiyonu
- f) Ağırlıkların ilk değerleri

Bu veriler hazırlandıktan sonra ağa eğitim kümesinden girdiler sunulur. Bu girdi değerleri gizli katmana iletilir. Eşik değerleri ile beraber toplama (birleştirme) işlemleri gerçekleşikten sonra aktivasyon fonksiyonuna iletilen “net” değer ile çıktı bulunur. Çıktı bulunduktan sonra ağın ürettiği çıktı ile eğitim kümesindeki çıktılar birbirleriyle karşılaştırılırlar. Aralarındaki fark hata değeri olarak hesaplanır. Bu oluşan hata değeri sırasıyla çıktı katmanından önce gelen gizli katmanlardaki nöronlara sinaptik ağırlar güncellenerek yansıtılır. Algoritmayı sonlandıracak hata değerine ulaşılan dek yukarıdaki süreç tekrarlanarak devam ettirilir. Şekil 2.9’da gösterilen akış şemasında bu süreç özetlenmektedir:



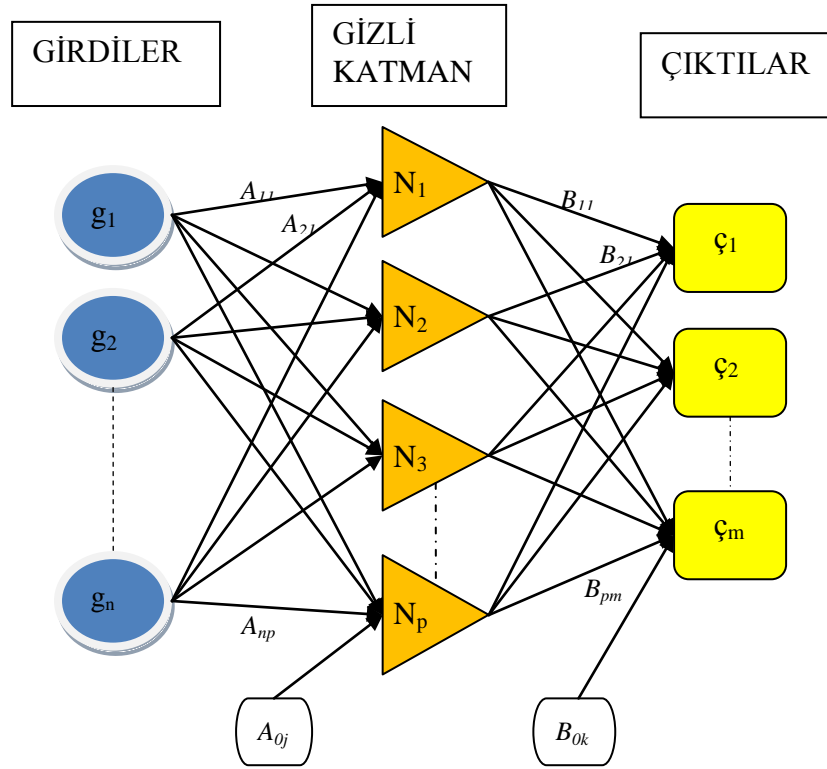
Şekil 2.9 Çok katmanlı yapay sinir ağının çalışma prensibi

### 2.6.1 Çok katmanlı ağ için çalışma prosedürü

Tanımlamalar:

$g_i$	i. girdi değeri,
$\zeta_k$	k. çıktı değeri,
$d_k$	k. istene çıktı değeri,
$\delta_k$	çıktı ile gizli katman arasındaki ağırlıklar için düzeltme oranı,
$\delta_j$	gizli katmanlar arası veya gizli katman ile girdi arasındaki ağırlıklar için düzeltme oranı,
$\lambda$	öğrenme katsayısı,
$\alpha$	momentum katsayısı,

- $A_{ij}$  gizli katmanlar arası veya gizli katman ile girdi arasındaki ağırlıklar,
- $A_{0j}$  j. gizli nöron için eşik değeri ağırlığı,
- $B_{jk}$  çıktı ile gizli katman arasındaki ağırlıklar,
- $B_{0k}$  j. çıktı nöronu için eşik değeri ağırlığı,
- $z_{jnetgirdi}$  j. gizli nöronun net girdisini,
- $Z_j$  j. gizli nöronun çıktısını,
- $t$  iterasyon sayısını, göstermektedir.



Şekil 2.10 Örnek çok katmanlı algılayıcı

Yukarıda tanımlanan ve şekilde gösterilen çok katmanlı ağ için eğim düşümü (Delta metodu) algoritması ile çalışma prosedürü aşama aşama aşağıdaki şekilde gösterilebilir:

#### 1. Aşama

- √ Ağırlıklara ilk değerleri rastgele atanır,
- √ Öğrenme parametreleri belirlenir,

√ Sonlandırma eşiği belirlenir.

## 2. Aşama

√ Girdiler ağa sunulur ( $g_i, i=1,2,\dots,n$ ) ve gizli katman nöronlarına gönderilir

## 3. Aşama

√ Gizli katman nöronları girdileri aktivasyon fonksiyonundan geçirerek çıktıları üretir ve çıktı katmanına gönderir:

$$z_{j_{netgirdi}} = A_{0j} + \sum_i A_{ij} g_i \quad (2.20)$$

$$Z_j = f(z_{j_{netgirdi}}) \quad (2.21)$$

## 4. Aşama

√ Çıktı katmanı gizli katmandan gelen net girdiyi aktivasyon fonksiyonundan geçirerek kendi çıktısını üretir:

$$\zeta_{knetgirdi} = B_{0k} + \sum_i B_{jk} g_i \quad (2.22)$$

$$\zeta_k = f(\zeta_{knetgirdi}) \quad (2.23)$$

## 5. Aşama

√ Her bir çıktı nöronu için hata değeri hesaplanır:

$$\delta_k = (d_k - \zeta_k) f'(\zeta_{knetgirdi}) \quad (2.24)$$

√ Daha sonra çıktı katmanı ile gizli katman arasındaki ağırlıkları güncellemek için esas alınacak değişim miktarı hesaplanır:

$$\Delta B_{jk}(t) = \lambda \delta_k Z_j + \alpha \Delta B_{jk}(t-1) \quad (2.25)$$

$$\Delta B_{0k}(t) = \lambda \delta_k + \alpha \Delta B_{0k}(t-1) \quad (2.26)$$

## 6. Aşama

√ Her bir gizli katman için hata ağırlıklar oranında yansıtılır:

$$\delta_{jnet} = \sum_{k=1} \delta_k B_{jk} \quad (2.27)$$

$$\delta_j = \delta_{jnet} f'(z_{jnetgirdi}) \quad (2.28)$$

- √ Böylece girdi katmanını gizli katmana bağlayan bağlantıların ve eşik teriminin ağırlıklarındaki değişim miktarı hesaplanır:

$$\Delta A_{ij}(t) = \lambda \delta_j g_i + \alpha \Delta A_{ij}(t-1) \quad (2.29)$$

$$\Delta A_{0j}(t) = \lambda \delta_j + \alpha \Delta A_{0j}(t-1) \quad (2.30)$$

#### 7. Aşama

- √ Ağırlıklar değiştirilir:

$$B_{jk}(t) = B_{jk}(t-1) + \Delta B_{jk}(t) \quad \{k=1,2,3,\dots,m ; j=0,1,2,\dots,p\} \quad (2.31)$$

$$A_{ij}(t) = A_{ij}(t-1) + \Delta A_{ij}(t) \quad \{j=0,1,2,\dots,p ; i=0,1,2,\dots,n\} \quad (2.32)$$


#### 8. Aşama

- √ Sonlandırma eşiği kontrol edilir, eğer uygunsa algoritma sonlandırılır.  
√ Sonlandırma hedefleri tutturulamamışsa 2-7 arası aşamalar tekrarlanır.

### 3. TÜRKİYE ELEKTRİK PİYASASI

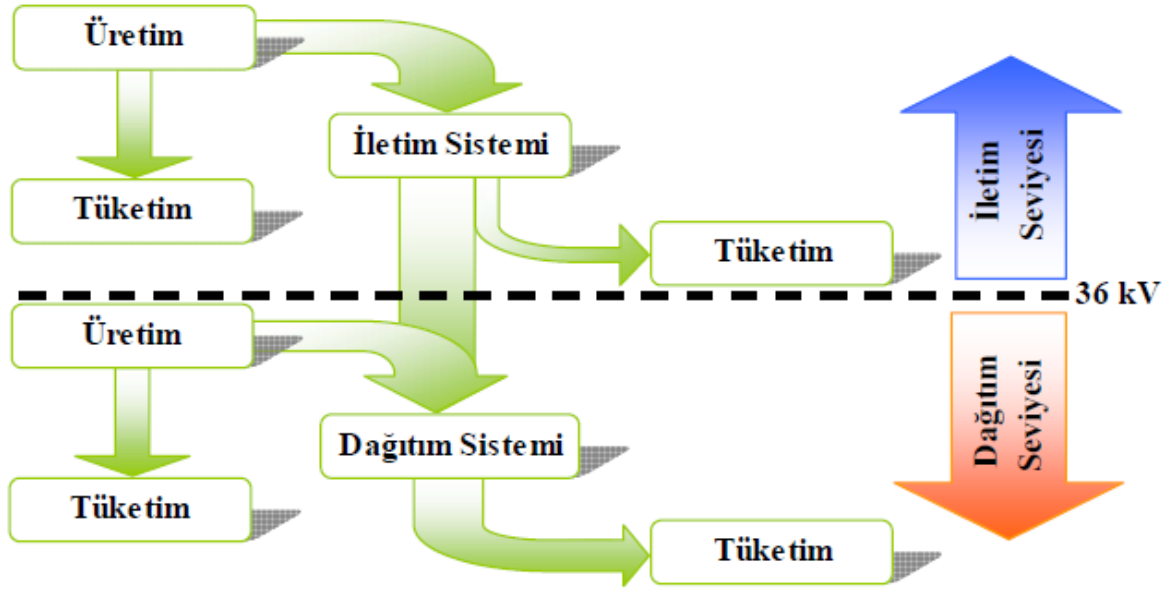
#### 3.1 Elektrik Piyasasının İşleyişi

Elektrik, üretim santrallerinde üretilir. Daha sonra yükseltici trafo ile iletim şebekesi gerilim seviyesine yükseltilerek iletim şebekesine gönderilir. Elektriğin iletim şebekesinde yüksek gerilimle taşınmasındaki amaç, elektriğin çok uzak mesafelere iletilmesi esnasında oluşan kayıpların en aza indirilmesidir Türkiye için 66 kV, 154 kV ve 380 kV olan gerilim seviyesi Avrupa’da 400 kV, Rusya’da 500 kV ve Kanada’da 700 kV seviyelerindedir. İletim şebekesi aracılığıyla tüketicilerin bulunduğu bölgelere taşınan elektrik enerjisi, gerilim düşürülerek nihai tüketicilere (konut, ticarethane, sulama vb.) ulaştırılmak üzere dağıtım şebekesine aktarılır. Bu sistemler, genellikle orta gerilim şebekesi (1-30 kV) ile dağıtım merkezleri ve alçak gerilim şebekesinden meydana gelir. Ülkemizdeki dağıtım şebekesi 36 kV gerilim seviyesinin altındaki hatlardan oluşmaktadır. Müşteriye ulaşan elektrik gerilim seviyesi ise tek fazlı sistemler için 220 V, üç fazlı sistemler için ise 380 V mertebesindedir (Kölmek 2009, Turgut ve Selçuk 2009). Bu işleyiş şekil 3.1 ile açıklanmaktadır:



Şekil 3.1 Elektrik Piyasasının İşleyişi

Bu akış her zaman bu doğrultuda olmak zorunda değildir. Dağıtım seviyesinde de üretim yapılarak üretilen enerji yine bu seviyede tüketilebileceği gibi enerji tüm enterkonnekte sisteme iletim seviyesinden de sunulabilmektedir. Tam olarak akış yönleri şekil 3.2'deki diyagram ile gösterilebilir:



Şekil 3.2 Elektrik sisteminin fiziksel yapısı (Bilimgut 2008)

### 3.2 Türkiye Elektrik Piyasasının Yapısı

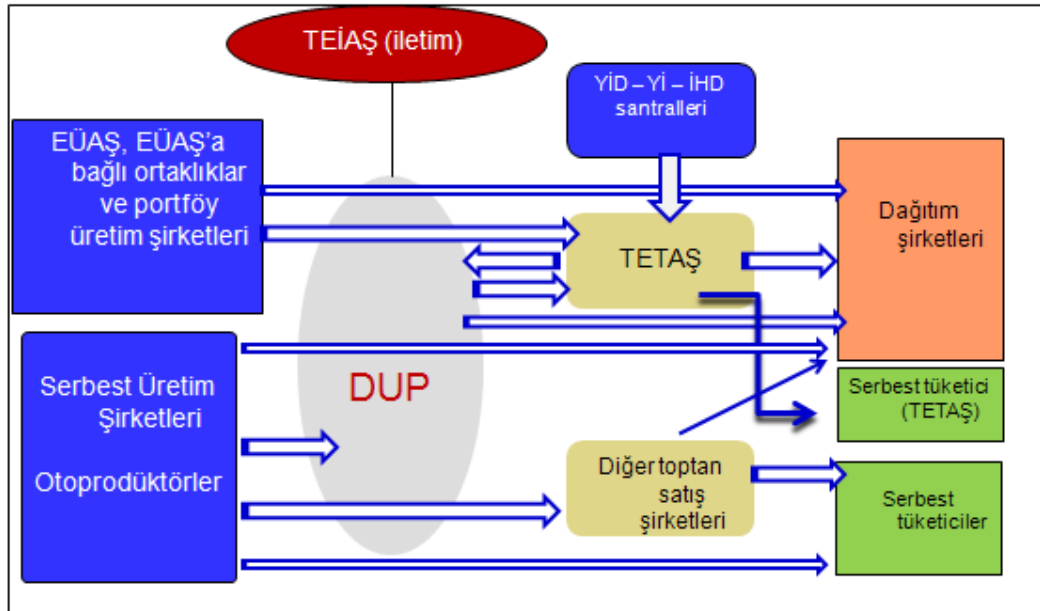
Daha önceleri Türkiye'de elektriğin üretimi, iletimi ve dağıtım faaliyetleri tek el konumunda olan Türk Elektrik Kurumu (TEK) tarafından yürütülüyordu.

Önceleri dikey bütünleşik bir yapıya sahip olan Türkiye Elektrik Kurumu günümüzde elektriğin dağıtım için Türkiye Elektrik Dağıtım A.Ş. (TEDAŞ), üretimi için Elektrik Üretim A.Ş. (EÜAŞ), iletimi için Türkiye Elektrik İletim A.Ş. (TEİAŞ) ve toptan satışı için Türkiye Elektrik Ticaret ve Taahhüt A.Ş. (TETAŞ) olmak üzere dört ana şirkete ayrılmıştır. Ayrıca elektrik piyasasının serbestleştirilmesi ve özel sektör yatırımlarının önünün açılması amaçlanarak bağımsız bir otorite olan Enerji Piyasası Düzenleme Kurumu (EPDK) yeniden yapılandırılmış elektrik piyasalarını düzenlemek, denetlemek

ve piyasada faaliyet gösterecek piyasa oyuncularını lisanslandırmak üzere kurulmuştur. (Arslan 2008, Şener ve Uluca 2009).

Ticari bazda ise elektrik piyasası çeşitli oyunculardan oluşmaktadır. Yukarıda TEK'in türevleri olarak anılan kuruluşlar haricinde, Özel sektör şirketleri (üretim, dağıtım, toptan satış taraflarındaki ile otoprodüktörler<sup>1</sup>), özel haklara haiz olan bazı santraller (Yap-işlet vb. ) ve tüketiciler bu ticari yapının içinde olarak gösterilebilirler. Ticari anlamda üretimden tüketime doğru olan akış içinde, enerji alışverişini sağlayan en önemli birincil piyasa “ikili anlaşmalar” mekanizmasıdır. Üretimden tüketime doğru hemen hemen her kademedeki piyasa oyuncusu (nihai tüketiciler hariç) ikili anlaşmalar yolu ile elektrik enerjisini birbirlerine satmaktadır. İkili anlaşmalar yoluyla tamamlanamayan ve piyasa içerisinde talep nedeniyle üretilip nihai tüketiciye ulaştırılması gereken enerjinin ticari olarak akışı ikincil bir piyasa olan “havuz (spot) piyasa” mekanizması ile sağlanmaktadır.

Elektrik piyasasındaki bu ticari akış şekil 3.3 ile özetlenebilir:



Şekil 3.3 Elektrik piyasasının ticari yapısı

<sup>1</sup> Otoprodüktör, “esas olarak kendi elektrik enerjisi ihtiyacını elektrik karşılamak üzere üretimi ile işgal eden tüzel kişiyi” ifade etmektedir.



### 3.2.1 Dengeleme ve uzlaştırma piyasası (DUP)

Şekil 3.3'te de görüldüğü üzere, piyasadaki oyuncuların katılımı ile oluşan ticarete “havuz piyasası” önemli bir konuma sahiptir. İkili anlaşmalar neticesinde piyasada oluşan boşlukları doldurmak ve sistem dengesizliğini gidermek için oluşturulan sanal piyasa “Dengeleme ve Uzlaştırma” piyasası ve bu piyasa kurallarını açıklayan yönetmelik “Dengeleme ve Uzlaştırma Yönetmeliği (DUY)” olarak adlandırılmaktadır.

Tanım olarak “dengeleme”, toplam arzı toplam talebe eşit olacak şekilde ayarlama ve sistemi dengede tutma işlemidir. Ülkemizde yürütülen dengeleme ve elektrik enerjisi arz ve talebinin gerçek zamanlı olarak dengelenmesinden sorumlu kuruluş TEİAŞ'ın bir birimi olan Milli Yük Tevzi Merkezi'dir (MYTM). Diğer bir deyişle, Sistem İşletmecisi MYTM'dir (Camadan 2009). MYTM, özellikleri yönetmelikle belirlenmiş her tür üretim ve tüketim tesisini izler, gerektiğinde dengelemenin sağlanabilmesi ve toplam talebin karşılanabilmesi için üretim tesislerine yük artırımını veya azaltımını yönünde talimat verir.

Dengeleme işleminde yukarıda da bahsedildiği üzere öncelikle arz talep dengesi gözetilmekte, ayrıca şebeke sistem frekansı olan 50 Hz değeri çevrimiçi olarak tutturulmaya çalışılmaktadır.

Piyasa katılımcılarının uzlaştırılması işlemi ise piyasa işletmecisi olan Piyasa Mali Uzlaştırma Merkezi (PMUM) tarafından gerçekleştirilmektedir. PMUM, MYTM tarafından faaliyetleri sonucunda oluşan enerji dengesini (pozitif veya negatif yönde) dikkate alıp katılımcıların alacak veya borç tutarlarını belirleyerek uzlaştırma görevini ifa etmektedir (Camadan 2009).

Dengeleme işlemi iki aşamadan oluşur: Gün Öncesi Dengeleme, (ki bu 1 Aralık 2011 itibari ile Gün Öncesi Piyasası kapsamında) ile Gerçek Zamanlı Dengeleme (1 Aralık 2011 itibari ile Dengeleme Güç Piyasası kapsamında) yoluyla gerçekleşmektedir. Yukarıda bahsedilen spot piyasa işte bu Gün Öncesi Dengelemenin gerçekleştiği Gün Öncesi Planlamanın (Piyasası) içerisinde yer almaktadır.

### 3.2.2 Gün öncesi planlama (piyasası)

Gün öncesi dengeleme; sistemdeki arz ve talebin dengelenmesi ve piyasa katılımcılarının sözleşme taahhütleri ile üretim ve/veya tüketim planlarını gün öncesinde dengelemeleri amacıyla gerçekleştirilen faaliyetlerden oluşur ve **Gün Öncesi Planlama** ya da **Gün Öncesi Piyasası** aracılığıyla sağlanır. Bu tez kapsamındaki fiyat modeli 1 Aralık 2011 tarihine kadar olan veriler üzerinden geliştirileceği için piyasa “gün öncesi planlama” yani 1 Aralık öncesi duruma göre anlatılacaktır.

Gün Öncesi Planlama, piyasa katılımcılarına üretim ve/veya tüketim ihtiyaçları ile sözleşmeye bağlanmış yükümlülüklerini gün öncesinde dengeleme olanağını sağlama, elektrik enerjisi referans fiyatını belirleme, Sistem İşletmecisine gün öncesinden dengelenmiş bir sistem sağlama, Sistem İşletmecisine gün öncesinden kısıt yönetimi yapabilme imkanı sağlama, piyasa katılımcılarına, ikili anlaşmalarına ek olarak bir sonraki gün için enerji alış-satışı yapma fırsatı yaratma amaçlarına uygun olarak düzenlenir.

Tüm piyasa katılımcılarının gün öncesi planlamaya katılımları zorunludur. Kendi adına kayıtlı dengeleme birimi olan katılımcılar gün öncesi planlama kapsamında sistem satış, sistem alış teklifi sunarlar (DUY). Gün öncesi piyasasında yer alan bu saatli alış/satış teklif işlemleri saatlik olarak gerçekleşir. Gün öncesi planlamada kabul edilen alış ya da satış tekliflerinin sahibi ilgili piyasa katılımcısı alış veya satış yönünde verdiği teklife göre fiziki olarak elektriğin arzından veya talebinden yükümlüdür. Gün öncesi planlamada sunulan tüm teklifler belli bir teklif bölgesi, belli bir gün ve o gün içindeki belli bir zaman dilimi için geçerli olup her bir işlem, aktif elektrik enerjisinin gerçek zamanda fiziki teslimatı ile sonuçlandırılır.

Piyasa Katılımcıları tarafından saat 11:30’a kadar bir gün sonrası için Gün Öncesi Planlama süreci kapsamında her bir saat için;

- Günlük üretim planları,
- Tüketim tahminleri,

- İkili anlaşma alış miktarlarını
- İkili anlaşma satış miktarlarını,

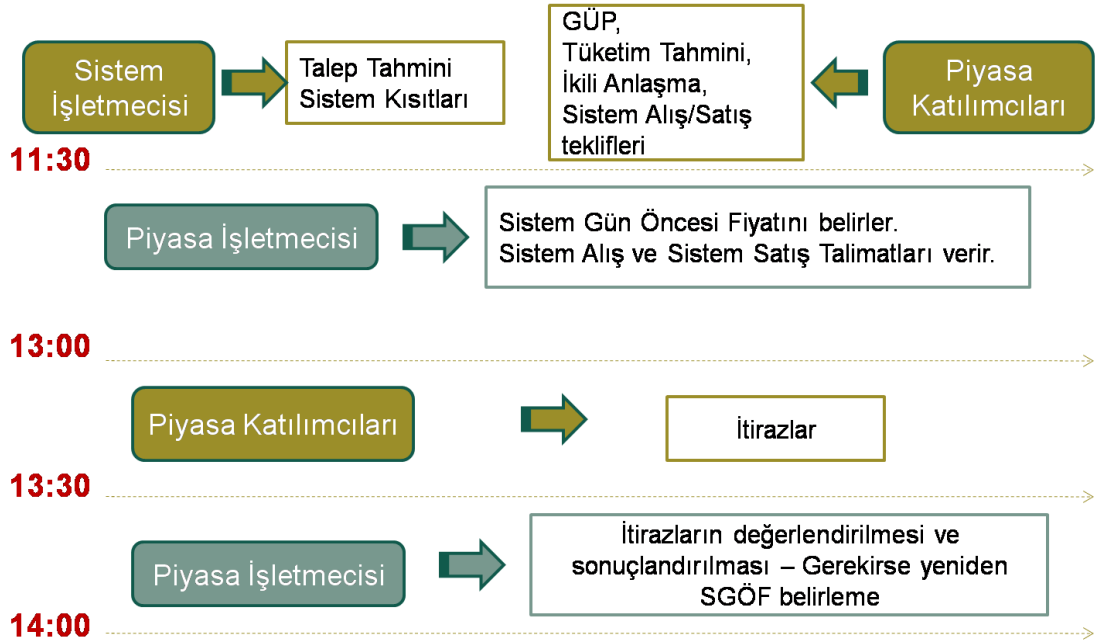
Dengeleme birimi sahibi piyasa katılımcıları da her bir dengeleme birimi için;

- Sistem Alış - Satış Teklifleri
- Blok Alış – Satış Tekliflerini,
- Esnek Satış Tekliflerini

TEİAŞ'a bağlı PMUM'a web tabanlı bir yazılım olan Piyasa Yönetim Sistemi (PYS) ile bildirir.

### **3.3 Sistem Gün Öncesi Fiyatının Oluşumu**

Piyasa katılımcıları daha önce de söz edildiği gibi sistem alış-satış tekliflerinin, blok alış-satış tekliflerini ve esnek satış tekliflerini PMUM'a PYS aracılığı ile bildirir. Bu bildirim, bu piyasanın işlediği günde saat 11:30'a kadar sunulmak zorundadır. PMUM'da halihazırda elinde olan talep tahminleri ve sistem kısıtlarını baz alarak, bir arz-talep dengesi içinde Sistem Gün Öncesi Fiyatını(SGÖF) belirler. Bu fiyata olası itirazlar saat 13:30'a kadar yapılmalıdır. Nihai SGÖF saat 14:00 itibari ile belirlenmiş olur. Bu mekanizmanın işleyişi şekil 3.4'te gösterilmiştir:



Şekil 3.4 SGÖF (PTF) belirleme süreci

### 3.3.1 Saatlik alış - satış teklifleri

Bu piyasada sistem alış/satış teklifleri farklı saatler için değişiklik gösterebilen miktar ve fiyat bilgilerinden meydana gelir. Bildirilen tüm teklif fiyatları yüzde birlik hassasiyete sahiptir ve teklifler TL cinsinden sunulur. Teklifler 1 MWh saat ve katları şeklinde PYS'ye girilir. Gün öncesi planlama kapsamında sunulan sistem satış ve sistem alış teklifleri en az aşağıdaki bilgileri içerir (DUY);

- İlgili piyasa katılımcısının adı ve gün öncesi planlamaya katılım kodu,
- Teklifin geçerli olduğu gün,
- Esnek teklifler dışında, teklifin geçerli olduğu zaman dilimi,
- Teklif tipi,
- Fiyat ve miktar bilgisi.

DUY'a göre saatlik satış teklifleri, bir piyasa katılımcısının önceden belli olan Günlük Üretim Planı'na göre, her bir saat için farklı fiyat seviyelerinde talep ettiği üretim artışı veya tüketim azalışını TL/MWh cinsinden teklif etmesidir. Saatlik alış teklifleri ise, bir piyasa katılımcısının önceden belli olan Günlük Üretim Planı'na göre, her bir

saat için farklı fiyat seviyelerinde talep ettiği üretim azalışını veya tüketim artışını TL/MWh cinsinden teklif etmesidir.

Piyasa katılımcıları 15 miktar seviyesinde saatlik satış ve alış teklifi bildirebilirler. Tüm saatlik satış ve alış teklif miktarlarına ilişkin fiyatlar sıfırdan büyük veya eşit olmak zorundadır. Saatlik satış teklifleri için teklif seviyesi bir önceki teklif seviyesinden büyük ya da eşit olacak şekilde artan bir seride girilmelidir. Aynı şekilde, tüm saatlik alış teklifleri için teklif seviyesi bir önceki teklif seviyesinden küçük ya da eşit olacak şekilde azalan bir seride girilmelidir.

### **3.3.2 Blok alış - satış teklifleri**

Blok alış-satış teklifleri ise saatlik tekliflerde olduğu gibi piyasa katılımcısının, alış için üretim artışı veya tüketim azalışının; satış için, üretim azalışı veya tüketim artışının MWh cinsinden miktarı kadar, belli bir saat yerine bir zaman aralığını seçerek (birkaç saat) bu miktar için talep ettiği (TL/MWh) cinsinden birim fiyatı içerir. Blok teklifler en az 4 saatlik zaman dilimleri için verilmelidir. Bu teklifler bir gün için her bir katılımcı bazında toplam 5 taneyi aşamaz. Blok teklifler, teklif yapılan zaman aralığının tümü için kabul edilir ya da reddedilir. Zaman aralığının daha küçük bir parçası için kabul edilmezler.

Bu teklifler haricinde gün içindeki yük alma işlemi için esnek teklif mekanizması oluşturulmuştur. Esnek tekliflerin, sistem gün öncesi fiyatının oluşumuna etkisi bulunmamaktadır.

### **3.3.3 Çoklu teklif ile sistem gün öncesi fiyatı oluşum örneği**

Çizelge 3.1'de örnek bir teklif seti gösterilmektedir. Teklifteki pozitif değerler alış yönünde, negatif değerler satış yönündeki teklif değerlerini göstermektedir.

Çizelge 3.1 Örnek bir piyasa katılımcısı

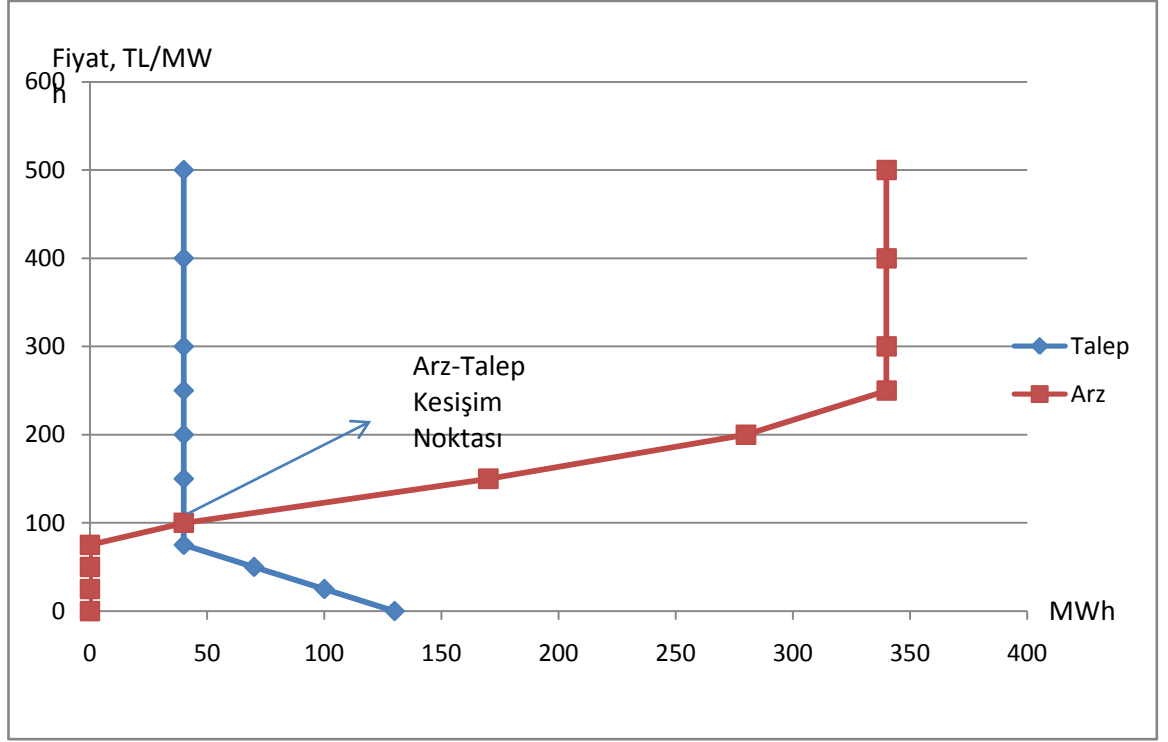
Fiyat, TL/MWh	0	25	50	75	100	150	200	250	300	400	500
Katılımcı A, MW	40	20	0	0	-10	-60	-120	-120	-120	-120	-120

Bu şekilde Katılımcı A, şöyle bir öngöründe bulunuyor. Eğer SGÖF “0” olursa 40 MWh, “25” olursa 20 MWh alacağım, eğer fiyat 100 TL’yi geçerse fiyatın durumuna göre sisteme elektrik satacağım demektedir. Bu katılımcı gibi diğer katılımcılardan sisteme tekliflerini sunarlar. Bu değerler bir arz-talep dengesi içine girer ve piyasa koşulları içinde ayrıca referans fiyat olan SGÖF değeri belirlenmiş olur.

Çizelge 3.2’de bu işlemin bir örneği gösterilmektedir. Burada A, B, C, D katılımcıları ertesi gün herhangi bir saat için sisteme tekliflerini sunmuşlardır. Tüm teklifler saatlik olarak alış veya satış yönünde gerçekleşmiştir. Arz-talep dengesi içinde sistem dahilindeki alış ve satış değerlerinin birbirine eşit olduğu yerde SGÖF değeri belirlenmiş olmaktadır. Aşağıdaki grafikte de gösterildiği üzere bu örnek için SGÖF değeri 100 TL olarak belirlenmiştir.

Çizelge 3.2 Alış ve satış yönünde tüm teklifler

Fiyat, TL/MWh	0	25	50	75	100	150	200	250	300	400	500
Katılımcı A, MW	40	20	0	0	-10	-60	-120	-120	-120	-120	-120
Katılımcı B, MW	50	40	30	0	0	50	-70	-100	-100	-100	-100
Katılımcı C, MW	40	40	40	40	40	40	40	40	40	40	40
Katılımcı D, MW	0	0	0	0	-30	-60	-90	-120	-120	-120	-120
Toplam Alış, MW	130	100	70	40	40	40	40	40	40	40	40
Toplam Satış, MW (-)	0	0	0	0	40	70	280	340	340	340	340



Şekil 3.5 SGÖF fiyatının arz-talep ile oluşumu

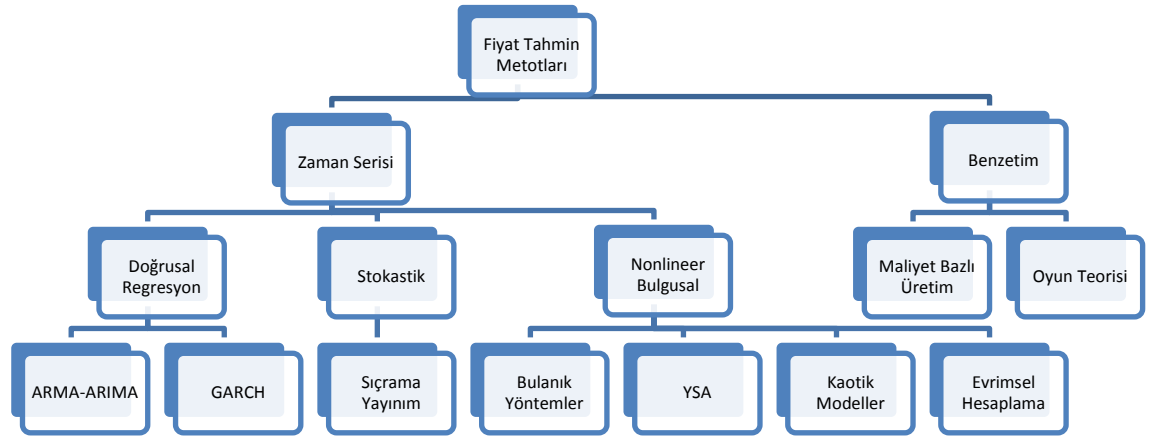
100 TL'lik fiyatın gerçekleşmiş olduğu noktada Katılımcı **A** 10 MWh, Katılımcı **D** 30 MWh sisteme enerji satarken, Katılımcı **C** sistemden 40 MWh saat enerji satın almaktadır. Katılımcı **B** ise spot piyasadan enerji alış/verişinde bulunmamaktadır.

## 4. SİSTEM GÜN ÖNCESİ FİYATININ MODELLENMESİ

### 4.1 Uygulanan Fiyat Tahmin Modeli Türleri

Sayısal (nicel) tahmin yolları temelde zaman serisi analizine dayalı ve sebep-sonuç ilişkisine dayalı metotlar olmak üzere ikiye ayrılır (Hamzaçebi 2011). En bilinen zaman serisi analizleri; hareketli ortalama, ARIMA, GARCH vb. olarak kullanılmaktadır. Sebep sonuç analizine dayalı metotlar ise regresyon üzerine kuruludur. Yapay sinir ağları ile tahmin ise her iki ayrımda da gösterilebilmektedir.

Elektrik piyasasında oluşan fiyatların tahmini için yapılan çalışmalara bakıldığında bir çok farklı yaklaşımın ele alındığı söylenebilir. Niimura'ya (2006) göre fiyat tahmini yollarına bakıldığında iki ana yol göze çarpmaktadır. Bunlar yukarıdaki ayrıma benzer şekilde zaman serisi analizi ile benzetim (simülasyon) metotlarıdır. Benzetim metotları genellikle “maliyet-tabanlı” optimizasyonu içermektedir. Özellikle iletim ve dağıtım sisteminin olası kısıtları, kesintileri ve diğer handikapları Monte-Carlo tipi stokastik benzetimlerle uyarlanmaya çalışılır. Benzetim sırasında oyun teorisi uygulamalarından faydalanılır.



Şekil 4.1 Fiyat tahmin metotları (Niimura 2006)



Zaman serisi analizleri temelde üç kısma ayrılabilir. Stokastik modeller normalde borsa için geliştirilmiş olup, yine zaman serisi verisini kullanmakla beraber fiyat tahmininden ziyade pozisyon tespiti için kullanılmaktadır. AR, ARMA ve ARIMA modelleri geçmiş tarihli verilerden fiyat tahminini hedeflerken, GARCH gibi regresyon modelleri fiyatlardaki dalgalanmayı tahmin etmeyi hedeflemektedir.

Doğrusal olmayan bulgusal modeller içerisinde ise bulanık (fuzzy) yöntemler, kaotik modeller, evrimsel hesaplama ve yapay sinir ağları gösterilebilmektedir. Bazen bu modeller tek başına kullanılmakla beraber bazı çalışmalarda karma modelleme yollarına gidilmiştir.

Zaman serisi modelleri için Contreras vd. (2003), Giurguis ve Felder (2004), Nogales vd. (2002), Swider ve Weber (2006), Weron ve Misiorek (2005), Weron ve Misiorek (2008), Zhou vd. (2004) ve Zhou vd. (2006), Jakaša vd. (2011) çalışmaları örnek verilebilir. Ayrıca hem zaman serisi modellerinde hem de doğrusal olmayan bulgusal modellerde sıklıkla kullanılan dalgacık dönüşümü (wavelet transform) ile ilgili bazı çalışmalar, Yao ve Song (2004), Kim vd. (2002), Conejo vd. (2005), Haiteng ve Niimura (2004) olarak gösterilebilir. Nogales ve Conejo 2005 yılındaki çalışmalarında modelleme yaparken transfer fonksiyonunu kullanmışlardır. Tüm bunlara ilave olarak birden çok metodu bir arada kullanan hibrit yaklaşımlar da literatürde yer almıştır. Amjady ve Keynia (2008), Wu ve Shahidehpour (2010), Shafie-khah vd. (2011) gibi çalışmalar “hibrit modelleme” çalışmaları olarak sıralanabilir.

## **4.2 Yapay Sinir Ağları ile Yapılan Çalışmalar**

Elektrik fiyatlarının tahmininde sıkça kullanılan doğrusal olmayan yöntemlerden bir diğeri ise yapay sinir ağlarıdır. YSA'ların tercih edilme nedeni konvansiyonel yöntemler ile modellenmesi güç olan karmaşık ve doğrusal olmayan ilişkileri öğrenme kabiliyetine sahip olmalarıdır (Aggarwal vd. 2009). YSA'lar, her ne kadar ilgili sürecin altında yatan mekanizma ile ilgilenmeden girdi ile çıktı arasında bir ilişki kurmaya yönelik oldukları söylene de, verilen girdilerin çıktı üzerindeki ağırlığını göstermeleri bakımından yapısal ilişkilerin tespiti için de önemli birer araç olarak kullanılabilirler.

Elektrik piyasası açısından öncelikle yapay sinir ağları ile talep tahmini veya yük tahmin konularında yapılan ilk çalışmalar (Peng vd 1990, Srinivasan vd 1991, Gooi vd 1993 vs.) fiyat tahmini modelleri açısından başlangıç noktası olagelmıştır. Bu modellerde geçmiş yük verileri yanı sıra sıcaklık bilgileri, kapasite bilgileri, gün özellikleri gibi veriler kullanılmıştır.

Elektrik piyasasında **fiyat** tahminlerinin yapay sinir ağları ile yapılması açısından öncü çalışma 1997 yılında Wang ve Ramsay'in Birleşik Krallık (BK) enerji havuz piyasasında gerçekleşen “sistem marjinal fiyatı”nı tahmin etmek için gerçekleştirdikleri modelledir. Modelleme her bir uzlaştırma periyodu için gerçekleştirilmektedir. Uzlaştırma periyotları o periyot için toplam planlanmış üretim kapasitesinin o uzlaştırma dönemi için karşılanması gereken talepten belli bir seviyeden fazla olması durumu (Tablo B) ve diğer durumlar (Tablo A) olmak üzere iki gruba ayrıştırılmıştır. Bu çalışmada her bir girdiye karşılık gelecek şekilde 12 tane girdi nöronuna sahip geri doğru yayımlı ileri beslemeli çok katmanlı yapay sinir ağı kullanılmıştır. Sistem girdileri ve çıktısı ise çizelge 4.1’de gösterilmektedir:

Çizelge 4.1 Wang ve Ramsay'in (1997) girdi kümesi

<b>Girdiler</b>	
	D(i)
	T(i,t)
	L(i,t)
	A_B(i,t)
	smp(i-21,t), smp(i-14,t), smp(i-7,t-1), smp(i-7,t), smp(i-7,t+1), smp(i-1,t-1) , smp(i-1,t), smp(i-1,t+1)
<b>Çıktı</b>	
	smp(i,t)

Girdilerin ve çıktıların açıklamaları ise çizelge 4.2’de sunulmuştur:

Çizelge 4.2 Girdi ve çıktıların açıklamaları

<b>TANIMLAR</b>	
i	Tahmin yapılan gün
t	Tahmin edilen uzlaştırma periyodu (BK için her yarım saat )
smp	Sistem marjinal fiyatı
D	Tahmin edilen saat için talep miktarı
T	Tahmin yapılan günün tipi (hafta sonu, tatil vs.)
L	Tahmin yapılan periyod için yük miktarı
A_B	Tahmin edilecek uzlaştırma periyodunun bulunduğu tabloyu

Yazarlar bu çalışmada farklı ağ topolojileri kullanmışlar ve her bir topoloji için ortalama mutlak yüzde hata (OMYH) hesaplamışlardır. Aynı yazarlar 1998 yılındaki yayınlarında ise bu çalışmalarına ilave olarak verileri süzerek, tahmin yapılacak günün tipine göre(cumartesi, pazar ve diğer tatil günleri) üç farklı şablon kullanarak farklı ağ topolojileri için bu günleri ayrı ayrı tahmin etmişlerdir. Bu çalışmalarda izlenen metodoloji ve kullanılan girdi seti takip eden çalışmalar için örnek teşkil etmiştir.

Szkuta vd. (1999) benzer şekilde Avustralya'nın Viktorya Eyaleti elektrik piyasası için geçmiş fiyat, talep ve kapasite verilerinin yanı sıra takvimsel özellikleri (gün tipi, mevsim, tatil kodu vs.) özellikleri içeren girdi setine karşılık gelen çıktıyı tahmin etmeye çalışmışlardır. Gao vd. (2000) bu girdi setine hava koşullarını ve yakıt fiyatlarını eklemiştir.

Yamin vd. (2004) yaptıkları çalışmada yukarıdaki girdi setinin benzeri şeklini kendi kurdukları ağa sunarak fiyat tahminine ulaşmışlardır. Burada farklı olarak fiyatlardaki ani çıkışların tahmin üzerinde olan etkisini kırabilmek için fiyatların aşırı artış gösterdiği değerler için üst limit koyma yolunu seçmişlerdir. Kendi üst limitlerine  $F_{üst}$  dersek kurdukları modelde veriyi ağa sunmadan önce şu işlemi uygulamışlardır:

$$F_{yeni} = \begin{cases} F_{eski} & \text{eğer } F_{eski} \leq F_{üst} \\ F_{üst} + F_{üst} \ln\left(\frac{F_{eski}}{F_{üst}}\right) & \text{eğer } F_{eski} > F_{üst} \end{cases} \quad (4.1)$$

Daha sonra ađa yeni veri seti sunduklarında çok daha başarılı sonuçlara ulaşmışlardır. Ayrıca çalışmalarında eğitim setinin büyüklüğünün tahmin gücüne olan etkisini de incelemişlerdir.

Rodriguez ve Anders (2004) Ontario güç piyasası için yapmış oldukları çalışmada önce tek başına yapay sinir ağlarını kullanarak, daha sonra nöro-bulanık yöntem ile ve daha sonra sistem kısıtları üzerinden yapmış oldukları modellemeleri kıyaslamışlardır.

Tüm bu çalışmaları takip eden çalışmalar içerisinde salt yapay sinir ağlarını kullananlar (Zhang vd. 2003, Pao 2007, Catalão vd. 2007) yanı sıra, nöro-bulanık çözümler getiren çalışmalarla beraber (Niimura vd. 2002, Hong ve Lee 2005, Amjady 2006 ), ilerleyen dönemlerde hibrit modeller üzerinde duran çalışmalar (Amjady ve Keynia 2008, Wu ve Shahidehpour 2010 ) geliştirilmiştir.

### **4.3 Sistem Gün Öncesi Fiyatının Modelleme için Yapay Sinir Ađı Uygulaması**

#### **4.3.1 Girdilerin türü ve kapsamı**

Dođru bir modelleme yapılabilmesi için sağlıklı bir veri havuzunun ortaya konulması gerekmektedir. Literatürde yapılan çalışmalarda yapay sinir ağının dođru tepki verebilmesi için kullanılan veriler özenle seçilmiş ve girdi olarak sisteme sunulmuştur. Aggarwal vd (2009)'un literatürü gözden geçirdiđi ve deđerlendirdiđi makalesinde, yapay sinir ağları ile elektrik fiyatı tahmininde kullanılan girdi verileri řu şekilde özetlenmektedir:

- Geçmiş yük verileri
- Sistem yük miktarı
- İthalat/ihracat
- Kapasite fazlası/açıđı
- Tarihi rezervler
- Nükleer üretim kapasitesi
- Termal üretim kapasitesi

- Hidroelektrik üretim kapasitesi
- Mecburi çalışma oranı
- Hat limitleri
- Geçmiş denge miktarı
- Tahmini yük
- Tahmini rezervler
- Sıcaklık
- Hava durumu
- Benzin fiyatı
- Doğal gaz fiyatı
- Yakıt fiyatı
- Hat durumu
- Kısıt endeksi
- Geçmiş fiyat verileri
- İşaretçi (tahmin edilecek saatin komşuluğundaki aşırı yüksek fiyatlar için)
- Uzlaştırma periyodu
- Gün tipi
- Ay
- Tatil kodu
- Noel tatili kodu
- Saat farkı
- Mevsim

Bu verilerden hemen hepsini havuz piyasasında oluşan fiyat modellemesinde kullanabilme imkanına sahip olunmasına karşın, araştırmacıların bu verilerden en sık kullandıkları geçmiş fiyat verileri olagelmıştır. Bunun haricinde talep miktarı ikinci önemli veri seti olmuştur (Aggarwal vd. 2009). Bu çalışmada da öncelik olarak geçmiş fiyat bilgileri ve talep miktarları kullanılmış bunların yanı sıra farklı girdi setleri üzerinde çalışılmıştır.

### 4.3.2 Uygun yapay sinir ağı modelleme ve ağı topolojisi

Fiyat tahmini için kurulacak olan ağın oluşturulması için bu ağı toplamda **kaç katmandan** oluşacağı ve her bir katman içinde yer alacak **nöron sayısı** belirlenmelidir.

Seçilecek olan model elbette ki tahmin edilecek olan parametreye ve buna karşılık gelen girdi türlerine göre şekillenecektir. Literatürde benzeri tahmin amaçlı çalışmalarda farklı ağı topolojileri önerilmekle beraber kesin ve açık bir metot bulunmamaktadır. Genel anlamda ise modeller arası kıyas yapabilmek açısından BIC (Bayesian Information Criterion) istatistiği veya AIC (Akaike Information Criterion) kullanılabilir. BIC ve AIC değerleri;

$$BIC = N \cdot \ln\left(\frac{HKT}{N}\right) + P \ln(N) \quad (4.2)$$

$$AIC = N \cdot \ln\left(\frac{HKT}{N}\right) + 2P \quad (4.3)$$

olarak hesaplanır. Burada N eğitim kümesinin büyüklüğünü, HKT hata kareleri toplamını, P ağı parametreleri sayısını yani ağıdaki mevcut bağlantı sayısını göstermektedir. BIC veya AIC değeri hesaplanan modeller arasından, daha düşük değerlere sahip olan model seçilmelidir. Ayrıca bu istatistikler her bir döngüde hesaplanarak, optimum katman ve nöron sayısı da belirlenebilmektedir (Sureerattanan vd. 2006).

Girdilerin yapısı ve sayısı yukarıda da bahsedildiği üzere literatürde farklı boyutlarda ve farklı türlerde ele alınarak modele sunulmuştur. Gizli katman sayısı ise bazı uygulamalarda iki olmakla beraber çoğu tahmin problemlerinde tek olarak ele alınmıştır. İki'den fazla gizli katmana ise ihtiyaç duyulmadığı belirtilmektedir (Kaastra ve Boyd 1996, Hamzaçebi 2011).

Gizli katmandaki nöron sayısının belirlenmesinde ise sabit bir kural bulunmamaktadır. Genel olarak, literatürde nöron ve katman sayısını belirlemek için dört yol izlenmektedir. Bunlar, deneme-yanılma yöntemi, kural oluşturarak yapılan bulgusal arama, olası tüm durumları inceleyen detaylı arama ve ağırlıkları ekleme ve çıkarmaya dayanan budama ve inşa algoritması olarak sıralanabilir (Stathakis 2008). Yapılan tüm bu çalışmalar neticesinde “n” tane girdi nöronu ve “m” çıktı nöronu için gizli katmandaki nöron sayısı için bazı öneriler:

- a)  $n$
- b)  $2n+1$
- c)  $2n$
- d)  $n^2$
- e)  $n \times \left(\frac{n-1}{2}\right)$
- f)  $\sqrt{n \times m}$
- g)  $0.75 \times n$

olarak belirtilebilir (Hamzaçebi 2011). Bu önerilerin yanı sıra hata performansına endeksleyerek iteratif bir şekilde nöron sayıları bulunabilmektedir.

Ağ yapısını kurduktan sonra dikkat edilmesi gereken bir diğer husus ise, sisteme girdi olarak sunulacak olan verilerin normalleştirilmesidir. Kullanılan aktivasyon fonksiyonunun çıktısının  $[0,1]$  veya  $[-1,1]$  aralığına sıkıştığı durumlarda, ağa sunulacak olan verinin de hesaplama hatalarından kaçınılması açısından normalleştirilmesi daha avantajlı olacaktır. Sıklıkla kullanılan normalleştirme fonksiyonlarını şu şekilde özetlenebilir:

- a)  $[0,1]$  aralığında doğrusal dönüşüm:

$$x_n = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad (4.4)$$

- b)  $[a,b]$  aralığında doğrusal dönüşüm:

$$x_n = (b - a) \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} + a \quad (4.5)$$

c) Basit normalizasyon:

$$x_n = \frac{x_0}{x_{\max}} \quad (4.6)$$

d) İstatiksel normalizasyon:

$$x_n = \frac{x_0 - \bar{x}}{s} \quad (4.7)$$

Burada	$x_n$	normalleştirilmiş veriyi,
	$x_0$	orijinal veriyi,
	$x_{\min}$	veri vektöründeki minimum değeri,
	$x_{\max}$	veri vektöründeki maksimum değeri,
	$\bar{x}$	veri vektörünün ortalamasını,
	$s$	standart sapmayı göstermektedir.

Çıktı nöronlarının aktivasyon fonksiyonuna bağlı olarak normalleştirme aralığı belirlenebilir. Örneğin aktivasyon fonksiyonunun sigmoid olduğu fonksiyonda normalleştirme aralığı [0,1] olarak, aktivasyon fonksiyonunun hiperbolik tanjant olduğu fonksiyonda normalleştirme aralığı [-1,1] olarak seçilir.

Bir diğer husus ise eldeki veri setinin hangi oranda eğitim ve hangi oranda test için kullanılacağıdır. Literatürde farklı önermeler olmakla beraber, genellikle %80-%20, %70-%30 veya %60-%40 gibi oranlar tercih edilmektedir. Fiyat modellemesi ile ilgili çalışmalarda da birbirlerinden farklı değerler kullanılmıştır. Örneğin eğitim setini, Wang ve Ramsay (1997) %73, Gao vd. (2000) %60, Zhang vd. (2003) %73, Hong ve Lee (2005) %80, Catalao vd. (2007) %85 oranında tutmuş, Yamin vd. (2004) ve Pao (2007) ise çalışmalarında farklı oranlarda ayrıştırmaya giderek bunun ağ performansına etkilerini incelemişlerdir.



Performans ölçütü de ağın doğru eğitilmesinde önemli bir yer oynamaktadır. Tahmin amaçlı kurulan bir yapay sinir ağının en önemli ölçütü tahmin hatasıdır. Basit olarak tahmin hatası e;

$$e = \text{Gerçekleşen-Tahmin Edilen} \quad (4.8)$$

olarak gösterilmektedir. Tahminin doğruluğunu ölçmek için bir çok kriter tanımlanmıştır. Bunlardan bazıları;

$$\text{Ortalama Hata (OH)} = \frac{1}{n} \sum_{i=1}^n e_i \quad (4.9)$$

$$\text{Ortalama Mutlak Hata (OMH)} = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4.10)$$

$$\text{Hata Kareleri Toplamı (HKT)} = \sum_{i=1}^n e_i^2 \quad (4.11)$$

$$\text{Hata Kareleri Ortalaması (HKO)} = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (4.12)$$

$$\text{Ortalama Karekök Hatası (OKH)} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (4.13)$$

olarak yer almaktadır. Fiyat tahmini çalışmalarında ise sıklıkla yüzde hata ölçütleri kullanılmaktadır. Bunlar ise;

$$\text{Yüzde Hata (YH)} = \frac{e_i}{\text{Gerçekleşen}_i} \times 100 \quad (4.14)$$

$$\text{Ortalama Yüzde Hata (OYH)} = \left( \frac{1}{n} \sum_{i=1}^n \frac{e_i}{\text{Gerçekleşen}_i} \right) \times 100 \quad (4.15)$$


$$Ortalama Mutlak Yüzde Hata (OMYH) = \left( \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{Gerçekleşen_i} \right| \right) \times 100 \quad (4.16)$$

olarak yer almaktadır.

### 4.3.3 Kurulan yapay sinir ağı ve çalışma prensibi

Kurulmuş olan geri doğru yayımlı ileri beslemeli çok katmanlı yapay sinir ağı için modellenecek gün içindeki belirli saat için gerçekleşmesi öngörülen sistem gün öncesi fiyatı  $f_{g,s}^{tah}$ , bu tahmin için ağa girdi olarak sunulacak olan n gün öncesi aynı saat için gerçekleşen fiyat değeri  $f_{g-n,s}$ , yine bu tahmin için ağa girdi olarak sunulacak olan m hafta öncesi aynı tür gün ve aynı saat için gerçekleşen fiyat değeri  $f_{g-7m,s}$ , tahmin yapılacak ilgili gün için toplam nüfusu 3.000.000'dan fazla şehirlerin (Ankara, İstanbul, İzmir) gerçekleşen sıcaklık derecelerinin ağırlıklı ortalama (nüfus 2010) değeri  $t_{ort,g}$ , tahmin edilecek gün ve saat için yapılmış olan tüketim tahmini  $tt_{g,s}$ , tahmin edilecek gün ve saat için gerçekleştirilen ikili anlaşma miktarını  $ia_{g,s}$ , ilgili gün için alınabilir toplam kapasite (termal, hidro ve rüzgar) miktarını sırasıyla  $a_{kap,g}$ , ilgili günün tipi  $gtip_g$  olarak belirlenerek girdi seti oluşturulmuştur. Farklı denemeler yolu ile girdi setlerinden sıralanmış olan bu veriler çıkartılarak modelin gücüne ve sonuca olan etkisi irdelenmiştir.

Nihai olarak oluşturulan girdi seti sonucunda yapay sinir ağı şekil 4.2'deki gibi tasarlanmıştır:



Şekil 4.2 Kurulan ağ yapısı ve girdi kümesi

#### 4.4 Nümerik Çalışmalar

Yukarıda değinilen tasarım ilkelerine ve yöntemlerine göre oluşturduğumuz modeller ile 1 Aralık 2009 tarihi ile 31 Aralık 2010 tarihleri arasındaki toplam 396 günlük veri kümesi için bir sonraki günün ilgili saatinin sistem gün öncesi fiyatını tahmin edilmektedir. Modelleme yapılırken her bir tasarım unsuru için ağ eğitilerek ağın performans sonuçlarına bakılmıştır. Modelleme Matlab programı üzerinden yapılmış, her bir konfigürasyon için beşer kez deneme yapılmış ve en iyi performans sonucu dikkate alınmıştır.

##### 4.4.1 Sadece geçmiş SGÖF verileri kullanılarak modelleme

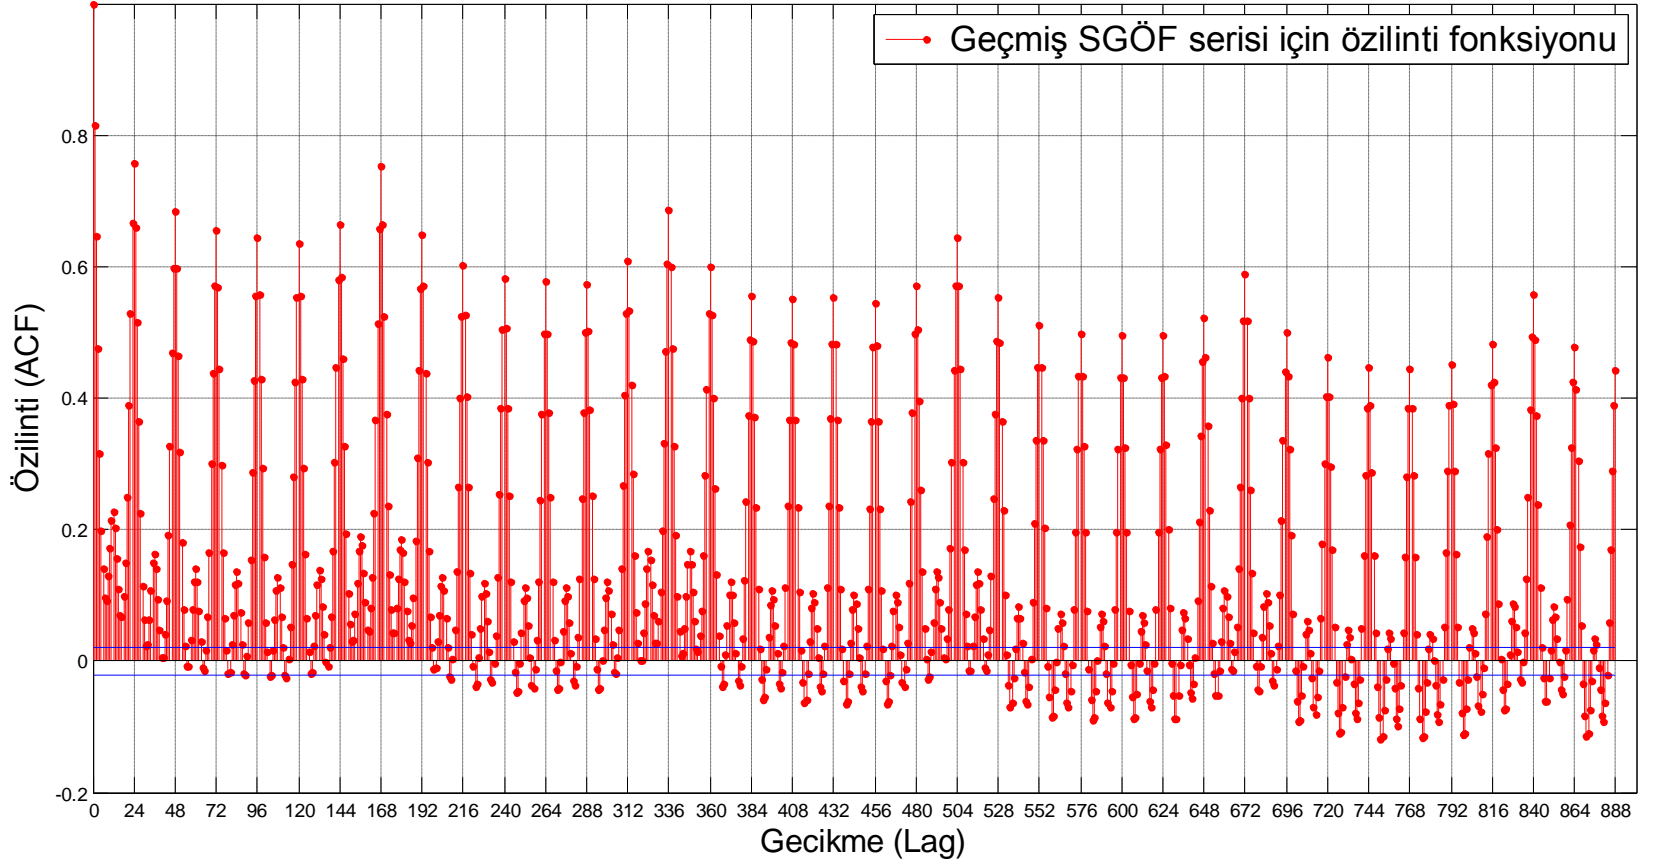
Bazı çalışmalarda olduğu gibi (Niumura vd. 2002) sadece geçmiş fiyat verileri kullanılarak bir modelleme yapılması mümkündür. Geçmiş fiyat verileri esas alınarak yapılan modelleme için Wang vd (1997), Szkuta vd. (1999) ve diğer çalışmalarda olduğu gibi tahmin edilecek olan çıktıyı en iyi şekilde açıklayabilecek veriler kullanılmaya çalışılmıştır. Bu verilerin seçiminde geçmiş fiyat verisinin beş haftalık öz ilinti fonksiyonuna bakmak (Pao 2007) yeterli olacaktır (bkz. Şekil 4.3 ). Görülebileceği

üzere herhangi bir saat için o saate komşu olan saatler ile, ilgili günden önceki günlerin aynı saatleri (Gecikme 24 ve katları) ve bir hafta, iki hafta, üç hafta önceki aynı saat (Gecikme 168 ve katları) arasında yüksek korelasyon bulunmaktadır.

İlk deneme eğitimi şu girdi kümesi için yapılmıştır:

$$\{f_{g-1,s} \quad f_{g-1,s-1} \quad f_{g-1,s+1} \quad f_{g-2,s} \quad f_{g-3,s} \quad f_{g-4,s} \quad f_{g-5,s} \quad f_{g-6,s} \quad f_{g-7,s} \quad f_{g-14,s} \quad f_{g-21,s}\}$$

Gece 00:00 için oluşacak olan SGÖF modellenirken, bir gün öncesinin 1 saat sonrası fiyat değerini alırken alınması gereken değer aslında tahmin edilecek olan günün ilk saati olacaktır. Tahmin edilecek bir değeri ağa göstermek mantıklı olamayacağı için bu değer yerine bir önceki gün aynı saati ağa göstermek yerinde olacaktır.



Şekil 4.3 Geçmiş beş haftalık SGÖF verisi için öz ilinti fonksiyonu

#### 4.4.1.1 Gizli katmandaki nöron sayısına ve katman sayısına göre performans

Model önce “n” kadar gizli nöronun olduğu bir ağ ile kurulmuştur. Yani, 11x11x1’lik tek bir gizli katmana sahip ağ ile simülasyon yapılmıştır. Bu simülasyon için kurulan ağda aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmış, eğitim Levenberg-Marquardt<sup>2</sup> algoritması ile gerçekleştirilmiştir. Verinin yaklaşık % 75’i eğitim seti % 25’i ise test seti olarak kullanılmıştır. Daha sonra sırasıyla 2n+1, 2n,  $\sqrt{n \times m}$ ,  $0,75 \times n$ , değerleri için girdi katmandaki nöron sayıları değiştirilmiştir. Bu modellere göre ortaya çıkan OMYH’ler 80 günlük test kümesinde 1920 saat için genel ve haftalık bazda hesaplanmıştır.

Genel bazda hesaplama;

$$Genel\ Hata = \left( \frac{1}{1920} \sum_{i=1}^{1920} \left| \frac{e_i}{Gerçekleşen_i} \right| \right) \times 100 \quad (4.17)$$

haftalık bazda hesaplama ise;

$$Haftalık\ Hata = \left( \frac{1}{7} \sum_{i=1}^7 \left| \frac{e_i}{Gerçekleşen_i} \right| \right) \times 100 \quad (4.18)$$

olarak yapılmış, toplam 11 hafta için OMYH hesaplanmıştır. Sonuçlar çizelge 4.3’te gösterildiği şekilde oluşmuştur:

---

<sup>2</sup> Levenberg-Marquardt algoritması anlatımı Ekler bölümünde sunulmuştur.

Çizelge 4.3 Gizli katmandaki nöron sayısına göre performans

a) Gizli katmanda 11 tane nöron olduğu zaman (n)

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,64%	8,31%	9,92%	18,62%	7,19%	15,00%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	9,75%	11,54%	10,35%	10,87%	21,81%	12,54%

b) Gizli katmanda 22 tane nöron olduğu zaman (2n)

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,83%	8,27%	10,68%	18,37%	7,63%	14,52%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,19%	11,98%	11,64%	10,86%	23,62%	12,91%

c) Gizli katmanda 23 tane nöron olduğu zaman (2n+1)

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	18,44%	12,92%	15,63%	18,79%	7,58%	14,60%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	12,12%	12,13%	12,48%	11,86%	25,41%	14,59%

d) Gizli katmanda 4 tane nöron olduğu zaman ( $\sim\sqrt{n \times m}$ )

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	15,31%	8,49%	10,73%	16,80%	8,35%	14,08%


	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	11,63%	11,62%	12,95%	11,00%	24,15%	13,10%

e) Gizli katmanda 9 tane nöron olduğu zaman ( $0,75 \times n$ )

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	16,11%	8,85%	11,52%	18,82%	8,30%	13,78%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	11,67%	12,54%	11,63%	11,79%	24,44%	13,47%



Şekil 4.4 Gizli katmandaki nöron sayısına göre performans

Yukarıdaki çizelgelerden de anlaşılacağı üzere, gizli katmanda farklı nöron sayıları denenerek oluşturulan ağların çıktıklarına bakıldığında birbirlerine yakın hata değerleri oluşmaktadır. Bununla beraber gizli katmandaki nöron sayısı 11 olduğunda yani girdi sayısına eşitlendiğinde daha iyi sonuç elde edildiği görülmektedir (Bkz. Şekil 4.6).

Çift katmanlı ve farklı nöron sayılı topolojiler için sonuçlar çizelge 4.4'te görüldüğü şekliyle ortaya çıkmıştır:

Çizelge 4.4 Çift katmanlı ağ performansları

a) 11x11x11x1'lik YSA'nın hata yüzdeleri

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,05%	7,77%	10,47%	19,02%	7,68%	14,08%
	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,43%	11,68%	12,20%	10,88%	23,25%	12,85%



Çizelge 4.4 Çift katmanlı ağ performansları (devam)

b) 11x11x3x1'lik YSA'nın hata yüzdeleri

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,56%	8,06%	11,47%	18,95%	8,52%	14,13%


	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,39%	11,77%	12,05%	10,95%	23,15%	13,05%

c) 11x11x20x1'lik YSA'nın hata yüzdeleri

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	18,75%	8,16%	11,49%	19,25%	8,59%	13,95%


  

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,92%	11,82%	12,11%	11,09%	24,52%	13,61%



Şekil 4.5 Çift katmanlı ağ performansları

Sonuçlardan da görülebileceği üzere ağ üzerindeki katman sayısını artırmak sonuçlara olumlu yönde etkilememiş, bununla birlikte gizli katman içerisindeki ikinci katmanda daha düşük sayıda nöron kullanmak hata oranını azaltmıştır.



Şekil 4.6 11x11x1'lik ağ ile tahmin sonucu ve gerçekleşen değerler

#### 4.4.1.2 Aktivasyon fonksiyonuna göre performans

Yine 11x11x1'lik tek bir gizli katmana sahip ağ ile simülasyon yapılmıştır. Bu simülasyon için kurulan ağda eğitim Levenberg-Marquardt algoritması ile gerçekleştirilmiştir. Verinin yaklaşık % 75'i eğitim seti % 25'i ise test seti olarak kullanılmıştır. Bu kez yukarıda kullanılan aktivasyon fonksiyonu olan tanjant hiperbolik yerine kullanılacak olan logaritmik sigmoid ve lineer fonksiyonlarına göre performans sonuçları çizelge 4.5'te gösterildiği gibi gerçekleşmiştir:

Çizelge 4.5 Aktivasyon fonksiyonuna göre performans

a) Aktivasyon fonksiyonu **logaritmik sigmoid** olduğunda

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
OMYH	13,96%	7,42%	10,03%	19,32%	7,05%	13,90%

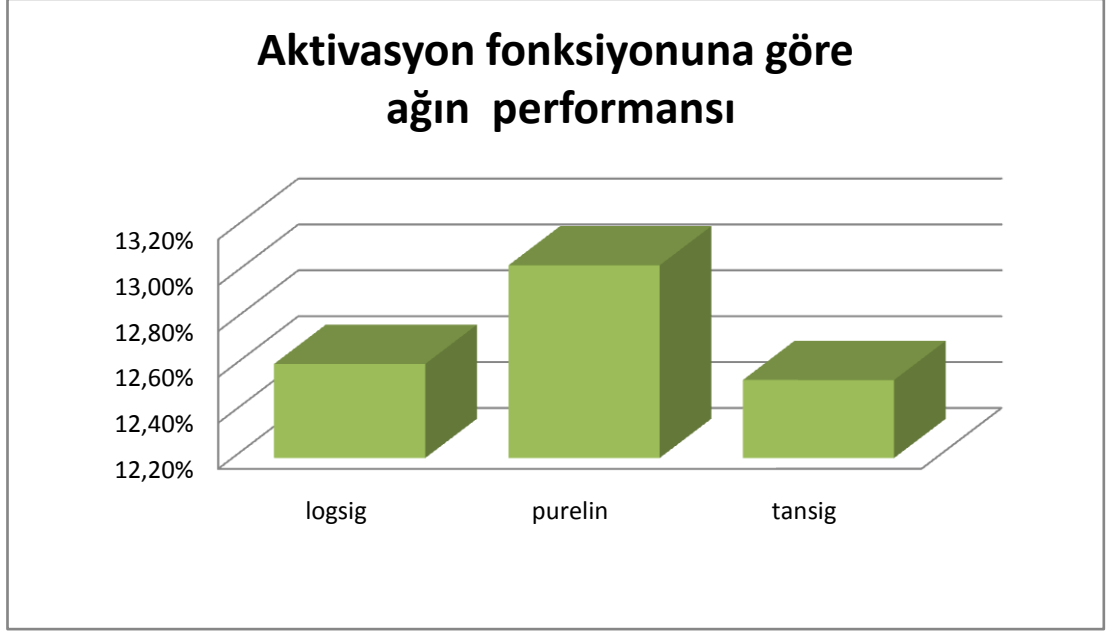
	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	Genel
OMYH	10,41%	11,69%	11,28%	10,56%	22,87%	12,61%

b) Aktivasyon fonksiyonu **lineer** olduğunda

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
OMYH	12,76%	7,74%	11,41%	18,47%	9,18%	15,20%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	Genel
OMYH	11,35%	12,44%	11,09%	11,25%	22,27%	13,04%

Yukarıdaki çizelgelere göre; aktivasyon fonksiyonu seçiminde logaritmik sigmoid ile hiperbolik tanjant birbirine yakın sonuçlar vermiş, buna karşılık lineer fonksiyonun kullanımını daha kötü sonuçlar vermiştir.



Şekil 4.7 Aktivasyon fonksiyonuna göre ağın performansı

#### 4.4.1.3 Eğitim metodunda göre performans

Klasik geri yayılım algoritmalarında kullanılan eğitim düşümü metodu yerine yukarıdaki örneklerde kullanılan ve Quasi-Newton yaklaşımının farklı bir uygulaması olan (Demuth ve Beale 2002, Hagan vd 1996) Levenberg-Marquardt algoritmasının performansı farklılıklar göstermektedir. Yine 11x11x1'lik topolojiye sahip ve diğer parametreleri yukarıdaki örneklerle aynı olan ağlarda sırasıyla basit eğitim düşümü, adaptif öğrenme katsayılı ve momentumlu eğitim düşümü ve Levenberg-Marquardt algoritması ile eğitilen ağların performans sonuçlarına bakılmıştır. Basit eğitim düşümünde öğrenme katsayısı adaptif olmadığından minimum hata oranından uzaksamış ve çözümsüz olmuştur. Yukarıdaki modelleme önerilerinde de değinildiği üzere normalize edilmemiş olan veri minimum noktasından uzaksamaya neden olmuştur. Basit metot ile yapılan normalleştirme sonucu uygulanan eğitim düşümü metodu ve diğer eğitim metotları ile oluşan performans sonuçları çizelge 4.6'daki gibidir:

Çizelge 4.6 Eğitim metodunda göre performans

a) Normalize edilmiş eğitim düşümü ile eğitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	33,20%	11,06%	13,89%	23,11%	15,27%	25,46%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	21,28%	21,13%	26,27%	24,77%	30,29%	22,29%

b) Adaptif öğrenme katsayılı ve momentumlu eğitim düşümü ile eğitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	18,25%	9,03%	11,83%	18,47%	8,60%	16,40%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	12,67%	12,63%	12,20%	12,68%	23,58%	14,22%


c) Levenberg-Marquardt algoritması ile eğitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,64%	8,31%	9,92%	18,62%	7,19%	15,00%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	9,75%	11,54%	10,35%	10,87%	21,81%	12,54%

Levenberg-Marquardt algoritmasının diğer eğitim düşümü algoritmalarına göre daha verimli çalıştığı yukarıdaki sonuçlarla da ortaya konulmaktadır.



Şekil 4.8 Eğitim metoduna göre hata performansı

#### 4.4.2 Geçmiş SGÖF verileri ve diğer verileri kullanarak modelleme

Aggarwal'ın (2009) belirttiği üzere literatürde yer alan fiyat tahmini modelleri ile sunulan girdi kümelerinde birçok farklı unsur yer almaktadır. Bu çalışma kapsamında sıklıkla kullanılan veriler geçmiş SGÖF verileri ile harmanlanarak oluşturulan girdi kümeleri oluşturulmuş ve farklı girdilerin ağ performansına etkilerini bakılmıştır. Burada da 11x11x1'lik tek bir gizli katmana sahip ağ ile simülasyon yapılmıştır. Bu simülasyon için kurulan ağda aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmış, eğitim Levenberg-Marquardt algoritması ile gerçekleştirilmiştir. Verinin yaklaşık % 75'i eğitim seti % 25'i ise test seti olarak kullanılmıştır.

Öncelikle tahmin edilecek güne ve saate ilişkin tüketim tahmini verisi geçmiş SGÖF verileri ile sisteme sunulmuş ve bu girdi kümesi ile ağ eğitilmiştir. Daha sonra tüketim tahmini verisi yerine sırasıyla ikili anlaşma miktarları, toplam kapasite miktarı, sıcaklık tahmini (üç büyük kent için ağırlıklı ortalama sıcaklık değerleri) ve gün tipi (hafta içi için **0** ve hafta sonu için **1**) geçmiş SGÖF verileri ile sisteme sunulmuştur. Tüm bu

eđitim s¼reçlerinde ortaya ıkan performans sonuları izelgeler 4.7'deki gibi ŐekillenmiŐtir:

izelge 4.7 Farklı veriler kullanıldıđında ađın performansı

a) T¼kretim tahmini ve SGF girdileri ile eđitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	13,02%	8,07%	9,20%	14,76%	10,06%	12,54%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	12,21%	12,94%	12,70%	12,40%	22,71%	13,15%

b) İkili anlaşma miktarı ve SGF girdileri ile eđitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	15,89%	9,22%	10,83%	17,36%	7,73%	13,58%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	11,49%	11,40%	13,29%	11,23%	23,90%	13,16%

c) Kullanılabilir kapasite miktarı ve SGF girdileri ile eđitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	15,78%	7,72%	10,05%	18,70%	9,37%	14,94%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,31%	11,87%	12,68%	11,70%	23,44%	13,19%

d) Ortalama sıcaklık ve SGF girdileri ile eđitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	16,45%	8,89%	9,81%	18,91%	7,24%	16,16%


	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,69%	11,25%	11,81%	11,04%	22,58%	13,08%

e) G¼n tipi ve SGF girdileri ile eđitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	13,87%	9,64%	11,94%	18,70%	7,49%	14,12%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,38%	12,60%	11,66%	11,35%	24,03%	13,25%

Elde edilen OMYH sonuçlarına göre, eklenen verilerin genelde benzer oranda performans gösterdiği bununla birlikte; sıcaklık verisinin diğer verilere oranla biraz daha etkili olduğu ortaya çıkmaktadır.




Şekil 4.9 Farklı veriler kullanıldığında ağın performansı

#### 4.4.3 Yüksek değerleri kırarak oluşturulan girdi ile modelleme

Gao vd (2000), Yamin vd (2004) gibi çalışmalarda da yer aldığı gibi uç noktalarda çıkan ve eğitim kümesini bozan sonuçları ortadan kaldırmak için girdi kümesindeki aşırı yüksek değerleri kırarak sonuçları iyileştirme de etkin bir rol oynayacaktır. Modellemenin anlatıldığı bölümlerde yer aldığı şekliyle bir  $F_{üst}$  eşiği belirleyerek buna göre kırma yapılmıştır. Öncelikle  $F_{üst}$ 'den daha büyük değere sahip fiyat değerlerini  $F_{üst}$ 'e eşitleyerek kırma yaparak oluşturulan girdi kümesi ağa verilmiştir.

Aşağıdaki şekilde geçmiş gerçekleşen SGÖF verilerini gösteren grafik gösterilmektedir (396 gün x 24 Saat). Bu grafikten de görülebileceği üzere maksimum fiyat değerleri 200 TL civarında seyretmekte iken bilhassa belli bir bölümde yüksek fiyat sıçramaları gözlemlenmektedir.





Şekil 4.10 Geçmiş SGÖF verilerinin dağılımı (01/12/2009-31/12/2010)

Üst limiti 200 TL civarında tutarak yapılacak olan seçim uygun bir seçim olacaktır. Veri kümesinde 200 TL üzerindeki tüm fiyat değerlerini 200 TL seviyesine çekerek girdi kümesi ağı sunulmuştur. Kırılmış olan bu veri seti ile kırılmamış veri setinin performans karşılaştırması çizelge 4.8’de gösterildiği şekilde gerçekleşmiştir.

Parametreler:

Girdi Türü	→	Geçmiş SGÖF verileri
Ağ topolojisi	→	11x11x1
Eğitim Algoritması	→	Levenberg-Marquardt
Aktivasyon Fonksiyonu	→	Hiperbolik tanjant
Eğitim/Test Kümesi Oranı	→	%75-%25

Çizelge 4.8 Yüksek fiyat değerlerini kırpmanın performansa etkisi

a) Kırılmamış SGÖF girdileri ile eğitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	14,64%	8,31%	9,92%	18,62%	7,19%	15,00%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	9,75%	11,54%	10,35%	10,87%	21,81%	12,54%

b) Kırılmış SGÖF girdileri ile eğitim

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	6,83%	5,48%	8,76%	17,65%	7,80%	13,99%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	<b>Genel</b>
<b>OMYH</b>	10,98%	12,13%	11,57%	10,88%	22,77%	11,71%

Yukarıdaki sonuçlar kıyaslandığında girdi kümesi içindeki aşırı yüksek sıçramaları kırpmak, ağın performansına katkıda bulunmaktadır. 11 haftanın toplamında OMYH % 12,5'ler seviyesinden, % 11,7'lere kadar inmiştir.

Kırpma işlemini yukarı bölümlerde Yamin vd'nin (2004) çalışmasında yer aldığı şekilde gerçekleştirildiğinde, yani (4.1)'de olduğu şekliyle

$$F_{yeni} = \begin{cases} F_{eski} & \text{eğer } F_{eski} \leq F_{üst} \\ F_{üst} + F_{üst} \ln\left(\frac{F_{eski}}{F_{üst}}\right) & \text{eğer } F_{eski} > F_{üst} \end{cases}$$


algoritması ile girdi veri önceden işlendiğinde yukarıdaki ağın performansı çizelge 4.9'da gösterildiği şekilde gerçekleşmektedir:

Çizelge 4.9 Kırpılmış SGÖF girdileri ile eğitim-Yamin vd. (2004)

	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta
<b>OMYH</b>	12,82%	7,17%	9,78%	17,49%	7,39%	14,18%

	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	Genel
<b>OMYH</b>	10,21%	11,96%	11,43%	11,02%	22,68%	12,35%



Şekil 4.11 Yüksek fiyat değerlerini kırpmanın performansa etkisi

Yamin vd (2004) önerisi ise kullanılan ağda kırılmamış veriye göre üstünlük sağlarken basit kırpmaya yani belirlenmiş olan eşiğe eşitlemeye nazaran daha iyi sonuçlar vermemiştir.

#### 4.5 ARIMA ile Modelleme

Yapay sinir ağları ile yapılan fiyat modellemesinin performans karşılaştırması için literatürde sıklıkla kullanılan bir yol olan ARIMA modellemesi ile fiyat tahmini yapılmıştır. Bu çalışmada Eviews istatistik programı kullanılmıştır. Yukarıda dördüncü bölümün ilk kısmında değinilen çalışmalarda, farklı açıklayıcı değişkenler için kurulan modellerin hata performansı üzerinde durulmuştur.

Contreras vd. (2003) ve literatürdeki diğer zaman serisi modellemeleri çalışmalarında Box-Jenkins metoduna göre analiz yapılarak modellemeye ulaşılmıştır. Modelleme temelde dört ana aşamadan oluşmaktadır. Bu aşamalar aşağıdaki şekilde sıralanabilir:

Aşama 1. Kurulan ilk model hipotez olarak formüle edilir.

Aşama 2. Gözlemlere dayanarak açıklayıcılar ile spesifik bir model kurulur

Aşama 3. Bu modelin parametreleri tahmin edilir.

Aşama 4. Belli ölçütlere göre modelin performansına bakılır, uygun ise model tahmin için kabul görmüş olur. Yanlış ise Aşama 2'ye dönülür.

SGÖF verileri üzerinden uygulanan bu modelde öncelikle ilk aşama olarak ARIMA modeli kurulmasına karar verilmiş ve ARIMA açıklayıcılarının fiyatı doğru tahmin edeceği varsayılmıştır:

$$f_t = c + \underbrace{\beta_1 f_{t-1} + \beta_2 f_{t-2} + \dots}_{\text{Otoregresif Model (AR)}} + \underbrace{\varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots}_{\text{Hareketli Ortalama Modeli (MA)}} \quad (4.19)$$

$f_t$  tahmin edilecek fiyatı (ilgili gün ve saat için),  $f_{t-d}$ ,  $d$  kadar farkı alınmış gözlemlenmiş fiyat değerlerini,  $\beta_t$ 'ler bu değerlerin katsayılarını,  $\varepsilon_t$  hata değerlerini,  $\theta_t$ 'ler ise bu hata değerlerinin katsayılarını göstermektedir.

Doğru bir modelleme için zaman serisi verilerinin durağan olup olmadığının kontrol edilmesi gerekmektedir. Bunun için kullanılan zaman serisi için birim kök testi (unit root test) yapılması sıklıkla kullanılan bir yöntemdir. Modelleme için kullanılacak olan Dickey-Fueller birim kök testi sonuçları şekil 4.12'de gösterildiği gibidir:


Augmented Dickey-Fuller Unit Root Test on SGOF		
Null Hypothesis: SGOF has a unit root		
Exogenous: Constant		
Lag Length: 30 (Automatic - based on SIC, maxlag=33)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.536706	0.0000
Test critical values:		
1% level	-3.431311	
5% level	-2.861850	
10% level	-2.566977	

\*MacKinnon (1996) one-sided p-values.

Şekil 4.12 Örnek birim kök testi

Bu teste göre %99 güven aralığında birim kökün varlığı reddedilebilmekte, bu durum da serinin durağan olduğu için bir bilgi vermektedir. Sonuç olarak da seri için fark alınmasına gerek olmadığı ortaya çıkmaktadır.

Serinin hangi açıklayıcı değişkenlere sahip olması gerektiğine karar verebilmek için de serinin özilinti ve kısmi özilinti grafiklerine bakmak yeterli olacaktır. SGÖF serisinin 36 saatlik gecikmeye kadar özilinti ve kısmi özilinti fonksiyonları Şekil 4.13'teki gibidir:



Şekil 4.13 Otokorelasyon ve kısmi otokorelasyon fonksiyonları

Yukarıda görüldüğü üzere özilinti fonksiyonunun geometrik olarak azalırken, kısmi özilinti birinci gecikmede yüksek değer alıp sönümleniyorsa, serinin AR(p) serisi olduğu sonucu ortaya çıkmaktadır. Bununla birlikte fiyat tahminini daha etkin kılabilmek açısından yapay sinir ağları ile tahmin kısmında kullanılan girdi kümesine benzer açıklayıcı değişkenler kullanılabilir. Literatürde de açıklayıcı değişken olarak  $f_{t-2}$ ,  $f_{t-3}$ ,  $f_{t-24}$ ,  $f_{t-48}$ ,  $f_{t-72}$ ,  $f_{t-168}$ ,  $f_{t-336}$ ,  $f_{t-504}$  gibi farklı fiyat gecikmeleri de kullanılmaktadır. Bu çalışmada kullanılan modelde hareketli ortalama kullanılmayarak

sadece otoregresif model kurulmuş ve açıklayıcı değişkenler bu şekilde değerlendirilmiştir.

Literatürde Aşama 3 olarak kurulan nihai model için bu sayılan fiyat gecikmelerinin kullanıldığı çalışmalar olagelmıştır. Bununla birlikte bu çalışmalarda kurulan modellerin açıklama gücü üzerinde durulmasına rağmen modelin tahmin için uygulanabilir olup olmadığı sorgulanmamıştır. Zaman serisinin birinci gecikmesi uygulamada kullanılabilir değildir, çünkü gerçek hayatta tahmin edilen fiyat bilgisinin bir önceki saatine erişme imkanı bulunmamakta, 24 saatlik bir gecikmeli seri tüm saat dilimleri için ancak kullanılabilir. Diğer bir deyişle belirli bir gün için tahmin yapılmak istendiği zaman, tahmin edilecek saate en yakın olarak elde sadece ilgili günden bir önceki günün verileri bulunmaktadır. Bu kısıt eşliğinde şu şekilde bir model kurulabilir:

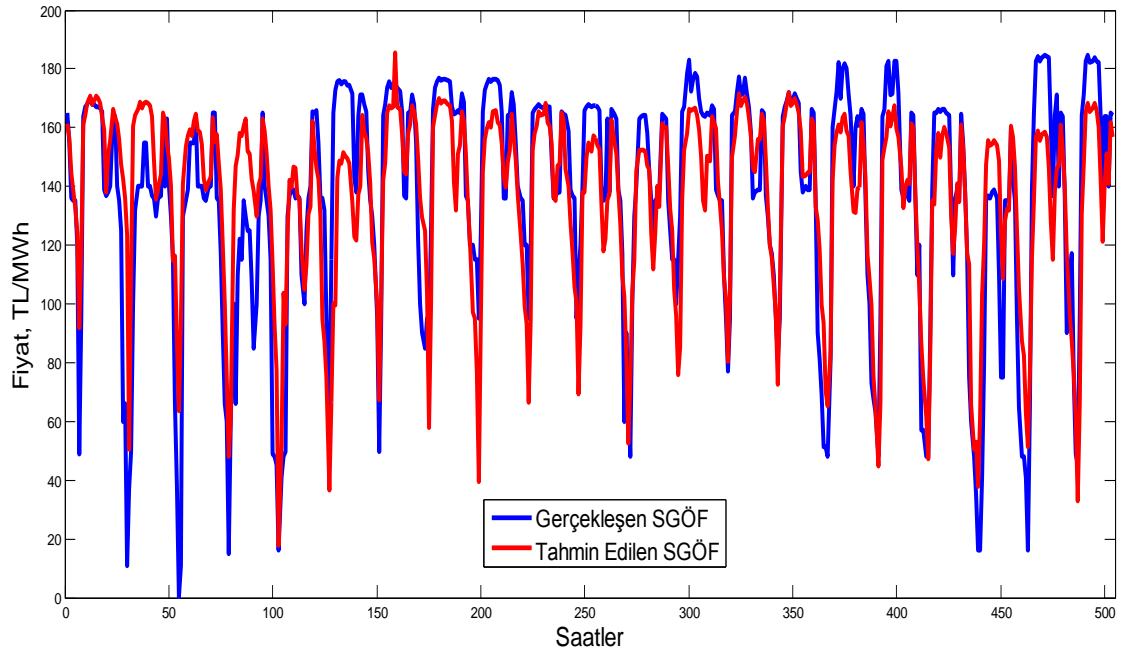
$$\hat{f}_t = c + \beta_1 \hat{f}_{t-24} + \beta_2 \hat{f}_{t-48} + \beta_3 \hat{f}_{t-168} + \beta_4 \hat{f}_{t-336} \quad (4.20)$$

Bu modele göre çizelge 4.10'daki katsayılar ortaya çıkmıştır:

Çizelge 4.10 Model katsayıları

c	-7,8145
$\beta_1$	0,3301
$\beta_2$	0,1673
$\beta_3$	0,2451
$\beta_4$	0,2779

Katsayıların hepsi 1'den küçük ve toplamaları 1'e yaklaşmakta, güven aralıkları % 85'ten fazla veya eşittir.  $R^2$  % 75 civarında ve açıklayıcı olarak kabul edilebilecek bir seviyededir. Bu modele göre; gerçekleşen ve tahmin edilen fiyat değerlerini gösteren örnek üç haftalık grafik aşağıdaki gibi gerçekleşmiştir:



Şekil 4.14 ARIMA ile tahmin edilen SGÖF ile gerçekleşen SGÖF

Otoregresif modelin tahmin gücüne OMYH yönünden bakıldığında yukarıda grafikte gösterilen haftalarda şu sonuçlar ortaya çıkmaktadır.

Çizelge 4.11 Üç hafta için OMYH'ler

Hafta 1( 09-15 Ekim 2010)	% 13,78
Hafta 2( 16-22 Ekim 2010)	% 12,49
Hafta 3( 23-29 Ekim 2010)	% 20,54
<b>Üç haftalık ortalama</b>	<b>% 15,60</b>

Görüldüğü üzere aşırı uç değerler olduğunda (ani yükselmeler ve düşmeler) model başarılı sayılamayacak fakat makul sonuçlar vermektedir. Bununla birlikte Contreras vd. (2003), Conejo vd. (2005), Weron ve Misiorek (2005), Jakaša vd. (2011) gibi ARIMA üzerinden modelleme yapılan çalışmalarda 24'ten daha küçük gecikmeler kullanıldığı için daha başarılı sonuçlar ortaya çıkmaktadır. 24'ten küçük gecikmeler ile



$$f_i = c + \beta_1 f_{i-1} + \beta_2 f_{i-2} + \beta_3 f_{i-24} + \beta_4 f_{i-48} + \beta_5 f_{i-168} + \beta_6 f_{i-336} \quad (4.21)$$

gibi birinci ve ikinci gecikmeleri açıklayıcı değişken olarak kullanan bir model kurulduğunda aynı dönem için hata değerleri aşağıdaki tablodaki gibi olmaktadır.

Çizelge 4.12 Üç hafta için OMYH'ler (birinci ve ikinci gecikme ile)

Hafta 1( 09-15 Ekim 2010)	% 10,56
Hafta 2( 16-22 Ekim 2010)	% 10,87
Hafta 3( 23-29 Ekim 2010)	% 14,33
<b>Üç haftalık ortalama</b>	<b>% 11,92</b>

Yukarıdaki tablodan da anlaşılacağı üzere daha başarılı sonuçlar ortaya çıkmaktadır. Ancak unutulmaması gereken ise, bu şekilde gerçekleştirilen modellemelerde tahmin yolunun uygulanabilirliği sorgulanmak yerine modelin verdiği hata performanslarını maksimize edilmeye çalışılmıştır.

## 5. SONUÇ ve TARTIŞMA

Elektrik piyasası içinde enerji ticareti, ikili anlaşmalar yoluyla yapılabilmekte bunun yanı sıra oluşturulan dengeleme ve uzlaştırma piyasası içinde yer alan havuz piyasası da ikincil bir ticaret hacmi oluşturmaktadır. Havuz piyasada oluşan referans enerji alış ve satış fiyatı olan SGÖF'ün tahmini hem piyasada rol alan enerji aktörleri (üretim, dağıtım, toptan satış şirketleri vs. ) için hem de sistem işletmecisi olan PMUM ve MYTM için büyük bir öneme sahiptir.

Fiyat tahmini yöntemleri ele alındığında genel olarak zaman serisi (Hareketli Ortalama, Üstel Düzeltme, ARIMA, ARCH, GARCH ) metotlarının yanı sıra sebep-sonuç ilişkisine dayalı regresyon yaklaşımları üzerinde literatürde birçok çalışma bulunduğu görülmektedir. Hem zaman serisi analizi hem de sebep-sonuç ilişkisi kurmada kullanılabilen yapay sinir ağları yaklaşımı son yıllarda sıklıkla kullanılır hale gelmiştir.

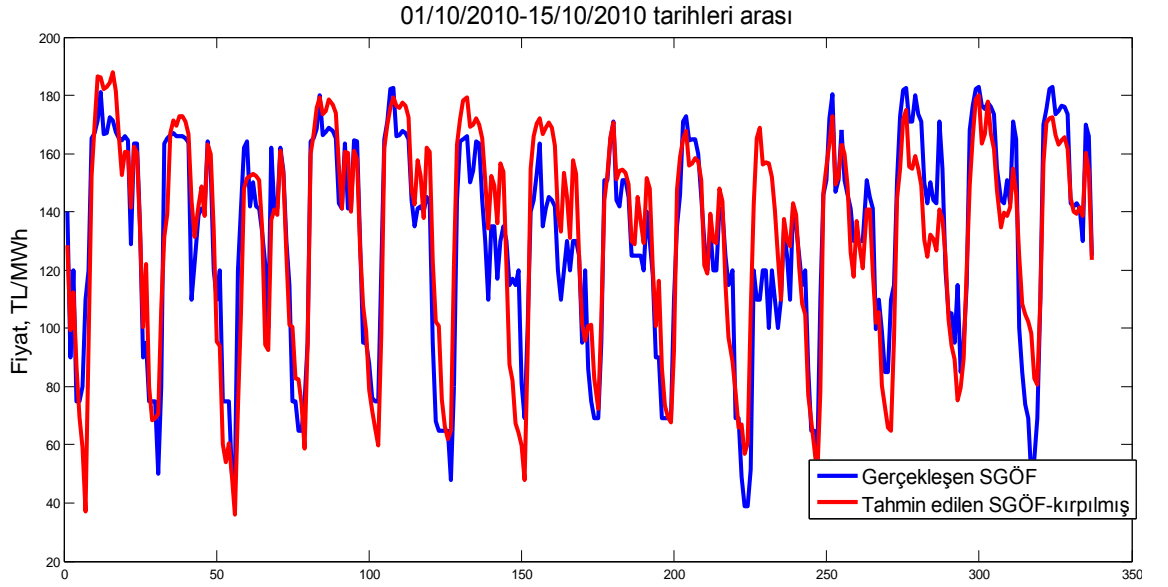
Bu çalışmada, öncelikle yapay sinir ağları ve özellikleri üzerinde durulmuş, daha sonra Türkiye elektrik piyasası kapsamında dengeleme ve uzlaştırma piyasasına değinilmiştir. SGÖF oluşumu aşama aşama gösterildikten sonra yapay sinir ağı ile modelleme üzerinde çalışılmıştır.

Model için ilk kullanılan veri kümesi PMUM'dan alınan ve 01/12/2009 ile 31/12/2010 tarihleri arasındaki gerçekleşmiş olan 396 günlük (9504 saatlik) SGÖF değerlerinden oluşmaktadır. Bu verinin yaklaşık olarak % 75'i eğitim kümesinde, % 25'i ise test kümesinde kullanılmıştır. Daha sonraki eğitim denemelerinde kullanılan ikili anlaşmalar, sıcaklık ortalamaları, tüketim tahminleri, gün tipi gibi veriler kullanılarak ağ eğitilmiştir.

Eğitim sürecinde farklı ağ topolojileri denenerek, farklı nöron ve katman sayısına sahip ağların hata performanslarına bakılmıştır. Ayrıca eğitim algoritması, aktivasyon fonksiyonu gibi parametreler değiştirilerek bunların hata oranlarını azaltıp azaltmadığına bakılmıştır. Tüm bunlara ilave olarak aşırı yüksek fiyat girdilerini kırpma yöntemi uygulanarak bu durumun ağ performansına etkileri incelenmiştir.

Edinilen bulgular neticesinde, tahmin yapan ađın hata oranını azaltan en önemli girdi, gemiř fiyat verileri olmuřtur. Gemiř fiyat verileri dıřında, ortalama sıcaklık verilerinin kullanılması; tüketime tahmini, ikili anlaşma miktarları ve gün tipi gibi verilerin kullanıldığı durumlara kıyasla daha iyi sonuçlar ortaya koymuřtur.

En başarılı eğitim metodu Levenberg-Marquardt algoritması olurken, aktivasyon fonksiyonunun türü tanjant hiperbolik ve logaritmik sigmoid seçildiğinde, benzer hata sonuçları ortaya çıkmıřtır.



Şekil 5.1 Yüksek fiyat değerlerini kırmanın tahmine etkisi

Girdi kümesindeki yüksek fiyatların kırılması hata oranlarını olumlu yönde etkilemiştir (Bkz. Şekil 5.1). Şekilde 01/10/2010 ile 21/10/2010 tarihleri arasında iki hafta 336 saatlik kırılmış girdi kümesi ile tahmini gösterilmektedir. OYMH oranı kırılmış veri ile genelde % 11’ler mertebelerine düşmüřtür.

Tüm konfigürasyonların performansı tek bir tablo olarak çizelge 5.1’de özetlenmiştir:

Çizelge 5.1 Yapay sinir ağları için sonuç tablosu

Gizli Katman Sayısı	Nöron Dizilişi	Aktivasyon Fonksiyonu	Öğrenme Algoritması	Girdi Türü	1. hafta	2. hafta	3. hafta	4. hafta	5. hafta	6. hafta	7. hafta	8. hafta	9. hafta	10. hafta	11. hafta	Genel
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF	14,64%	8,31%	9,92%	18,62%	7,19%	15,00%	9,75%	11,54%	10,35%	10,87%	21,81%	<b>12,54%</b>
1	11x22x1	Tansig	Levenberg-Marquardt	G. SGÖF	14,83%	8,27%	10,68%	18,37%	7,63%	14,52%	10,19%	11,98%	11,64%	10,86%	23,62%	<b>12,91%</b>
1	11x23x1	Tansig	Levenberg-Marquardt	G. SGÖF	18,44%	12,92%	15,63%	18,79%	7,58%	14,60%	12,12%	12,13%	12,48%	11,86%	25,41%	<b>14,59%</b>
1	11x4x1	Tansig	Levenberg-Marquardt	G. SGÖF	15,31%	8,49%	10,73%	16,80%	8,35%	14,08%	11,63%	11,62%	12,95%	11,00%	24,15%	<b>13,10%</b>
1	11x9x1	Tansig	Levenberg-Marquardt	G. SGÖF	16,11%	8,85%	11,52%	18,82%	8,30%	13,78%	11,67%	12,54%	11,63%	11,79%	24,44%	<b>13,47%</b>
2	11x11x1x1	Tansig	Levenberg-Marquardt	G. SGÖF	14,05%	7,77%	10,47%	19,02%	7,68%	14,08%	10,43%	11,68%	12,20%	10,88%	23,25%	<b>12,85%</b>
2	11x11x4x1	Tansig	Levenberg-Marquardt	G. SGÖF	14,56%	8,06%	11,47%	18,95%	8,52%	14,13%	10,39%	11,77%	12,05%	10,95%	23,15%	<b>13,05%</b>
2	11x11x20x1	Tansig	Levenberg-Marquardt	G. SGÖF	18,75%	8,16%	11,49%	19,25%	8,59%	13,95%	10,92%	11,82%	12,11%	11,09%	24,52%	<b>13,61%</b>
1	11x11x1	Purelin	Levenberg-Marquardt	G. SGÖF	12,76%	7,74%	11,41%	18,47%	9,18%	15,20%	11,35%	12,44%	11,09%	11,25%	22,27%	<b>13,04%</b>
1	11x11x1	Logsig	Levenberg-Marquardt	G. SGÖF	13,96%	7,42%	10,03%	19,32%	7,05%	13,90%	10,41%	11,69%	11,28%	10,56%	22,87%	<b>12,61%</b>
1	11x11x1	Tansig	Basit Eğitim Düşümü	G. SGÖF	33,20%	11,06%	13,89%	23,11%	15,27%	25,46%	21,28%	21,13%	26,27%	24,77%	30,29%	<b>22,29%</b>
1	11x11x1	Tansig	Ada. Öğr. Kats. ve Mom. Eğitim Düşümü	G. SGÖF	18,25%	9,03%	11,83%	18,47%	8,60%	16,40%	12,67%	12,63%	12,20%	12,68%	23,58%	<b>14,22%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF+ Tük. Tah	13,02%	8,07%	9,20%	14,76%	10,06%	12,54%	12,21%	12,94%	12,70%	12,40%	22,71%	<b>13,15%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF+ İk. Anl.	15,89%	9,22%	10,83%	17,36%	7,73%	13,58%	11,49%	11,40%	13,29%	11,23%	23,90%	<b>13,16%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF+ Al. Kap.	15,78%	7,72%	10,05%	18,70%	9,37%	14,94%	10,31%	11,87%	12,68%	11,70%	23,44%	<b>13,19%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF+ Sıcaklık	16,45%	8,89%	9,81%	18,91%	7,24%	16,16%	10,69%	11,25%	11,81%	11,04%	22,58%	<b>13,08%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	G. SGÖF+ Gün Tipi	13,87%	9,64%	11,94%	18,70%	7,49%	14,12%	10,38%	12,60%	11,66%	11,35%	24,03%	<b>13,25%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	Kırılmış G. SGÖF	6,83%	5,48%	8,76%	17,65%	7,80%	13,99%	10,98%	12,13%	11,57%	10,88%	22,77%	<b>11,71%</b>
1	11x11x1	Tansig	Levenberg-Marquardt	Kırılmış G. SGÖF (Yamin 2004)	12,82%	7,17%	9,78%	17,49%	7,39%	14,18%	10,21%	11,96%	11,43%	11,02%	22,68%	<b>12,35%</b>

Bu sonuçlarla başarılı olan ağ ve eğitim seçimini çizelge 5.2 ile özetlenebilir:

Çizelge 5.2 Başarılı olan ağ seçimi

Gizli Katman Sayısı	1
Gizli Katmandaki Nöron Sayısı	n
Aktivasyon fonksiyonu	Hiperbolik tanjant
Eğitim Metodu	Levenberg-Marquardt
Girdi kümesi	Kırılmış geçmiş SGÖF değerleri

Tüm bunlarla beraber, bulunan bu sonuçlar ideal olan ağ tasarımına erişildiği anlamına gelmemektedir. Modelleme kısmında da üzerinde durulduğu gibi yapay sinir ağları için kesin bir topoloji belirleme algoritması bulunmamaktadır.

Ayrıca literatürde sıklıkla kullanılan ARIMA yaklaşımı ile kurgulanan modelde ise daha başarısız hata performansı ortaya koyulmaktadır (Çizelge 5.3).

Çizelge 5.3 YSA ile ARIMA OMYH kıyaslaması

	Yapay Sinir Ağları	ARIMA
Hafta 1( 09-15 Ekim 2010)	% 20,84	% 13,78
Hafta 2( 16-22 Ekim 2010)	% 7,72	% 12,49
Hafta 3( 23-29 Ekim 2010)	% 13,90	% 20,54
<b>Üç haftalık ortalama</b>	<b>% 14,15</b>	<b>% 15,60</b>

Literatürde fiyat tahmini ile ilgili devam eden diğer çalışmalarda, fiyat sınıflandırma (Anbazhagan vd. 2012) ve fiyat sıçramalarını tahmin etme (Christensen vd. 2012) metotları sunulmuştur. Bu tez çalışmasında bulunan sonuçlar, Türkiye’deki elektrik dengeleme ve uzlaştırma piyasasında oluşan spot fiyatın yapay sinir ağları ile iyi bir tahmin yürütülebileceğini göstermektedir. Ancak sunulan yapay sinir ağı modelleri, fiyat sınıflandırma ve fiyat sıçramalarını tahmin etme yaklaşımlarını da içerecek biçimde geliştirilerek dengeleme ve uzlaştırma piyasasındaki fiyat tahmininde performansa etkileri araştırılabilir.

## KAYNAKLAR

- Aggarwal, S.K., Saini, L.M. and Kumar, A. 2009. Electricity price forecasting in deregulated markets: A review and evaluation. *Electrical Power and Energy Systems*, Vol. 31, pp. 13–22.
- Amjady, N. 2006. Day ahead price forecasting of electricity markets by a new fuzzy neural network. *IEEE Trans Power Syst*, Vol. 21(2), pp. 887–896.
- Amjady, N. and Keynia, F. 2008. Day ahead price forecasting of electricity markets by a mixed data model and hybrid forecast method. *Electrical Power and Energy Systems*, Vol. 30, pp. 533–546.
- Anbazhagan, S. and Kumarappan, N. 2012. Day-ahead deregulated electricity market price classification using neural network input featured by DCT. *Electrical Power and Energy Systems*, Vol. 37, pp. 103–109.
- Anonim. 2012. Web Sitesi. <http://www.sonsuz.us/?q=book/export/html/1574>, Erişim Tarihi: 08.08.2012.
- Arslan, S. 2008. Elektrik Enerjisi Sektöründe Serbestleşme, Yeniden Yapılanma, Özelleştirme Uygulamaları ve Dünya Örnekleri. Uzmanlık Tezi, Enerji Piyasası Düzenleme Kurumu, 172 s., Ankara.
- Bilimgut, İ. 2008. Elektrik Piyasasında Son Kaynak Tedariği. Uzmanlık Tezi, Enerji Piyasası Düzenleme Kurumu, 106 s., Ankara.
- Camadan, E. 2009. Türkiye Elektrik Piyasası Dengeleme ve Uzlaştırma Mekanizması: Karşılaştırmalı Analiz. Uzmanlık Tezi, Enerji Piyasası Düzenleme Kurumu, 173 s., Ankara.
- Catalão, J.P.S, Mariano, S.J.P.S, Mendes, V.M.F. and Ferreira L.A.F.M. 2007. Short-term electricity prices forecasting in a competitive market: A neural network approach. *Electric Power Systems Research*, Vol. 77, pp. 1297–1304.
- Christensen, T.M., Hurnb, A.S. and Lindsay, K.A. 2012. Forecasting spikes in electricity prices. *International Journal of Forecasting*, Vol. 28, pp. 400–411.
- Civalek, Ö. ve Calayır Y. 2007. İnce Dikdörtgen Plakların Titreşim Frekanslarının Yapay Sinir Ağları Yaklaşımı ile Tahmini. *İMO Teknik Dergi*, s. 4161–4176.
- Conejo, A.J., Plazas, M.A., Espinola, R. and Molina, A.B. 2005. Day-ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models. *IEEE Transactions on Power Systems*, Vol. 20 (2), pp. 1035–1042.

- Contreras, J., Espinola, R., Nogales, F.J. and Conejo, A.C. 2003. ARIMA Models to Predict Next-Day Electricity Prices. IEEE Transactions on Power Systems, Vol. 18(3), pp. 1014-1020.
- Çetin, N. S. 2006. Şebeke Bağlantısız Pm Generatörlü Rüzgar Türbünlerinin Ysa İle Sistem Optimizasyonu. Doktora Tezi (basılmamış), Ege Üniversitesi, 244 s., İzmir.
- Demuth, H. and Beale, M. 2002. Neural Network Toolbox User's Guide. The MathWorks, Inc., 840 p.
- Efe, M.Ö. ve Kaynak, O. 2000. Yapay sinir ağları ve uygulamaları. Boğaziçi Üniversitesi, 148s., İstanbul.
- Elektrik Piyasası Dengeleme ve Uzlaştırma Yönetmeliği (DUY) ,14/04/2009 tarihli ve 27200 sayılı Resmi Gazete.
- Engle, R.F. 1982. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. Econometrica, Vol. 50, pp. 987-1007.
- Gao, F., Cao, X. and Papalexopoulous, A. 2000. Forecasting power market clearing price and quantity using a neural network method. IEEE Power Eng Soc Summer Meet, Vol. 4, pp. 2183-2188.
- Garcia, R.C., Contreras, J., van Akkeren, M. and Garcia, J.B.C. 2005. A GARCH Forecasting Model to Predict Day-ahead Electricity Prices. IEEE Transactions on Power Systems , Vol. 20(2), pp. 867-874.
- Gooi, H.B., Teo, C.Y., Chin, L, Ang, S.Y. and Khor E.K. 1993. Adaptive short-term load forecasting using artificial neural networks. IEEE Region 10 Conference on. Vol. 2 , pp. 787-790.
- Grossberg, S. 1969. Embedding fields: A theory of learning with physiological implications, Journal of Mathematical Psychology, Vol. 6, pp. 209-239.
- Guirguis, H.S. and Felder, F.A. 2004. Further advances in forecasting day-ahead electricity prices using time series models. KIEE International Transactions on PE. Vol. 4-A(3), pp. 159-166.
- Gün Öncesi Planlamada Sistem Marjinal Fiyatının Belirlenmesi ile Sistem Satış ve Sistem Alış Talimatlarının Oluşmasına İlişkin Metodoloji, EPDK.
- Hagan, M. T., Demuth, H.B. and Beale, M.H. 1996. Neural Network Design, MA: PWS Publishing, 734 s., Boston, USA.
- Hamzaçebi, C. 2011. Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı. Ekin Basım Yayın Dağıtım, 133 s., Bursa.

- Haykin, S. 1999. *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 842 p., New Jersey, USA.
- Hong, Y.Y. and Lee, C.F. 2005. A neuro-fuzzy price forecasting approach in deregulated electricity markets. *Electric Power Syst Res*, Vol.73, pp. 151–157.
- Huisman, R. and de Jong, C. 2003. Option Pricing for Power Prices with Spikes. *Energy Power Risk Management*, Vol. 7.11, pp. 12–16.
- Huisman, R. and Mahieu, R. 2003. Regime Jumps in Electricity Prices, *Energy Economics*, Vol. 25, pp. 425–434.
- Jakaša, T., Andročec, I. and Sprčić, P. 2011. Electricity price forecasting – ARIMA model approach. 8th International Conference on the European Energy Market, 2011.
- Kaastra I. and Boyd M. 1996. Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, Vol. 10, pp. 215-236.
- Kim, C.I., In-Keun, Yu and Song, Y.H. 2002. Prediction of System Marginal Prices of Electricity Using Wavelet Transform Analysis. *Energy Convers Manage*, Vol. 43, pp. 1839-1851.
- Kölmek, F. 2009. *Serbest Elektrik Piyasalarında Kısıt Yönetimi*. Uzmanlık Tezi, Enerji Piyasası Düzenleme Kurumu, 160 s., Ankara.
- Mehrotra, K., Mohan C.K. and Ranka, S. 1996. *Elements of Artificial Neural Networks*. MIT Press, 344 p., Boston, USA.
- Mugele, Ch., Rachev, S.T. and Trück, S. 2005. Stable Modeling of Different European Power Markets. *Investment Management and Financial Innovations*, Vol. 2(3), pp. 65-85.
- Niimura, T., Ko, H.S. and Ozawa, K. 2002. A day-ahead electricity price prediction based on a fuzzy-neuro autoregressive model in a deregulated electricity market. *Proceedings of the 2002 international joint conference on neural networks*, Vol. 2, pp. 1362–1366.
- Niimura, T. 2006. *Forecasting Techniques for Deregulated Electricity Market Prices-Extended Survey*. *Proceedings of Power Engineering Society General Meeting*, 2006.
- Nogales, F.J., Contreras, J., Conejo, A.J. and Espinola, R. 2002. Forecasting Next-Day Electricity Prices by Time Series Models. *IEEE Transactions on Power Systems*, Vol.17 (2), pp. 342-348.



- Öztemel, E. 2006. Yapay Sinir Ağları. Papatya Yayıncılık, 2. baskı, 232 s., İstanbul.
- Pao, H.T. 2007. Forecasting electricity market pricing using artificial neural Networks. Energy Conversion and Management, Vol. 48, pp. 907–912.
- Peng, T.M., Hubele, N.F. and Karady, G.G. 1990. Conceptual approach to the application of neural network for short-term load forecasting. Circuits and Systems, IEEE International Symposium on, Vol.4, pp. 2942 - 2945.
- Rodriguez, C.P. and Anders, G.J. 2004. Energy price forecasting in the Ontario competitive power system market. IEEE Trans Power Syst, Vol. 19 (3), pp. 366–374.
- Schmutz, A. and Elkuch, P. 2004. Electricity price forecasting: Application and experience in the European power markets. Proceedings of the 6th IAEE European Conference, Zurich.
- Srinivasan, D., Liew, A.C. and Chen J.S.P. 1991. Short term forecasting using neural network approach. Neural Networks to Power Systems. Proceedings of the First International Forum on Applications, pp. 12-16.
- Stathakis, D. 2008. How many hidden layers and nodes?. International Journal of Remote Sensing. Vol. 30 (8), pp. 2133-2147.
- Sureerattanan, S. Phien, H.N., Sureerattanan, N. and Mastorakis, N.E. 2006. The Optimal Multi-layer Structure of Backpropagation Networks. Proceedings of the 7th WSEAS International Conference on Neural Networks, Cavtat, Croatia, pp. 108-113.
- Swider, D.J. and Weber, C. 2006. Extended ARMA Models for Estimating Price Developments on Day-Ahead Electricity Markets. Electric Power Systems Research, Vol. 77(5/6), pp. 583-593.
- Szkuta, B.R., Sanabria, L.A. and Dillon, T.S. 1999. Electricity price short-term forecasting using artificial neural networks. IEEE Trans Power Syst, Vol. 14(3), pp. 851–857.
- Şener, A.C. ve Uluca B. 2009 Türkiye Elektrik Piyasaları ve Jeotermal Enerjinin Konumu. IX. Ulusal Tesisat Mühendisliği Kongresi ve Sergisi, Jeotermal Enerji Semineri, İzmir.
- Torro, H. 2007. Forecasting Weekly Electricity Prices at Nord Pool, Nota di Lavoro, p. 88.
- Turgut, E. ve Selçuk K. 2009. Elektrik Enerjisi Üretimi ve Dağıtımı. Detay Yayıncılık, 432 s., Ankara.

- Wang, A. and Ramsay, B. 1997. Prediction of system marginal price in the UK Power pool using neural networks”, Proceedings of IEEE International Conference on Neural Networks, Vol. 4, pp. 2116-2120.
- Wang, A. and Ramsay, B. 1998. A neural network based estimator for electricity spot pricing with particular reference to weekend and public holidays. Neurocomputing, Vol. 23, pp. 47–57.
- Weron, R. 2006. Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach, Wiley, 178 p., Chichester, İngiltere.
- Weron, R. and Misiorek, A. 2005. Forecasting Spot Electricity Prices with Time Series Models. Proceedings of International Conference on the European Electricity Market EEM, pp. 133-141, Lodz, Poland.
- Weron, R. and Misiorek, A. 2008. Forecasting Spot Electricity Prices: A Comparison of Parametric and Semiparametric Time Series Models. International Journal of Forecasting, Vol. 24, pp. 744-763.
- Wilamowski, B. M. 2011. Neural Networks Learning. Industrial Electronics Handbook Vol. 5, pp. 11-1 to 11-18, USA.
- Wu, L. and Shahidehpour, M. 2010. A Hybrid Model for Day-Ahead Price Forecasting. IEEE transactions on power systems, Vol. 25 (3), pp. 1519-1530.
- Yamin, H.Y., Shahidehpour, S.M. and Li, Z. 2004. Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets. Electrical Power Energy Syst, Vol. 26, pp. 571–581.
- Yu, H. and Wilamowski, B.M. 2011. Levenberg–Marquardt Training. Industrial Electronics Handbook, vol. 5 – Intelligent Systems, 2nd Edition, chapter 12, pp. 12-1 to 12-15, CRC Press.
- Zhang, L., Luh, P.B. and Kasivisvanathan, K. 2003. Energy clearing price prediction and confidence interval estimation with cascaded neural networks. IEEE Trans Power Syst , Vol. 18(1), pp. 99–105.
- Zhou, M., Yan, Z., Ni, Y. and Li, G. 2004. An ARIMA approach to forecasting electricity price with accuracy improvement by predicted errors. Proceedings of the IEEE Power Engineering Society General Meeting, pp. 233–238.
- Zhou, M., Yan, Z., Ni, Y., Li, G. and Nie, Y. 2006. Electricity price forecasting with confidence-interval estimation through an extended ARIMA approach, IEE Proceedings – Generation, Transmission and Distribution , Vol. 153(2), pp. 233–238.

## EK- NEWTON VE LEVENBERG-MARQUARDT METODLARI

### Newton Metodu

Basit eğim düşümü metoduyla bir  $A_k$  ağırlığı  $\alpha$  gibi sabit bir öğrenme katsayısı ile,

$$A_{k+1} = A_k - \alpha g_k \quad (\text{E.1})$$

şeklinde güncellenmektedir. Buradaki  $g_k$  hatanın gradyanını (gradient) göstermektedir.  $g_k$   $E$  hatasının ağırlıklara göre kısmi türevinden oluşmaktadır. Yani:

$$g_k = \frac{\partial E}{\partial A_k} \quad (\text{E.2})$$

tüm gradyan vektörü ise;

$$\mathbf{g} = \frac{\partial E(x, w)}{\partial A} = \left[ \frac{\partial E}{\partial A_1} \quad \frac{\partial E}{\partial A_2} \quad \frac{\partial E}{\partial A_3} \quad \dots \quad \frac{\partial E}{\partial A_N} \right]^T \quad (\text{E.3})$$

olarak gösterilebilir. Newton yaklaşımında gradyan vektörünün elemanları, ağırlıkların birer fonksiyonu şeklinde farz edilmektedir:

$$\begin{cases} g_1 = F_1(A_1, A_2, \dots, A_N) \\ g_2 = F_2(A_1, A_2, \dots, A_N) \\ \vdots \\ g_N = F_N(A_1, A_2, \dots, A_N) \end{cases} \quad (\text{E.4})$$

Bu elemanların Taylor serisinin birinci dereceden açılımı,

$$\begin{cases} g_1 \approx g_{1,0} + \frac{\partial g_1}{\partial A_1} \Delta A_1 + \frac{\partial g_1}{\partial A_2} \Delta A_2 + \dots + \frac{\partial g_1}{\partial A_N} \Delta A_N \\ g_2 \approx g_{2,0} + \frac{\partial g_2}{\partial A_1} \Delta A_1 + \frac{\partial g_2}{\partial A_2} \Delta A_2 + \dots + \frac{\partial g_2}{\partial A_N} \Delta A_N \\ \vdots \\ g_N \approx g_{N,0} + \frac{\partial g_N}{\partial A_1} \Delta A_1 + \frac{\partial g_N}{\partial A_2} \Delta A_2 + \dots + \frac{\partial g_N}{\partial A_N} \Delta A_N \end{cases} \quad (\text{E.5})$$

şeklinde yazılabilir. (E.2) tanımı ile birleştirilirse;

$$\frac{\partial g_i}{\partial A_j} = \frac{\partial \left( \frac{\partial E}{\partial A_i} \right)}{\partial A_j} = \frac{\partial^2 E}{\partial A_i \partial A_j} \quad (\text{E.6})$$

elde edilir ve (E.5)'e eklenirse;

$$\begin{cases} g_1 \approx g_{1,0} + \frac{\partial^2 E}{\partial A_1^2} \Delta A_1 + \frac{\partial^2 E}{\partial A_1 \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_1 \partial A_N} \Delta A_N \\ g_2 \approx g_{2,0} + \frac{\partial^2 E}{\partial A_2 \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_2^2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_2 \partial A_N} \Delta A_N \\ \vdots \\ g_N \approx g_{N,0} + \frac{\partial^2 E}{\partial A_N \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_N \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_N^2} \Delta A_N \end{cases} \quad (\text{E.7})$$

ulaşılması olur. Hatanın minimum olması için gradyan vektörünün her bir elemanı 0'a eşitlenmelidir:

$$\begin{cases} 0 \approx g_{1,0} + \frac{\partial^2 E}{\partial A_1^2} \Delta A_1 + \frac{\partial^2 E}{\partial A_1 \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_1 \partial A_N} \Delta A_N \\ 0 \approx g_{2,0} + \frac{\partial^2 E}{\partial A_2 \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_2^2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_2 \partial A_N} \Delta A_N \\ \vdots \\ 0 \approx g_{N,0} + \frac{\partial^2 E}{\partial A_N \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_N \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_N^2} \Delta A_N \end{cases} \quad (\text{E.8})$$

Yine (E.2) burada gradyan vektörünün her bir elemanı için yerine konulursa,

$$\begin{cases} -\frac{\partial E}{\partial A_1} = g_{1,0} \approx \frac{\partial^2 E}{\partial A_1^2} \Delta A_1 + \frac{\partial^2 E}{\partial A_1 \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_1 \partial A_N} \Delta A_N \\ -\frac{\partial E}{\partial A_2} = g_{2,0} \approx \frac{\partial^2 E}{\partial A_2 \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_2^2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_2 \partial A_N} \Delta A_N \\ \vdots \\ -\frac{\partial E}{\partial A_N} = g_{N,0} \approx \frac{\partial^2 E}{\partial A_N \partial A_1} \Delta A_1 + \frac{\partial^2 E}{\partial A_N \partial A_2} \Delta A_2 + \dots + \frac{\partial^2 E}{\partial A_N^2} \Delta A_N \end{cases} \quad (\text{E.9})$$

elde edilmiş olur. (E.9) denkleminin matris hali şu şekildedir:

$$\begin{bmatrix} -g_1 \\ -g_2 \\ \vdots \\ -g_N \end{bmatrix} = \begin{bmatrix} -\frac{\partial E}{\partial A_1} \\ -\frac{\partial E}{\partial A_2} \\ \vdots \\ -\frac{\partial E}{\partial A_N} \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 E}{\partial A_1^2} & \frac{\partial^2 E}{\partial A_1 \partial A_2} & \dots & \frac{\partial^2 E}{\partial A_1 \partial A_N} \\ \frac{\partial^2 E}{\partial A_2 \partial A_1} & \frac{\partial^2 E}{\partial A_2^2} & \dots & \frac{\partial^2 E}{\partial A_2 \partial A_N} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial^2 E}{\partial A_N \partial A_1} & \frac{\partial^2 E}{\partial A_N \partial A_2} & \dots & \frac{\partial^2 E}{\partial A_N^2} \end{bmatrix} \times \begin{bmatrix} \Delta A_1 \\ \Delta A_2 \\ \Delta A_3 \\ \vdots \\ \Delta A_N \end{bmatrix} \quad (\text{E.10})$$

Buradaki kare matris, Hessian matristir:

$$\mathbf{H} = \begin{vmatrix} \frac{\partial^2 E}{\partial A_1^2} & \frac{\partial^2 E}{\partial A_1 \partial A_2} & \cdots & \frac{\partial^2 E}{\partial A_1 \partial A_N} \\ \frac{\partial^2 E}{\partial A_2 \partial A_1} & \frac{\partial^2 E}{\partial A_2^2} & \cdots & \frac{\partial^2 E}{\partial A_2 \partial A_N} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial^2 E}{\partial A_N \partial A_1} & \frac{\partial^2 E}{\partial A_N \partial A_2} & \cdots & \frac{\partial^2 E}{\partial A_N^2} \end{vmatrix} \quad (\text{E.11})$$

(E.3) ve (E.10), (E.11) ile birleştirildiğinde;

$$-g = \mathbf{H}\Delta A \quad (\text{E.12})$$

Buradan;

$$\Delta A = -\mathbf{H}^{-1} g \quad (\text{E.13})$$

olur. Newton metodu için ağırlık güncelleme böylece;

$$A_{k+1} = A_k - \mathbf{H}^{-1} g_k \quad (\text{E.14})$$

şeklinde yazılabilir.

### **Gauss-Newton Metodu**

Hessian matrisini hesaplamak için gerekli olan ikinci dereceden türev alma işi çok verili ağırlarda karmaşık bir hal alabilmektedir. Hesaplama sürecini kolaylaştırmak için Jakobiyen matrisi şu şekilde oluşturulmuştur:

$$\mathbf{J} = \begin{pmatrix} \frac{\partial e_{1,1}}{\partial A_1} & \frac{\partial e_{1,1}}{\partial A_2} & \dots & \frac{\partial e_{1,1}}{\partial A_N} \\ \frac{\partial e_{1,2}}{\partial A_1} & \frac{\partial e_{1,2}}{\partial A_2} & \dots & \frac{\partial e_{1,2}}{\partial A_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{1,M}}{\partial A_1} & \frac{\partial e_{1,M}}{\partial A_2} & \dots & \frac{\partial e_{1,M}}{\partial A_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,1}}{\partial A_1} & \frac{\partial e_{P,1}}{\partial A_2} & \dots & \frac{\partial e_{P,1}}{\partial A_N} \\ \frac{\partial e_{P,2}}{\partial A_1} & \frac{\partial e_{P,2}}{\partial A_2} & \dots & \frac{\partial e_{P,2}}{\partial A_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{P,M}}{\partial A_1} & \frac{\partial e_{P,M}}{\partial A_2} & \dots & \frac{\partial e_{P,M}}{\partial A_N} \end{pmatrix} \quad (\text{E.15})$$

Gradyan vektörü şu şekilde de gösterilebilir.

$$g_i = \frac{\partial E}{\partial A_i} = \frac{\partial \left( \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \right)}{\partial A_i} = \sum_{p=1}^P \sum_{m=1}^M \left( \frac{\partial e_{p,m}}{\partial A_i} e_{p,m} \right) \quad (\text{E.16})$$

(E.16) ile Jakobiyen matrisi beraber değerlendirildiğinde,

$$\mathbf{g} = \mathbf{J}\mathbf{e} \quad (\text{E.17})$$

olduğu görülmektedir. Burada hata vektörü  $\mathbf{e}$ ,

$$\mathbf{e} = \begin{pmatrix} e_{1,1} \\ e_{1,2} \\ \vdots \\ e_{1,M} \\ e_{P,1} \\ \vdots \\ e_{P,M} \end{pmatrix} \quad (\text{E.18})$$

şeklinde gösterilir. Yukarıda hesaplanan Hessian matrisin her bir elemanı  $h_{i,j}$  şu denklemlerle gösterilebilir:

$$h_{i,j} = \frac{\partial^2 E}{\partial A_i \partial A_j} = \frac{\partial^2 \left( \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \right)}{\partial A_i \partial A_j} = \sum_{p=1}^P \sum_{m=1}^M \left( \frac{\partial e_{p,m}}{\partial A_i} \frac{\partial e_{p,m}}{\partial A_j} \right) + S_{i,j} \quad (\text{E.19})$$

Burada  $S_{i,j}$ ;

$$S_{i,j} = \sum_{p=1}^P \sum_{m=1}^M \left( \frac{\partial^2 e_{p,m}}{\partial A_i \partial A_j} e_{p,m} \right) \quad (\text{E.20})$$

kadardır. Newton metoduna göre  $S_{i,j}$ , sifira yakın olup sifir kabul edilebilir. Dolayısıyla Hessian matrisi ile Jakobiyen ilişkisi,

$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} \quad (\text{E.21})$$

olarak yazılabilir. (E.14), (E.17) ve (E.21) birleştirildiğinde yeni ağırlık güncelleme,

$$\mathbf{A}_{k+1} = \mathbf{A}_k - (\mathbf{J}_k^T \mathbf{J}_k)^{-1} \mathbf{J}_k \mathbf{e}_k \quad (\text{E.22})$$

olarak gösterilebilir.



## Levenberg-Marquardt Algoritması

İkinci dereceden türev almaya gerek bırakmayan Gauss-Newton algoritması,  $\mathbf{J}^T\mathbf{J}$  tersi alınamayan bir matris olduğu zaman yakınsama problemine düşer. Bunu engellemek için Levenberg-Marquardt algoritması Hessian matrisi için yeni bir yaklaşım sergiler:

$$\mathbf{H} \approx \mathbf{J}^T\mathbf{J} + \mu\mathbf{I} \quad (\text{E.23})$$

Burada  $\mathbf{I}$  birim matrisi,  $\mu$  ise birleştirme katsayısını gösterir. Bu yaklaşık Hessian matrisinin diyagonalindeki terimlerin sıfırdan farklı olması toplama işlemi ile garanti altına alınarak, bu matrisin tersinin alınması garanti altına alınmıştır. (E.22) ve (E.23) birleştirildiğinde Levenberg-Marquardt algoritmasına göre ağırlık güncelleme;

$$A_{k+1} = A_k - (\mathbf{J}_k^T\mathbf{J}_k + \mu\mathbf{I})^{-1}\mathbf{J}_k e_k \quad (\text{E.24})$$

şeklinde yazılabilecektir. Fark edilebileceği üzere  $\mu$  0'a yaklaştığında algoritma Gauss-Newton algoritması gibi, çok büyüdüğünde (Hessian matrisinin önemi düştüğünde) eğim düşümü algoritması gibi davranacaktır.

## ÖZGEÇMİŞ

Adı Soyadı : Mehmet Ali KÖLMEK  
Doğum Yeri : SİVAS  
Doğum Tarihi : 05/06/1985  
Medeni Hali : Evli  
Yabancı Dili : İngilizce

### **Eğitim Durumu**

Lise : Özel Yavuz Sultan Fen Lisesi (1999 -2002 )  
Lisans : Bilkent Üniversitesi, Elektrik-Elektronik Mühendisliği (2002-2007)  
Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim Dalı ( Eylül 2009-Ocak 2013)

### **Çalıştığı Kurum**

Enerji Piyasası Düzenleme Kurumu ( 2010 -... )