

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

**DİFERANSİYEL POLİNOM SİNİR AĞI
TEKNİĞİ İLE ELEKTRİK TÜKETİM TAHMİNİ**

YÜKSEK LİSANS TEZİ

Ecem BAYAR

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

**Tez Danışmanı : Dr. Öğr. Üyesi Alparslan Serhat
DEMİR**

Ocak 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DİFERANSİYEL POLİNOM SİNİR AĞI TEKNIĞI İLE ELEKTRİK TÜKETİM TAHMİNİ

YÜKSEK LİSANS TEZİ

Ecem BAYAR

Enstitü Anabilim Dalı

ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 10/01/2019 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Dr. Öğretim Üyesi
Berrin DENİZHAN
Jüri Başkanı

Dr. Öğretim Üyesi
Alparslan Serhat DEMİR
Üye

Dr. Öğretim Üyesi
Ömer Hulusi DEDE
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Ecem BAYAR

10.01.2019

TEŞEKKÜR

Yüksek lisans eğitimim boyunca ve bu çalışmada değerli bilgi ve görüşleri ile katkıda bulunan, çalışmanın her aşamasında desteğini esirgemeyen değerli danışman hocam Dr. Öğr. Üyesi Alparslan Serhat DEMİR'e sonsuz teşekkürlerimi sunarım. Ayrıca çalışma için desteklerinden Ladislav Zjavka'ya, son olarak da tüm hayatım boyunca sonsuz sevgi ve desteklerini esirgemeyen aileme teşekkürlerimi bir borç bilirim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ.....	vii
ÖZET.....	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KONUNUN BİLİMSEL VE TEKNOLOJİK UYGULAMADAKİ YERİ	3
2.1. Türkiye’de Elektrik Enerjisi	3
2.2. Elektrik Talebi Tahmin Yöntemleri	5
2.3. Elektrik Talebi Tahminine Yönelik Yapılan Çalışmalar.....	8
BÖLÜM 3.	
MATERYAL VE YÖNTEM	15
3.1. Elektrik Tüketim Tahmini Uygulamasında Kullanılan Yöntemler	15
3.1.1. Diferansiyel polinom sinir ağı.....	15
3.1.1.1. Diferansiyel polinom sinir ağı genel mimarisi	16
3.1.1.2. Diferansiyel polinom sinir ağı yapısı.....	19
3.1.2. Yapay sinir ağı	25
3.1.2.1. Yapay sinir ağlarının yapısı	27
3.1.2.2. Yapay sinir ağlarının sınıflandırılması	28
3.1.2.3. Yapay sinir ağlarının öğrenme kuralları.....	30
3.1.2.4. Geri yayılım algoritması ve çok katmanlı algılayıcılar	31

3.1.3. Biyolojik Sinir Hücresi ile D-PNN ve YSA yapısına genel bakış	32
3.1.4. Çalışmada kullanılan istatistiksel değerlendirme yöntemleri...	34
3.2. Elektrik Tüketim Tahmini Uygulaması.....	35
3.2.1. Uygulamada kullanılan veriler	36
3.2.2. Diferansiyel polinom sinir ağı ile tahmin uygulaması	39
3.2.3. Yapay sinir ağı ile tahmin uygulaması	41
BÖLÜM 4.	
BULGULAR VE TARTIŞMA	43
4.1. Diferansiyel Polinom Sinir Ağı ile Elektrik Tüketim Tahmini	43
4.2. Yapay Sinir Ağı ile Elektrik Tüketim Tahmini.....	45
BÖLÜM 5.	
SONUÇLAR VE ÖNERİLER	47
KAYNAKLAR	50
ÖZGEÇMİŞ	54

SİMGELER VE KISALTMALAR LİSTESİ

ANFIS	: Adaptif ağ tabanlı bulanık çıkarım sistemi
AR	: Otoregresif
ARIMA	: Bütünleşik otoregresif hareketli ortalama
ARMA	: Otoregresif hareketli ortalama
CT	: Birleşik terimler
ÇKA	: Çok katmanlı ağ
DE	: Diferansiyel denklem
D-PNN	: Diferansiyel polinom sinir ağı
DSİ	: Devlet Su İşleri
EİEİ	: Elektrik İşleri İdaresi
EÜAŞ	: Elektrik Üretim Anonim Şirketi
FF-BP-ANN	: İleri beslemeli çok katmanlı algılama
GD	: Gradyan dereceli alçalma
GDMH	: Grup veri işleme yöntemi
GSD	: Gradyan en dikine iniş
GSYH	: Gayri safi yurtiçi hasıla
GWH	: Gigawatt
IPSO	: Geliştirilmiş parçacık sürü optimizasyonu
LR	: Doğrusal regresyon
LS-SVM	: En küçük kareler destek vektör makineleri
MA	: Hareketli ortalama
MAE	: Ortalama kare hatası
MAPE	: Ortalama mutlak yüzde hata
MPE	: Mean Percentage Error
MTA	: Maden Tetkik ve Arama
NLR	: Doğrusal olmayan regresyon

PAR	: Periyodik otoregresif
PSO	: Parçacık sürü optimizasyonu
RMSE	: Hata karelerinin ortalamasının karekökü
ROC	: Alıcı davranış karakteristiği
SEGARCH	: Genelleştirilmiş mevsimsel üstel varyasyon
SFL	: Karıştırılmış kurbağa sıçrama
TEAŞ	: Türkiye Elektrik Üretim İletim Anonim Şirketi
TEDAŞ	: Türkiye Elektirik Dağıtım Anonim Şirketi
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
TEK	: Türkiye Elektrik Kurumu
TETAŞ	: Türkiye Elektrik Ticaret ve Taahhüt Anonim Şirketi
TUIK	: Türkiye İstatistik Kurumu
YSA	: Yapay sinir ağları
WARCH	: Genelleştirilmiş mevsimsel üstel varyasyon hibrit modeli
WEFuNN	: Ağırlıklı gelişen bulanık sinir ağı

ŞEKİLLER LİSTESİ

Şekil 2.1. 2015 yılı Türkiye elektrik enerjisi üretiminin kaynaklara göre dağılımı	4
Şekil 3.1. Nöronlardan oluşan blok yani ikame türevi terimleri	16
Şekil 3.2. Geriye doğru bağlantıları ile bileşik fonksiyon oluşumu.....	21
Şekil 3.3. N sayıda bağımsız değişkenli çok katmanlı D-PNN.....	22
Şekil 3.4. D-PNN resgele paralel kademeli bitirme işlemleri ve seçim ayarı.....	24
Şekil 3.5. Yapay nöronun temel bileşenleri	26
Şekil 3.6. Yapay sinir ağları temel yapısı	28
Şekil 3.7. Biyolojik sinir hücresi.....	33
Şekil 3.8. Verilerin programa transferini gerçekleştiren .txt uzantılı dosya	40
Şekil 3.9. Paket programa işlenmek üzere hazırlanan eğitim girdi verileri	41
Şekil 3.10. Uygulama model yapısı	42
Şekil 4.1. Oluşan ağın yapısı.....	43
Şekil 4.2. Optimum test sonuçları	44
Şekil 4.3. Test gerçek değerleri ve D-PNN test değerlerinin kıyaslanması	44
Şekil 4.4. Test gerçek değerleri ve D-PNN test değerlerinin dağılım grafiği.....	45
Şekil 4.5. Gerçek test seti ve YSA test değerlerinin kıyaslanması	45
Şekil 4.6. Gerçek test seti ve YSA test değerlerinin dağılım grafiği	46
Şekil 5.1. Türkiye elektrik enerjisi tüketim modellerinin karşılaştırılması.....	48

TABLolar LİSTESİ

Tablo 2.1. 2015 yılı Türkiye elektrik enerjisi üretiminde kaynaklara göre analiz	5
Tablo 2.2. Yapay sinir ağı yöntemi ile yapılan elektrik talebi tahmin çalışmaları	13
Tablo 3.1. Biyolojik sinir sistemi ve YSA işlem elemanları	33
Tablo 3.2. Biyolojik sinir sistemi ve DPNN işlem elemanları.....	34
Tablo 3.3. Çalışmada ele alınan değişkenler.....	37
Tablo 3.4. Elektrik tüketimi ve girdi değişkenleri arasındaki korelasyon katsayısı ..	37
Tablo 3.5. Uygulamada kullanılan veriler.....	38
Tablo 5.1. Türkiye elektrik enerjisi gerçekleşen ve tahmin tüketim değerleri	48
Tablo 5.2. Modellerin istatistiksel sonuçları	48

ÖZET

Anahtar kelimeler: Diferansiyel polinom sinir ağları, Yapay sinir ağları, Elektrik enerjisi, tüketim tahmini

Elektrik enerjisi ülkelerin refah ve çağdaşlaşma seviyesine ayna tutan metarlardan bir tanesidir. Elektrik enerjisi depolayamayan üretildiği anda tüketilmesi gereken enerji türüdür. Bu nedenle arzın karşılanması için tüketim talebinin tahmin doğruluğu önem arz etmektedir.

Nüfus artışının hızlanması, gelişen teknoloji ve hızlı sanayileşme gibi gelişmelerin yaşanması ile elektrik enerjisinin kullanımı ve ihtiyacı her geçen gün artmaktadır. Ayrıca elektrik enerjisi, ülkeler arası rekabetin önemli unsurları arasında yer alması nedeniyle de ülkeler doğru tahmin sistemi geliştirerek daha doğru tahminler elde etme üzerine çalışmalar yapmaktadır.

Bu çalışmada, uygulama yaygınlığı ile öne çıkan yapay sinir ağları ve yapay zeka tekniklerinin yeni bir çeşidi olan diferansiyel polinom sinir ağları ile Türkiye'nin elektrik enerji talebi tahmin edilmiştir. İhracat, ithalat, nüfus, kurulu güç ve gayri safi yurtiçi hasıla elektrik tüketimini etkileyen önemli faktörlerdir. Bu nedenle Türkiye'nin elektrik enerjisi tüketim tahmininde 1965-2016 yılları için bağımsız değişken olarak ele alınarak model girdileri olarak kullanılmıştır. Her iki metotla elde edilen tahmin sonuçlarının performansı karşılaştırmalı olarak ortaya konulmuştur. Karşılaştırmalar neticesinde diferansiyel polinom sinir ağı yönteminden elde edilen sonuçların ortalama mutlak yüzde hatası %4,32 daha düşük elde edilmiştir. Sonuçların analizinde kullanılan istatistiksel yöntemler diferansiyel polinom sinir ağının yüksek doğrulukta tahminler gerçekleştirdiği anlaşılmıştır.

ENERGY CONSUMPTION ESTIMATION WITH DIFERANSIYEL POLYNOMINAL NEURAL NETWORK TECHNIQUE

SUMMARY

Keywords: Differential polynomial neural networks, artificial neural networks, electric energy, consumption forecast

Electricity energy is one of the commodities in terms that mirrors the level of welfare and modernization of the countries. Electric energy is the type of energy that must be consumed when it is produced without storing it. For this reason, the prediction accuracy of the demand for consumption is important to meet the supply.

The use of electrical energy and the need for it is increasing day by day with the developments such as the acceleration of population growth, developing technology and rapid industrialization. In addition, as electricity energy is one of the important elements of competition among countries, countries are working on obtaining more accurate estimates by developing correct estimation system.

In this study, Turkey's electric energy consumption has been estimated with the artificial neural networks technique, which are prominent in application prevalence and differential polynomial neural networks which a new kind of neural networks technique. Export, import, population, installed power and gross domestic product are important factors affecting electricity consumption. Therefore, by considering as independent variables were used as inputs for the 1965-2016 model years in Turkey's electricity consumption estimated. As a result of the comparisons, the mean absolute percentage error of the results obtained from the differential polynomial neural network method was 4.32% lower. The statistical methods used in the analysis of the results have revealed that the differential polynomial neural network performed highly accurate estimates.

BÖLÜM 1. GİRİŞ

Enerji, ülkelerin refahının belirleyici faktörü olmakla beraber günümüzde siyasete yön veren kritik bir faktör durumundadır. Ülkeler arası rekabetin en önemli unsurları arasında yer alması nedeniyle ülkeler bu konuya farkındalık ile yaklaşmaktadırlar (Durmuşoğlu, 2016). Kullanım yaygınlığı ile refah seviyesinin en belirleyici enerji türlerinden biri olan elektrik enerjisi, depolanamayan, üretildiği anda tüketilmesi gereken bir enerji kaynağıdır. Elektrik enerjisinin depolanamıyor olması, talebe göre üretim yapılmasının önemini artırmaktadır (Yılmaz, 2012). Ülkemizin cari açık değerlerine bakıldığında yıllık elektrik enerjisinin bu değere katkısının oldukça büyük olduğu söylenebilmektedir. Nüfus artışının hızlanması, teknolojik gelişmeler ve hızlı sanayileşme gibi gelişmelerin yaşanmasıyla elektrik enerjisinin kullanımı ve ihtiyacı her geçen gün daha fazla artmaktadır (Karaca ve Karacan 2016). Ülke politikalarının yerine getirilmesi ve aynı zamanda günlük yaşamın vazgeçilmez unsuru haline gelen elektrik enerjisi talebinin karşılanması konusu önem arz etmektedir. Bu doğrultuda her ülke elektrik enerjisi tüketimine etki eden etmenler ile en doğru tahmin sistemi geliştirerek tahmin değerlerinin daha doğru elde edilmesi üzerinde çalışmalar yapmaktadır (Yavuzdemir, 2014).

Elektrik enerjisine yönelik yapılan planlamanın amacı, talebi ekonomik, kaliteli, olması gerekene en yakın ve güvenilir biçimde temin etmektir (Yavuzdemir, 2014). Elektrik enerjisi planlaması yapılırken kullanılan tahmin teknikleri parametrik yöntemler ve yapay zeka tabanlı yöntemler olmak üzere iki ana başlık altında incelenmektedir. Bu iki ana başlık altında yer alan yöntemlerden elektrik tüketimi talebinin tahmininde en çok kullanılan yöntemler ise zaman serisi modelleri, hareketli ortalama, regresyon analizi, üstel düzeltme, bütünleşik otoregresif hareketli ortalama (ARIMA) modelleri, uzman sistemler, yapay sinir ağları, genetik algoritma,

bulanık mantık, karınca kolonisi optimizasyon modelleri ve hibrit modellerdir (Boltürk, 2013). Etkin talep tahmin sonuçları ile klasik tahmin yöntemlerine göre daha doğru tahminler elde edilebilen yapay zeka tekniklerinin son yıllarda önemi daha da artmıştır (Kaynar ve Taştan, 2009).

Bu tez çalışması kapsamında Türkiye elektrik enerji talebi diferansiyel polinom sinir ağları ve yapay sinir ağları ile hesaplanmış ve hesaplama sonucunda elde edilen tahmin değerleri karşılaştırılmıştır.

İkinci bölümde Türkiye’de elektrik enerjisi ele alınmıştır. Geçmişten günümüze elektrik enerjisi talebi tahmini için kullanılan yöntemler anlatılarak Elektrik enerjisi tahmini için yapılan çalışmalara yer verilmiştir.

Üçüncü bölümde diferansiyel polinom sinir ağları ile yapay sinir ağlarının ayrıntılı olarak yapısı açıklamıştır. Her iki yöntemin de temel kavramları, temel elemanları, modelleri ele alınarak işleyiş sistemleri ortaya konularak tüketim tahmini uygulaması yapılmıştır.

Dördüncü bölümde diferansiyel polinom sinir ağları ve yapay sinir ağları ile talep tahmini uygulamasında elde edilen bulgulara yer verilmiştir.

Beşinci bölümde diferansiyel polinom sinir ağı ile yapılan tahminden elde edilen sonuçlar ile yapay sinir ağı ile elde edilen sonuçlar karşılaştırılarak yorumlanmıştır. Diferansiyel polinom sinir ağı ile elde edilen sonuçların yapay sinir ağı ile elde edilen sonuçlar değerlendirilerek yöntemin performansı yorumlanmıştır.

BÖLÜM 2. KONUNUN BİLİMSEL VE TEKNOLOJİK UYGULAMADAKİ YERİ


2.1. Türkiye’de Elektrik Enerjisi

Türkiye’de elektrik üretimine ilk defa Mersin’de 1902 yılında küçük su türbini ile başlanmıştır. Mersin üretiminin geliştirilmesi ile 1913 yılında İstanbul’da daha fazla güce sahip termik santralin kurulması ile üretime devam edilmiştir. 1930 yılında yasaların değişmesi ile birlikte belediyeler kendi sorumlu olduğu sınırlarda elektrik üretimi, iletimi ve dağıtımına başlamıştır. Etibank, Elektrik İşleri İdaresi (Eİİ), Maden Tetkik ve Arama (MTA) kurumlarının 1935 yılında kurulmasına takiben 1945 ile 1953 yılında kurulan İller Bankası ve Devlet Su İşleri (DSİ) Genel Müdürlüğü de elektrik piyasasında faaliyet göstermeye başlamıştır. Elektrik üretimi için yapılan çalışmaların ve gelişmelerin yanında iletim konusunda da çalışmaların önem kazanmasıyla iletim ağırları ve trafolar ile santraller kurularak işletilmeye başlanmıştır. 1963 ile 1967 yıllarını kapsayan Birinci Beş Yıllık Kalkınma Planı ile 1968-1972 yıllarını kapsayan İkinci Beş Yıllık Kalkınma Planı dönemlerinde elektrik üretim, iletim, dağıtım ve ticaret faaliyetlerinin entegre bir sistem halinde bir kamu kurumu bünyesinde birleştirilmesi hedef olmasından dolayı 1970 yılında 1312 Sayılı Yasa ile Türkiye Elektrik Kurumu (TEK) kurulmuş ve 1982 yılında da Belediyeler ve Birliklerin bünyesindeki elektrik tesisleri 2705 Sayılı Yasa gereğince TEK’e devredilmiştir. TEK, kuruluşunun 23. Yılında 513 sayılı Kanun Hükmünde Kararname ile Enerji ve Tabii Kaynaklar Bakanlığı ile bağlantılı olmak üzere özelleştirilerek Bakanlar Kurulunun 93/4789 Sayılı Kararı ile ” Türkiye Elektrik Üretim İletim A.Ş.” (TEAŞ) ve ” Türkiye Elektrik Dağıtım A.Ş.” (TEDAŞ) adı altında iki ayrı İktisadi Devlet Teşekkülüne ayrılmıştır. 2001 yılında Bakanlar Kurulu 2001/2026 sayılı kararı ile TEAŞ, Elektrik Üretim Anonim Şirketi (EÜAŞ), Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) ve Türkiye Elektrik Ticaret ve Taahhüt Anonim Şirketi (TETAŞ) olarak İktisadi Devlet Teşekkülü olmak üzere üçe ayrılarak yapılandırılmıştır. 2001 yılında elektrik dâhil olmak üzere enerji alanında yeniden yapılanma ile elektriğin

yeterli, sürekli, kaliteli, minimum maliyetli ve çevre dostu bir şekilde kullanıma sunulması ile mali açıdan güçlü, istikrarlı ve şeffaf bir elektrik enerjisi piyasasının oluşturularak rekabet ortamı yaratılması amaçlanmıştır (Yavuzdemir, 2014).

Türkiye, enerji kaynakları kısıtlı olan bir ülke olmasına karşın jeopolitik konumu ve teknoloji gelişimleri, yenilenebilir enerji kaynaklarına yatırımlar ile kaynak kısıtlılığını minimuma indirme şansına sahiptir (Durmuşoğlu, 2016). Asya ile Avrupa arasında bağlantı noktası olan, enerji tüketim miktarlarında olduğu gibi geçiş güzergâhı olması sebebi ile de enerji politikaları açısından stratejik öneme sahip bir ülkedir. Türkiye’de yaşanan hızlı nüfus artışı, şehirleşme, teknolojik gelişmeler gibi durumlar 2000 yılından bu yana doğalgaz ve elektrik talebinde yaşanan artışa sahip olan Çin’den sonra ikinci büyük ekonomi durumuna gelmesine sebep olmuştur. Elektrik enerjisi talebinde artışın olması ülkemizdeki elektrik enerjisinin de dâhil olduğu enerji alanında doğru politikaların, yasalarının oluşturulmasını ve talebi karşılamak için ülke talebini iyi analiz edecek programlar geliştirilmesini gerekli ve önemli kılmıştır (Es ve ark., 2014).

Daha önce bahsedildiği üzere elektrik enerjisi üretimi petrol, doğal gaz, kömür gibi termik santraller ile nükleer santraller ve güneş, jeotermal, rüzgâr gibi yenilenebilir enerji kaynaklarından üretilen bir enerjidir. Türkiye’de elektrik enerjisi üretiminin kaynaklara göre dağılımı Şekil 2.1.’de yer almaktadır.



Şekil 2.1. 2015 yılı Türkiye elektrik enerjisi üretiminin kaynaklara göre dağılımı (TEİAŞ, 2015)

2015 yılında elektrik üretiminde %37'lik dilim ile en fazla paya sahip enerji türü doğal gaz olmuştur. Üretim kaynağı olarak doğal gazdan sonra elektrik üretiminde en fazla paya sahip kaynaklar barajlar ve linyit olmuştur. Yenilenebilir, atık ve atık ısının elektrik enerjisi üretimindeki payı ise 0,67 olurken rüzgâr ve güneşin üretimdeki payı sırasıyla %4,45 ve %0,07'dir. Tablo 2.3.'te elektrik enerjisi üretiminde yer alan kaynakların üretim miktar detayları yer almaktadır. %37,9 pay ile birinci sırada yer alan doğal gaz kaynağı ile üretilen elektrik 99.218,7 gigawatt (GWH) olmuştur. Rüzgar ve güneşin ise elektrik üretimi sırasıyla 11.652,5 ve 194,1'dir.

Tablo 2.1. 2015 yılı Türkiye elektrik enerjisi üretiminde kaynaklara göre analiz (TEİAŞ, 2015)

Kaynak	Üretim (GWh)	Katkısı (%)
İthal Kömür	39.986,0	15,27
Taşkömürü + Asfaltit	4.843,9	1,85
Linyit	31.335,7	11,97
Doğal Gaz	99.218,7	37,90
Sıvı Yakıtlar	2.223,9	0,85
Barajlı	47.514,1	18,15
D.Göl ve Akarsu	19.631,8	7,50
Rüzgar	11.652,5	4,45
Atık Isı	407,9	0,16
Biyokütle	1.350,3	0,52
Jeotermal	3.424,5	1,31
Güneş	194,1	0,07
Toplam	261.783,3	100,00

Tablo 2.1.'deki verilere göre elektrik üretiminde yenilenebilir enerji kaynaklarının payının çok az olduğu görülmektedir. Özellikle ülkemizin dışa bağımlılığın azaltılması, karbondioksit emisyonlarının azaltılması, çevre dostu elektrik üretimi ve istihdamı arttırmak için elektrik enerjisi üretiminde yenilenebilir enerji kaynak paylarının artırılmasına yönelik projelerin içerisinde yer alınmasının önemli olduğu bir gerçektir.

2.2. Elektrik Talebi Tahmin Yöntemleri

Ekonomik ve sosyal kalkınmanın önemli bir boyutuna sahip olan girdilerinden biri olan enerji, herhangi bir ulusun sosyal ve ekonomik kalkınması için kritik öneme sahiptir. Son birkaç on yılda endüstriyel ve ekonomik faaliyetlerin artmasıyla birlikte enerji talepleri hızla büyümüştür (Xiao ve ark.,2015). Enerjiye olan talep nüfusta

yaşanan artış, sanayileşme, şehirleşme ile beraber küreselleşmeyle de artan ticaret ve üretim fırsatlarına bağlı olarak artış göstermektedir. Türkiye’de yaşanan hızlı nüfus artışı, şehirleşme, teknolojik gelişmeler gibi durumlar da enerji talebinin de her geçen gün daha fazla artmasına ve önem taşımaya sebep olmuştur (Yılmaz, 2012). Kalkınmanın en önemli girdileri arasında olan enerjinin planlamasında enerji yönetiminde önemli ve üzerine düşülmesi gereken en önemli adımlardan biri, talebin tahmin edilmesidir (Suhono ve Sarjiya, 2015).

Elektrik tüketiminde en çok kullanılan yöntemler, zaman serisi modelleri, hareketli ortalama, regresyon analizi, üstel düzeltme, bütünleşik otoregresif hareketli ortalama (ARIMA) modelleri, Box-Jenkins modelleri, uzman sistemler, yapay sinir ağları (YSA), genetik algoritmalar, bulanık mantık, destek vektör makineleri, karınca kolonisi optimizasyon modelleri ve hibrit modellerdir (Boltürk, 2013).

- Zaman Serisi Modelleri: Bu modelde, eğilim analiz yöntemi kullanılarak farklı zamanlardaki değerler arasındaki bağımlılık analiz edilerek tahmin değerleri elde edilen yöntemdir.
- Hareketli Ortalama Yöntemi: Belirli dönem ele alınarak zaman serisindeki gelecek dönemi ortalama alınarak tahmin eden yöntemdir.
- Regresyon Analizi: İki veya daha fazla bağımsız değişken ile bağımlı değişkenler arasındaki ilişkiyi ölçerek bağımsız değişkenlerin bağımlı değişkeni hangi doğrultuda etkilediğini ortaya çıkaran tahmin yöntemidir.
- Üstel Düzeltme: Üstel düzeltme yöntemi önceki zaman verileri değerlerinin üstel ağırlıklı hareketli ortalaması alınarak elde edilen bir sonraki zaman verileridir.
- ARIMA: Otoregresif ve hareketli ortalamanın birleşiminden oluşan yöntem olan ARIMA yöntemi istatistiksel bir yöntemdir. ARIMA modelleri, durağan

olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellerdir (Kaynar ve Taştan, 2009).

- Box-Jenkins Modelleri: Zaman serilerinin tek değişkenlileri için tahmin ve kontrolü için kullanılan istatistik yöntemlerdendir. Bu yöntem ile tahmin edilen zaman serisi modellerinin arasında hareketli ortalama (MA), otoregresif bütünleşik hareketli ortalama (ARIMA), otoregresif (AR) ve otoregresif hareketli ortalama (ARMA) modelleri yer almaktadır (Kaynar ve Taştan, 2009).
- Uzman Sistemler ve Yapay Sinir Ağları: Çözümü uzmanların bilgi ve deneyimini kullanarak çözüme giden bilgisayar sistemleridir. Uzmanların bilgisi taklit edilmeye dayalı prensiple çalışmalarından dolayı insanların nörolojik yapısı kullanılarak veriler eğitilir ve öğrenme gerçekleştirilerek tahmine gidilir (İçen ve Günay, 2014).
- Genetik Algoritma: Doğal gözlemlenen durumu taklit ederek her bir aday çözümlerin popülasyonu oluşturmasıyla en iyi çözümü arama yöntemidir (İşçi ve Korukoğlu, 2003).
- Bulanık Mantık: Küme ve alt kümelere dayanarak matematiksel fonksiyon oluşturulması ile insan gibi düşünmeyi esas alarak elde edilen aralık ve grafikler ile tahmin yapmaya yönelik bir yöntemdir.
- Destek Vektör Makineleri: Destek vektör makineleri, uygulamaya alınan verileri iki kategoriye ayırarak sahip olduğu iki katmanlı ileri beslemeli yapay sinir ağı yapısı ile çalışan tahmin yöntemidir (Türkay, 2015).
- Karınca Kolonisi Optimizasyon Modelleri: Karıncaların hareketine göre en kısa yolu bulma bakış açısı ile geliştirilmiş modellerdir.

Elektrik enerjisi depolanamayan bir enerji kaynağıdır. Ülkemizin cari açığı değerlerine bakıldığında yıllık elektrik enerjisinin katkısı çok büyüktür. Bu nedenle elektrik

enerjisinin talebe göre üretilmesi büyük önem arz etmektedir. Elektrik enerjisi tüketimi üzerine tahmin çalışmalarının ülkemiz için öneminin büyük olmasından dolayı tahmin çalışmaları 1960'lı yıllarda başlamıştır (Karaca ve Karacan, 2016). Gün geçtikçe artan nüfus, teknolojik gelişmeler ve hızlı sanayileşme ile artan elektrik talebine yönelik yapılan planlamanın amacı gelecekteki talepleri en ekonomik, kaliteli ve güvenilir biçimde temin etmektir. Elektrik talep tahmini yöntemleri iki ana başlıkta incelenmektedir. Birinci ana başlık parametrik yöntemlerdir. İkinci ana başlık ise yapay zeka tabanlı yöntemlerdir (Yavuzdemir, 2014).

2.3. Elektrik Talebi Tahminine Yönelik Yapılan Çalışmalar

Karabulut ve ark. (2008), uzun vadeli elektrik enerjisi tüketiminin tahmini için bir genetik programlama yaklaşımı önerilmişlerdir. Önerilen model Türkiye'nin güneydoğusundaki bir hizmet birimi tarafından kapsanan alanın elektrik enerjisi tüketimi ve buna karşılık gelen zaman verileri ile çalıştırılmıştır. Çalışma sonucunda elde edilen düşük hata oranı, elektrik tüketimi konusunda başarılı olunmasını sağlamıştır (Karabulut ve ark., 2008).

Srinivasan (2008), yaptığı çalışmada, Asya'daki bir elektrik kuruluşundan elde ettiği 78 aylık konut, endüstriyel, ticari olmayan, endüstriyel olmayan, eğlence ve kamusal elektrik verileri ile altı kategoride talebi tahmin etmeye yönelik çeşitli geleneksel ve sinir ağına dayalı yöntemlerin karşılaştırmalı bir değerlendirmesi yapılmıştır. Değerlendirmeye alınan modeller arasında yapay sinir ağına (YSA) dayalı modellerin daha iyi sonuçlar elde ettiği ve bu modeller içerisinde kendi kendini organize edebilen aktif nöronlardan oluşan grup veri işleme yöntemleri (GDMH) sinir ağının geleneksel zaman serileri ve regresyon tabanlı modellerden daha etkin sonuç verdiği ispatlanmıştır (Srinivasan, 2008).

Geem ve Roper (2009), Güney Kore'nin enerji talebini, hata geri yayılım algoritması ile ileri beslemeli çok katmanlı algılama (FF-BP-ANN) yapay sinir ağı modeli kullanarak gayrisafi yurtiçi hasıla (GSYH), nüfus, ithalat ve ihracat miktarları gibi dört bağımsız değişken doğrultusunda tahmin etmişlerdir. Önerilen YSA modeli, enerji

talebini, çoklu doğrusal regresyon modele göre veya üssel modelden RMSE açısından daha iyi tahmin etmiştir. Verilerin iki gruba bölünmesiyle doğrulanması YSA modelinin diğer iki modelden RMSE açısından çok daha iyi tahmin ettiğini göstermiştir (Geem ve Roper, 2009).

Pao (2009), Tayvan'daki toplam enerji tüketiminin neredeyse % 90'ını oluşturan elektrik ve petrol enerjisini hibrit doğrusal olmayan modelleri kullanarak tahmin çalışmasında bulunmuştur. Çalışmada, tek değişkenli modellemeyi içeren, doğrusal bir modeli yapay sinir ağı ile birleştiren ve değişen varyans dikkate alınarak düzeltilmiş tahminler geliştirmek adına oluşturulan iki yeni hibrit doğrusal olmayan model önerilmiştir. Genelleştirilmiş mevsimsel üstel varyasyon (SEGARCH) modeli ile yapay sinir ağlarının hibrit modeli olan SEGARCH-YSA ve üstel yumuşatma ile genelleştirilmiş mevsimsel üstel varyasyon modelinin kombinasyon modeli olan WARCH modeli ile yapay sinir ağlarının hibrit modeli olan WARCH-YSA modeli önerilerek elektrik enerjisi ve petrol enerjisi verileri ile uygulama yapılmıştır. Her bir modelin örnek dışı tahmin performansı, üç istatistiksel ölçüm değerleri (RMSE, MAE, MAPE) ile değerlendirilmiş, WARCH modelinin SEGARCH modelinden daha iyi olduğunu, SEGARCH-YSA'nın SEGARCH modelinden daha iyi olduğunu ve WARCH-YSA'nın hem elektrik hem de petrol tüketimi için dört modelin en iyisi olduğu sonucuna varılmıştır (Pao, 2009).

Bilgili (2009), Türkiye'nin 1990-2007 yılları arasındaki elektrik tüketim ve kurulu kapasite, brüt elektrik enerjisi üretimi, nüfus, toplam abone sayısı verilerini kullanarak doğrusal regresyon (LR), doğrusal olmayan regresyon (NLR) ve yapay sinir ağları yöntemleri ile 2012 yılına kadar elektrik tüketim tahminini yapmıştır. Elde edilen sonuçlara göre YSA yönteminin performans değerlerinin LR ve NLR modellerinin performans değerlerinden daha iyidir (Bilgili, 2009).

Demirel ve ark. (2010), adaptif ağ tabanlı bulanık çıkarım sistemi ve otoregresif hareketli ortalamalar modelleri ile Türkiye'nin 2010 yılına kadar olan yıllık elektrik enerjisi yük tahmini çalışması yapmışlardır. Çalışmada 1970-2007 yılları arasındaki gayri safi milli hasıla, tüketilen enerji, üretilen enerji, kurulu güç ve nüfus verileri

kullanılmıştır. Çalışmanın sonucunda elde edilen hata değerleri ile iki modelin sonucu kıyaslandığında adaptif ağ tabanlı bulanık çıkarım sistemi ile elde edilen sonuçların daha doğru olduğu sonucuna varılmıştır (Demirel ve ark., 2010).

Yiğit (2011), genetik algoritma kullanarak Türkiye'nin 1979 ile 2009 yılları arasındaki veriler ile elektrik enerjisinin 2020 yılına kadar tüketimini tahmin etmiştir. Çalışmada gayrisafi yurtiçi hasıla, ithalat, nüfus ve ihracat bağımsız değişken olarak alınmıştır. Genetik Algoritma elektrik tahmin yöntemi olarak, karesel ve lineeri esas alan iki model geliştirilmiştir. Elde edilen sonuçlara göre Türkiye'nin elektrik enerjisi ihtiyacını belirlemek için geliştirilen modeller geçerlidir (Yiğit, 2011).

Chang ve ark. (2011), yaptıkları çalışmada, ağırlıklı gelişen bulanık sinir ağı yaklaşımını (WEFuNN) geliştirerek Tayvan'ın aylık elektrik talebini tahmin etmişler ve Tayvan bölgesi için elde edilen sonuçlar ile bu yöntemin uygulanabilir olup olmadığını değerlendirmişlerdir. Parametrelerin en iyi kombinasyonunu belirlenmesinde taguchi yöntemi kullanılmıştır. Aylık elektrik tahmini için kullanılan girdi değişkenleri, belirli bir ay için ortalama hava basıncı, ortalama sıcaklık, ortalama rüzgâr hızı, yağış miktarı, yağışlı süre, ortalama bağıl nem ve gün ışığı süresidir. Yöntemin genel yapısı verilerin bulanıklaştırılması, ağırlıklandırılması, gelişim (evrim), benzerlik hesaplaması ve faktörlerin ağırlıklandırılması, çıkış değerlerinin hesaplanması, hata değerlerinin hesaplanması, durulaştırma işlemi, ayarların güncellenmesi ve ağırlık üretimi şeklindedir. Geliştirilen bu ağ ile elde edilen tahmin sonuçları ve hata değerleri literatürde önerilen diğer yaklaşımlar ile karşılaştırılmıştır ve WEFuNN modeli pratik olarak daha iyi sonuçlar verdiği için Tayvan'da elektrik talebi aracı olarak kullanılabileceği sonucuna varılmıştır (Chang ve ark., 2011).

Mestekemper ve ark. (2013), gün içi enerji talebi tahmininde periyodik otoregresif (PAR) ve dinamik faktör modellerinin performansının karşılaştırılması için yaptıkları çalışmada Almanya'daki buhar şebekesinde bölgesel ısıtma talebinin tahmininde ve Avustralya eyaletinde toplam elektrik talebinin tahmininde, geliştirdikleri yöntemin kullanışlı olduğu sonucuna varmışlardır (Mestekemper, 2013).

Ardakani ve Ardehali (2014), Amerika'nın elektrik tüketim talebi 1967–2009 yıllarının verileri ile gayri safi yurt içi hasıla, zaman, enerji ithalatı, enerji ihracatı ve nüfus bağımsız değişkenleri esas alınarak 2010-2030 yılları için geliştirilmiş parçacık sürü optimizasyonu (IPSO) ve karıştırılmış kurbağa sıçrama (SFL) algoritmalarına dayanan en iyi yapay sinir ağı kullanılarak tahmin edilmiştir. IPSO-YSA ve SFL-YSA ile elde edilen simülasyon sonuçları, IPSO-YSA modelinde elde edilen hata değerinin daha düşük olmasından dolayı daha iyi model olduğunu göstermiştir (Ardakani ve Ardehali, 2014a).

Ardakani ve Ardehali (2014), gelişmiş ve gelişmekte olan ekonomiler için İran ve ABD bölgesinin uzun vadeli elektrik talebinin tahminini 1967-2009 verilerinden sosyo-ekonomik göstergeler, yani gayri safi yurtiçi hasıla, enerji ithalatı, enerji ihracatı ve nüfus bağımsız değişken olarak esas alınarak 2010-2030 yıllarının talebini öngörmüşlerdir. Talebin değerlendirilmesi gradyan-dereceli alçalma (GD), parçacık sürüsü optimizasyonu (PSO) ve geliştirilmiş/iyileştirilmiş parçacık sürüsü optimizasyonu (IPSO) algoritmalarına dayanan optimize edilmiş regresyon ve yapay sinir ağı modelleri geliştirilerek yapılmıştır. Uygulamalardan elde edilen sonuçlar değerlendirildiğinde, IPSO-YSA modeline ve sosyo-ekonomik tarihi verilere dayanan elektrik enerjisi tüketimi tahminlerinin en doğru sonuç verdiği anlaşılmıştır (Ardakani ve Ardehali, 2014b).

Kaytez ve ark. (2015), yaptıkları çalışmada Türkiye'nin 1970-2009 yılları arasında yıllık elektrik tüketim verileri ile regresyon analizi, yapay sinir ağları ve en küçük kareler destek vektör makineleri (LS-SVM) yöntemlerini kullanarak elektrik tüketimini tahmin etmişlerdir. Modellerde brüt elektrik üretimi, toplam abone sayısı, nüfus ve kurulu kapasite bağımsız değişkenler olarak kullanılmıştır. Elde edilen sonuçlar çeşitli performans kriterleri karşılaştırılarak ampirik sonuçların özgüllüğü için alıcı davranış karakteristiği (ROC) analizi yapılmıştır. Önerilen LS-SVM modeli diğer yöntemlere göre daha doğru ve hızlı olduğu sonucuna varılmıştır (Kaytez ve ark., 2015).

Hussain ve ark. (2016), Pakistan'ın 1980 ile 2009 yılları arasındaki zamansal verileri ile Holt-Winter ve Özbağlanımlı entegre hareketli ortalama (ARIMA) yöntemleri ile elektrik talebini tahmin etmişlerdir. Sonuçlar, Holt-Winter'ın, Pakistan'daki elektrik tüketimini tahmin etmeye uygun model olduğunu ortaya koymuştur (Hussain,2016).

Kaboli ve ark. (2016) tahmin doğruluğunu iyileştirmek amacıyla yapay kooperatif arama algoritması geliştirerek İran'ın uzun vadeli elektrik enerjisi tüketimini, gayri safi yurt içi üretim, nüfus, borsa endeksi, ihracat ve ithalat bağımsız değişkenleri esas alınarak 1993 ile 2013 yılları arasındaki veriler ile tahmin çalışmasında bulunmuşlardır. Önerilen yöntem ile elde edilen sonuçlar göz önünde bulundurularak bu yöntemin uygulanabilirliğini ve doğruluğunu değerlendirmek için, genetik algoritma, parçacık sürüsü optimizasyonu, emperyalist yayımlı algoritma, benzetimli tavlama ve diferansiyel evrim ile karşılaştırılmıştır. Yapılan kıyaslama sonucunda, yapay kooperatif arama algoritmasının diğer optimizasyon yöntemlerine kıyasla önerilen elektrik tüketim tahmini yönteminde daha yüksek doğruluğun ve güvenilirliğin doğruluğunu teyit etmişlerdir (Kaboli ve ark., 2016).

Berneti (2016), İran'ın elektrik talebini 1967'den 2011'e kadar olan verileri ile tahmin etmek için adaptif ağ tabanlı bulanık çıkarım sistemini (ANFIS) geliştirmek için, genetik algoritmayla birleştirilmiş, çıkarılabilir bir kümeleme tekniği olan melez bir metot önermiştir. Bağımsız değişken olarak nüfus, GSYH, müşteri sayısı, elektrik fiyatı, ithalat ve ihracat alınmıştır. Elde edilen sonuçlar, önerilen hibrid yaklaşımın performansının, geleneksel parametrik bulanık mantıksal çıkarım sisteminden daha iyi olduğunu göstermiştir (Berneti 2016).

Baçoğlu ve Bulut (2017), Türkiye'nin kısa vadeli elektrik talebinin tahmin edilmesine yönelik uzman sistemlerin ve yapay sinir ağların birlikte kullanıldığı hibrit sistem önermişlerdir. Önerilen yöntem ile Türkiye'nin kısa dönem elektrik talep tahmini yapmışlardır. Elde edilen sonuçlar gerçek değerler ile karşılaştırılmış ve yakın değerler elde edildiği görülmüştür (Baçoğlu ve Bulut, 2017).

Verdejo ve ark. (2017), elektrik enerjisi dağıtım sistemlerinin en hassas ve önemli alanlarından biri olan operasyonel ve planlama aşamasının merkezinde talep evrimini ölçmek üzerine istatistiksel doğrusal parametrik teknikler (regresyon, zaman serisi, stokastik diferansiyel denklemler, harmonik regresyon) kullanılarak çalışma yapmışlardır. Yaptıkları çalışmada özellikle konut elektrik tüketimine dikkat çekilerek talep büyümesi ölçülmesi esas alınmıştır. Uygulama Şili'nin Santiago şehri için gerçekleştirilmiş olup, dışsal değişkenler ile ilgili olarak çevre, ekonomik ve sosyal faktörler esas alınmıştır. Enerji tüketiminde en etkili faktörlerden sıcaklık, ülke ekonomik değeri, insanların günlük sosyal davranışları (örn. Resmi tatillerdeki yük talebi, iş saatlerindeki yük talebi) bağımsız değişken olarak ele alınmıştır. Dört teknik için talep tahmini sonuçları yorumlanarak MPE (Mean Percentage Error) hata değerleri karşılaştırılmıştır (Verdejo ve ark., 2017).

Elektrik talebi tahminine yönelik yapay sinir ağları yöntemini kullanılarak yapılan çalışmalar kullanılan veri seti yılı, eğitim seti, test seti yılı ve tahmin türü detayında Tablo 2.2.'de verilmiştir.

Tablo 2.2. Yapay sinir ağı yöntemi ile yapılan elektrik talebi tahmin çalışmaları

Yazarlar	Tahmin Yöntemi	Değişkenler	Tahmin Türü	Veri Yılı	Eğitim	Test
Geem ve Roper (Geem & Roper, 2009)	YSA	GSYH, nüfus, ithalat, ihracat, tüketim	Yıllık	1980-2006	1980-2000	2001-2006
Pao (Pao, 2009)	YSA+Mevsimsel Üstel Varyasyon, YSA+Üstel Yumuşatma	Zaman ve tüketim	Aylık	1993-2007	1993-2005	2006-2007
Bilgili (Bilgili, 2009)	YSA, Doğrusal Regresyon ve Doğrusal Olmayan Regresyon	Kurulu kapasite, nüfus, abone sayısı, elektrik üretimi	Yıllık	1990-2007	1995-2007	1995,2000, 2005

Ardakani ve Ardehali (Ardakani & Ardehali, 2014a)	Parçacık Sürü Optimizasyonu, YSA	GSYH, zaman, ithalat, ihracat, nüfus	Yıllık	1967-2009	1967-2001	2002-2009
Kaytez vd. (Kaytez vd., 2015)	YSA, en küçük kareler destek vektör makinaları ve regresyon analizi	Elektrik üretimi, abone sayısı, nüfus, kurulu kapasite	Yıllık	1970-2009	1970-1996	1997-2009
Başoğlu ve Bulut (Başoğlu & Bulut, 2017)	Uzman sistemler+YSA	Önceki gün, bayram günleri, sıcaklık	Günlük, Haftalık	2005-2016	2005-2015	2016

Literatür incelendiğinde elektrik tüketim tahmini için kullanılan yöntemlerin ve ele alınan değişkenlerin çeşitliliği görülmektedir. Kullanım yaygınlığı fazla olan yapay sinir ağları ile yapılan tahmin çalışmalarını incelediğimizde bağımsız değişken olarak gayri safi yurtiçi hasıla, ithalat, ihracat, kurulu kapasite gibi verilerin ele alındığı görülmektedir.

BÖLÜM 3. MATERYAL VE YÖNTEM


3.1. Elektrik Tüketim Tahmini Uygulamasında Kullanılan Yöntemler

3.1.1. Diferansiyel polinom sinir ağı

Diferansiyel polinom sinir ağları (D-PNN), insan beyninin öğrenmesinde uygulanan ilkeler ile işlevsellik geliştiren, çok parametrik polinom fonksiyonları kullanarak kesirli diferansiyel oluşturarak en iyi çözümü bulmaya yönelik ağ sistemidir. D-PNN, bilinmeyen ilişkileri, beyin gibi değişkenlerin mutlak değerlerini kullanmayarak göreceli değişkenleri kullanarak tanımlayabilmektedir. Böylece geniş bir aralıktaki giriş veri aralığı değerlerini daha iyi tanımlayabilme imkânına sahiptir. Ayrıca, ağ, biyolojik nöronların yüksek dinamik davranış tarzı yaklaşımı ile zaman dinamik periyodik aktivasyon fonksiyon yaklaşımını uygulamaktadır (Zjavka, 2011).

Sinir ağlarının yeni bir sınıfını oluşturan diferansiyel polinom sinir ağları, işlevselliği temel olarak yapay sinir ağlarından farklı yeni bir sinir ağı türüdür. Diferansiyel polinom sinir ağları, doğrusal olmayan çok değişkenli karmaşık polinomları kullanarak seçimi yapılan ikame göreceli terimlerle ilişkili bir fonksiyonun bilinmeyen genel kısmi diferansiyel denklemi kuran ve aynı zamanda çözen sisteme sahiptir. Ağın tanımlaması, değişkenlerin desen benzeşimi ve mutlak değerleri temelinde değil, sadece bilinmeyen genelleştirilmiş veri ilişkileri üzerine kuruludur. Bu, insan beyninin öğrenmesinin simülasyonu olarak görülebilir; böylece, girdi verilerini, bağımlılıklarını genellemek için de araştırır. D-PNN yapısı ve parametre ayarlaması için araç olarak genetik algoritma uygulamaktadır. Genel itibarı ile geliştirilen yeni sinir ağı modeli D-PNN, bağımlı değişkenlere sahip karmaşık sistemlerin modellenmesi için kullanılabilir; bu ilişkiler bir sistemin yeni durumlarını (örn. hava tahmini) tanımlayabilir (Zjavka, 2010).

Diferansiyel polinom sinir ağının çalışmasındaki en ufak birim nöronların oluşturulduğu bloklardır. Şekil 3.1.'de görüleceği üzere bir blokta yer alan elemanlar ikili kombinasyona girecek bağımsız değişkenler, işleme giren bağımsız değişkenlerden oluşturulan diferansiyel denklem, nöronlar ve blok çıktısıdır.



Şekil 3.1. Nöronlardan oluşan blok yani ikame türevi terimleri (Zjavka ve Pedrycz, 2016)

x_1 ve x_2 'nin kombinasyonu ile iki doğrusal x_1 , x_2 , iki kare x_1^2 , x_2^2 bir kombinasyon x_1x_2 türev değişkeni için oluşturulmuş 5 basit nöronu olacaktır. Diferansiyel polinom sinir ağlarının en küçük birimini oluşturan bloklar giriş değişkenlerinin sayısının artması ile etkileşime girecekleri ikili kombinasyon sayının artması sebebiyle blok sayısında artış olacaktır.

Giriş bağımsız değişkenlerinin kombinasyonları ile oluşturulan blokların işlem gördüğü gizli katmanlar da diferansiyel sinir ağının temel kavramlarından biridir. Her gizli katmanda giriş değişkenleri, bloklar ve bir sonraki gizli katmana girecek blok çıktı değişkenleri yer almaktadır.

3.1.1.1. Diferansiyel polinom sinir ağı genel mimarisi

Diferansiyel polinom sinir ağının geliştirilmesinin başlangıç noktası, 1968 yılında Aleksey Ivakhnenko'nun sinir ağı yapısı tasarımı ve polinomların ayar parametreleri

için geliştirdiği veri işleme grubu yöntemi (GDMH) polinom sinir ağıdır. Diferansiyel polinom sinir ağının işletim ve tasarım ilkeleri, Taylor serisi genişletmelerine dayanan GMDH'den farklıdır, ancak genel kısmi diferansiyel denklemi GMDH'ye genel giriş-çıkış bağlantı polinomunda olduğu gibi parçalamaktadır (Zjavka, 2010).

Diferansiyel polinom sinir ağı, değişkenlerin boyutsuz oran gruplarından sistem özelliklerini oluşturarak benzerlik boyut analizine göre genel kısmi diferansiyel denklemi çözebilen ikame polinom kesir toplam terimlerini üretmek için komple polinom sinir ağı yapısını kullanmaktadır. Temel ilkeleri önceden bilinmeyen ve genel olarak kısmi çok değişkenli polinom türev terimlerinin ikame birleşimi kullanılarak aranan bir fonksiyonu (Denklem 3.1) modelleyebilen genel kısmi diferansiyel denklemi (DE) oluşturmak ve çözmektir (Denklem 3.2).

$$u = \sum_{k=1}^{\infty} u_k \quad (3.1)$$

$$Y = a + \sum_{i=1}^n b_i \frac{\partial u}{\partial x_i} + \sum_{i=1}^n \sum_{j=1}^n c_{ij} \frac{\partial^2 u}{\partial x_i \partial x_j} + \dots = \text{çözüm} \quad (3.2)$$

Burada $u = f(x_1, x_2, \dots, x_n)$ n-girdi değişkenlerinin aranan fonksiyonunu, $a, B(b_1, b_2, \dots, b_n), C(c_{11}, c_{12}, \dots, c_{mn})$ parametrelerini ifade etmektedir.

Bilinmeyen fonksiyon ‘u’(Denklem 4.1), kısmi diferansiyel denklemden (Denklem 3.2) hesaplanır ki bu da basit formunu terimlerin geri kalanının, yani onun kısmi fonksiyon türevlerinin bir toplamı olarak içerir. GMDH (Denklem 3.3) değişkenlerine karşılık gelen birkaç farklı türde azaltılmış kombinasyon polinomu, benzerlik analizi prensiplerine benzer genel bir polinom boyutsuz yer değiştirmeyi kullanarak genel kısmi diferansiyel denklemi (Denklem 3.2) çözebilen kesir terimlerinin (Denklem 3.4) türev parçalarını oluşturur (Zjavka ve Pedrycz, 2016).

$$y = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j + a_4 x_i^2 + a_5 x_j^2 \quad (3.3)$$

Burada $x_{(i)}$ giriş değişkenleri ve $a(a_0, a_1, a_2, \dots, a_n)$ parametre vektörlerini ifade etmektedir.

$$u_i = \frac{(a_0 + a_1 x_1 + a_2 x_2 + \dots + a_n x_n + a_n + x_1 x_2 + \dots)^{m/n}}{(b_0 + b_1 x_1 + b_2 x_2 + \dots)} = \frac{\partial^m f(x_1, \dots, x_n)}{(\partial x_1 \partial x_2 \dots \partial x_m)} \quad (3.4)$$

Burada n , n -girdi değişkenlerinin tam bir polinomunun kombinasyon derecesini ve m türev polinom paydağı kombinasyon derecesini ifade etmektedir.

Denklem 3.4'ün payı, tek bir nöronun komple n değişken kombinasyonlarının bir polinomudur ve Denklem 3.5' in yeni bir fonksiyonunu uygular (Zjavka, 2010).

$$Y = w_0 + w_1 \frac{\partial z}{\partial x_1} + w_2 \frac{\partial z}{\partial x_2} + \dots + w_n \frac{\partial z}{\partial x_n} + w_{n+1} \frac{\partial z}{\partial x_1 x_2} + \dots \quad (3.5)$$

Burada z n -girdi değişkenlerinin fonksiyonunu (u fonksiyonunu) ve W_i terim ağırlıklarını ifade etmektedir.

D-PNN çıkışı, ağdaki probleme göre değişiklik gösteren farklı sayıda nöronun aktif nöron çıktı değerlerinin aritmetik ortalamasıdır (Denklem 3.6).

$$Y = \frac{\sum_{i=1}^k y_i}{k} \quad (3.6)$$

Burada k gerçek aktif nöron sayısını (diferansiyel denklem terimleri) ifade etmektedir.

Örneğin, iki değişkenli bir blok ele alınacak olursa blok ve nöron polinomlarının kare güç değişkenleri ile uzatılacak ve blok aranan iki değişkenli u fonksiyon modelinin 2. dereceden kısmi diferansiyel denklemin çözümünün (denklem 3.7) iki doğrusal x_1 ,

x_2 , iki kare x_1^2, x_2^2 , bir kombinasyon x_1x_2 türev değişkeni için oluşturulmuş 5 basit nöronu olacaktır. Böylece ikinci dereceden kısmı diferansiyel denkleminin (denklem 3.7) 8 değişkeni olacaktır.

$$F(x_1 + x_2 + u + \frac{\partial u}{\partial x_1} + \frac{\partial u}{\partial x_2} + \frac{\partial^2 u}{\partial x_1^2} + \frac{\partial^2 u}{\partial x_2^2} + \frac{\partial^2 u}{\partial x_1 \partial x_2}) = 0 \quad (3.7)$$

Burada, $F(x_1, x_2, u, p, q, r, s, t)$ 8 değişkenin bir fonksiyonudur. x_1 'in doğrusal türev değişkeni (denklem 3.8), x_2 'nin kare türev değişkeni (denklem 3.9) ve x_1 ve x_2 'nin kombinasyon türev değişkeni (denklem 3.10) aşağıda yer almaktadır.

$$y_1 = \frac{\partial f(x_1x_2)}{\partial x_1} = w_1 \frac{\left(\frac{1}{6} \cdot (a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2)\right)^{\frac{1}{2}}}{\frac{1}{2} \cdot (b_0 + b_1x_1)} \quad (3.8)$$

$$y_3 = \frac{\partial^2 f(x_1x_2)}{\partial x_2^2} = w_3 \frac{3 \cdot (a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2)}{6 \cdot (b_0 + b_1x_2 + b_2x_2^2)} \quad (3.9)$$

$$y_5 = \frac{\partial^2 f(x_1x_2)}{\partial x_1 \partial x_2} = w_5 \frac{4 \cdot (a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2)}{6 \cdot (b_0 + b_1x_1 + b_2x_2 + b_3x_1x_2)} \quad (3.10)$$

Ele alınan iki değişkenli bir blok 5 basit nöron içermektedir ve her bloktan seçilen nöronların kombinasyonu ağıın çıktısını oluşturmaktadır. Her blok türevsel olmayan GDMH (Denklem 3.3) denklemini kullanarak çıktı üretir ve üretilen çıktılar bir sonraki gizli katmana girer. Her bir blokta a ve b olmak üzere ayarlanabilir iki vektör ve w_i terim ağırlığı mevcuttur. Polinomların parametreleri reel sayılarla temsil edilir, burada başlangıç değerleri 0,5 ve 1,5 aralığında rastgele oluşturulur. Ayrıca nöron ve blok polinom çıktıları negatif değer alamamaktadır (Zjavka ve Pedrycz, 2016).

3.1.1.2. Diferansiyel polinom sinir ağı yapısı

Diferansiyel polinom sinir ağı, çok katmanlı ve geriye doğru çalışma mekanizmasına sahiptir. Temel yapı elemanları girdi değişkenleri, bloklar, nöronlar, gizli katmanlar ve çıktılardır. Çok Kamanlı geriye doğru diferansiyel polinom sinir ağı, her blok için ikili kombinasyonu gerçekleştirebildiği için diferansiyel denklemler aracılığı ile girdi değişkenlerinin daha yüksek kombinasyonunu içeren bileşik polinom fonksiyonlarını oluştururlar. Oluşturulan bileşik fonksiyonların, kısmi türevlerinin de kullanılması ile olası tüm kombinasyon diferansiyel denklem terimlerini elde etmek için yöntemde geriye doğru yapı benimsenmiştir. Kombinasyon sayısını belirli ölçekte tutabilmek adına Diferansiyel polinom sinir ağlarının diğer bir temel kavramlarından biri olan gizli katman sayısını her giriş değişken sayısı için giriş değişken sayısı ile aynı ayarlanmalıdır. Çok katmanlı geriye doğru diferansiyel polinom sinir ağında bileşik diferansiyel denklem, bileşik fonksiyon türevi yerine iç (denklem 3.11) ve dış (denklem 3.12) fonksiyonların kısmi türev çarpımı (denklem 3.13) ve kısmi türev kurallarına göre oluşturulmaktadır.


$$y_1 = \varphi_1(X) == \varphi_1(x_1, x_2, x_3, \dots, x_n) \quad i = 1, \dots, m \quad (3.11)$$

$$F(x_1, x_2, \dots, x_n) = f(y_1, y_2, \dots, y_m) = f(\phi_1(X), \phi_2(X), \dots, \phi_m(X)) \quad (3.12)$$

$$\begin{aligned} \frac{\partial F}{\partial x_1} &= \frac{\partial f}{\partial y_1} \cdot \frac{\partial \varphi_1}{\partial x_1} + \frac{\partial f}{\partial y_2} \cdot \frac{\partial \varphi_2}{\partial x_1} + \dots + \frac{\partial f}{\partial y_m} \cdot \frac{\partial \varphi_m}{\partial x_1} \\ \frac{\partial F}{\partial x_2} &= \frac{\partial f}{\partial y_1} \cdot \frac{\partial \varphi_1}{\partial x_2} + \frac{\partial f}{\partial y_2} \cdot \frac{\partial \varphi_2}{\partial x_2} + \dots + \frac{\partial f}{\partial y_m} \cdot \frac{\partial \varphi_m}{\partial x_2} \\ &\dots \\ \frac{\partial F}{\partial x_n} &= \frac{\partial f}{\partial y_1} \cdot \frac{\partial \varphi_1}{\partial x_n} + \frac{\partial f}{\partial y_2} \cdot \frac{\partial \varphi_2}{\partial x_n} + \dots + \frac{\partial f}{\partial y_m} \cdot \frac{\partial \varphi_m}{\partial x_n} \\ \frac{\partial F}{\partial x_k} &= \sum_{i=1}^m \frac{\partial f(y_1, y_2, \dots, y_m)}{\partial y_i} \cdot \frac{\partial \phi_i(X)}{\partial x_k} \quad k = 1, \dots, n \end{aligned} \quad (3.13)$$


Katmanların önündeki bloklar iç fonksiyonları (Denklem 3.11) oluşturur ve dış fonksiyon (Denklem 3.12) üretmek için nöronun ve blok polinomların bir sonraki girdi değişkenlerin yerini alır. İkinci ve sonraki gizli katmanlarda yer alan bloklar, ek bağlantılı önceki katman bloklarının girdi değişkenlerine göre iç ve dış fonksiyonlar

ile birleşik/bileşke (kompozit) fonksiyon türevlerinin yerini alan terimi (CT), (yani) nöronları oluşturmaktadır.



Şekil 3.2. Geriye doğru bağlantıları ile bileşik fonksiyon oluşumu (Zjavka ve Pedrycz, 2016)

Şekil 3.2.'den görülebileceği üzere, 3. katmanın 1. bloğu ele alınarak anlatılacak olursa, çok katmanlı geriye doğru yapı ile giriş ve çıkış değişkenlerinin etkileşimiyle bileşke fonksiyonlar ve dolayısı ile bileşik nöronlar oluşumu gerçekleşir. 3. Katmanın 1. Bloğunda 5 basit nöron oluşmuştur. Her bir sonraki katmanda nöron aktivasyon olasılığı 2 kat artarken, CT (bileşik terimler, nöronlar) yarıya düşer. Her katmanda oluşan tüm nöron ve blok çıkış polinomları içerdikleri öge sayısına yani polinom üye sayısına bölünür. Böylece nöronlar yani bileşik terimler, bloklar, tüm ağ çıktıları işleme girecekleri bir sonraki gizli katmandaki blok çıktılarından oluşması için ve polinom parametrelerinin ayarlanmasında özellikle yararlı olan 1 değeri etrafında üretilirler.



Şekil 3.3. N sayıda bağımsız değişkenli çok katmanlı D-PNN (Zjavka ve Pedrycz, 2016)

Şekil 3.3.'ten sayıda değişken için çok katmanlı geriye doğru diferansiyel polinom sinir ağı yapısı genel hatları ile verilmiştir. Çok katmanlı geriye doğru D-PNN, bileşik fonksiyonları kısmi türevlerini kullanarak olası tüm kombinasyon diferansiyel denklem terimlerini oluşturmak için geriye doğru çalışan yapıya sahip olduğu için gizli katman sayısı ile toplam girdi değişken sayısı aynı olmalıdır. Geriye doğru çalışma mekanizması ile yapılan işlemler doğrultusunda seçilen nöronların kombinasyonu, ağıın çıktısını olan Y değerini oluşturur.

D-PNN, giriş ve çıkış veri değerlerinin oldukça farklı eğitim ve test aralıklarını uygulayabilmektedir. Nöron aktivasyon olasılığı PA, blokların genel olarak olası tüm nöronların yaklaşık yarısını içermesi ve optimal bir diferansiyel denklem çözümü ile sonuçlanması için 0,5 civarında belirlenmektedir. Genel diferansiyel polinom sinir ağı çıkışını ifade eden Y değeri, ağıın toplam çıktısını etkileyen değişen sayıda nöron kombinasyonunun dengesini sağlamak amacı ile tüm aktif nöron değerlerin aritmetik ortalaması ile hesaplanmaktadır (Denklem 3.15).

$$Y = \frac{\sum_{i=1}^k y_i}{k} \quad (3.15)$$

Burada k , aktif nöronların gerçek sayısını (diferansiyel denklem terimlerini) ifade etmektedir.

D-PNN metodunda uygun bir nöron kombinasyonunun seçimi, kısmi diferansiyel denklem yapısının başlıca parçasıdır (Zjavka ve Pedrycz, 2016). Her bir nöron durumu aktif ve pasif durumuna göre 1 veya 0 olarak kodlanmaktadır. Böylece ağı yapısını mutasyon ve çaprazlamayı sağlayacak genetik algoritma ile çaprazlamaya uygulayabilen nöron aktifleşmeleri PA kombinasyonu oluşturacaktır (Zjavka, 2010). Bir çözümün toplam nöron sayısını etkileyen PA olasılıkları tamsayılardır. Ayrıca D-PNN yöntemi polinom kalemelerinin(nöronları) sigmoidal dönüşümlerini (Denklem 3.16) kullanarak polinom ve yapay sinir ağı işlevselliğini bütünleştirir. Sigmoid fonksiyonu sürekli olmasının yanında türevi de alınabilen bir fonksiyondur. Türevinin alınabiliyor olması geriye doğru yapı içeren D-PNN'nin yapısına entegre olmasını kolaylaştırmıştır. Öğrenme hızı her döngüde, parametreleri rastgele azalan öğrenme katsayıları ile değişen bir bireyi geliştirmeye dayanmaktadır. Bireysel çözümler nöronların aktivasyon olasılıkları PA ile başlatılır ve birbirleriyle daha da birleştirilir. Sigmoid fonksiyonu (Denklem 3.16) (Denklem 3.17) girdi değişken değerlerinin her biri için 0-1 arasında değer üretimi gerçekleştirir. Öğrenme hızı mutasyona ek olarak, mutasyona uğratılan bireyi yani nöronu ile eş olarak uygulanan parametre değişikliklerini de ifade etmektedir. Mutasyon ve çaprazlama ile öğrenme hızı daha iyi bir hata bulmak hedefindedir.

$$\text{sign}(v_{ij}(t+1)=1) = \frac{1}{1 + e^{-v_{ij}(t)}} \quad (3.16)$$

$t+1$ adımıdaki bir nöron durumu aşağıdaki gibi olur:


$$x_{ij}(t+1) = \begin{cases} 1 & \text{eger } \rho \leq s(v_{ij}(t)) \\ 0 & \text{diger} \end{cases} \quad (3.17)$$

$\rho : 0$ ile 1 arası rasgele fonksiyon

Sigmoidal fonksiyonun x_1 ve x_2 değişkenlerinin etkileşime girdiği polinom yapısındaki işleyişi denklem 3.18'deki gibi olur. Kare polinom kalemelerinin ve parametrelerinin (Denklem 3.18) sigmoid dönüşümünü uygulayan D-PNN modelleri ayarlama yapay sinir ağlarına göre olarak daha istikrarlıdır.

$$y = \frac{(a_0 + a_1x_1 + a_2x_j + a_3x_1x_j + \text{sig}(a_4x_1^2) + \text{sig}(a_5x_j^2))}{6} \quad (3.18)$$

Nöronun mutasyon işlemi polinomların parametreleri, bazı yerel hata minimallerinde tıkanıklığı önlemek için yeterli rastgele mutasyonlar ile sağlanan gradyan en dikine iniş (GSD) yöntemi ile ayarlanır.



Şekil 3.4. D-PNN rasgele paralel kademeli bitirme işlemleri ve seçim ayarı

Her iterasyonda diferansiyel denklem ayarı için Şekil 3.4.'te ifade edilen çalışma prensibi ile rastgele paralel optimizasyon işlemi gerçekleşir. İlk olarak polinom parametre ayarı, daha sonra türev nöron seçimi ve son olarak da birleşik blokların yeniden bağlanması yapılır. Bu üç aşamadan birine rastgele mutasyon işlemi uygulanır. Parametre optimizasyonu aynı anda ilk oluşturma aşamasında en uygun nöron kombinasyonu seçimi ile gerçekleştirilir. Tüm blok ve nöron parametreleri, ağırlıkları, [0,5 1,5] aralığındaki değerlerle polinom kalemelerinin çarpımları olarak rasgele olarak başlatılır ve parametreler 1,0 değerleri etrafında üretilir. Böylece, polinomun türev terimlerinin etkin hesaplanması ve çıktıların optimizasyonu en iyi şekilde gerçekleştirilir.

Eğitim ve teste ayrılacak veriler [0,5 1,5] aralığında normalize (Denklem 3.19) edilir.

$$x_{nom} = LO_x + \frac{x - x_{min}}{x_{max} - x_{min}} \cdot (HI_x - LO_x) \quad (3.19)$$

Burada x_{nom} , x giriş değerinin normalleştirilmiş değerini, x_{max} , x_{min} değeri x giriş vektörünün maksimum ve minimum değerlerini LO_x , HI_x normalize edilmiş aralık değerlerinin alt ve üst sınırlarını x [0,5 1,5] aralığında ifade etmektedir.

Çıktılar ise çoğunlukla [0,9 1,1] aralığında denormalize (Denklem 3.20) edilerek 1,0 değerinde üretirler.

$$y_{out} = y_{min} + \frac{y - LO_y}{HI_y - LO_y} \cdot (y_{max} - y_{min}) \quad (3.20)$$

Burada y_{out} , bir çıkış şebeke değerinin normalize edilmemiş çıkış fonksiyonu değerini, y_{max} ve y_{min} değeri fonksiyonun maksimum ve minimum çıktılarını, LO_y , HI_y , çıkış aralığı değerlerinin alt ve üst sınırlarını y [0,9 1,1] aralığında ifade etmektedir. Eğitim ve test verileri hata karelerinin ortalamasının karekökü (RMSE) ve ortalama mutlak yüzde hata (MAPE) hata hesaplama denklemleri ile hesap edilmektedir.


3.1.2. Yapay sinir ağı

Yapay sinir ağları, insan beynindeki biyolojik sinir hücrelerinin çalışma prensibi ile geliştirilen karmaşık bilgileri öğrenerek bilgi türeten yapay sinir hücrelerinin bir araya gelmesi ile oluşturulan sistemlerdir. Öğrenme yeteneğinin yanında ilişki kurma, genelleme yapabilme, modelleme ve ezberleme yeteneklerine de sahiptir. Sahip olduğu yetenekler ile geleneksel yöntemlerin sahip olmadığı ve çözüm üretemeyeceği problemlere yönelik geliştirilmiş bir yöntemdir (Kılıç, 2015).

Yapay sinir ağıları, bilgi zekâ geliştiren işlemleri gerçekleştirecek tek yönlü bağlantılar ile birbirlerine bağlanan paralel bilgi işleme eleman sistemine sahiptir. İnsan beyni fonksiyonları ile yapay sinir ağının ana prensibi arasında benzerlik yer aldığı için yapay sinir ağlarına insan beyni simülasyonu denilebilir. Karmaşık problemleri çözme yeteneği ile bilinen yapay sinir ağıları hedefe ulaşmak için analiz edilen veri setini hangi denkleme uyguladığı bilinmemekle beraber herhangi bir denkleme bağlı çalışmamaktadır (Saraç, 2012).

Yapay sinir ağlarının en temel elemanı bilgi işleme birimi olan yapay nörondur. Nöronların bağlantı kurması ile katmanlar oluşur ki bu da yapay sinir ağlarının temel yapısını oluşturmaktadır.

Şekil 3.5., yapay sinir ağlarının temel bilgi işleme birimi olan nöronu ve temel bileşenlerini içermektedir. Yapay sinir hücresinde, biyolojik sinir hücresindeki dentritin karşılığı girdilerin alınması, çekirdeğin karşılığı girdilerin işlendiği aşama, aksonun karşılığı işlenen girdilerin çıktıya çevrilmesi ve bağlantının karşılığı ise çıktıların diğer sinir hücrelerine iletilmesidir.



Şekil 3.5. Yapay nöronun temel bileşenleri (Aşık, 2013)

Şekil 3.5.'te yapay bir nöronun yapısı verilmektedir. Genel anlamda yapay bir nöronun temel bileşenleri, nöronun öğrenmesi istenen bilgiler olan girdiler (x_i), çıktı değerinin sıfır değerini almasını önlemek için kullanılan eşik değeri (b), nöronlara gelen bilgilerin önemine göre nörona etki eden ağırlıklar (w_i), nörona gelen ağırlıklı girdinin

hesaplanmasını sağlayan ve en yaygın olarak kullanılan ağırlıklı toplam fonksiyonu olan toplama fonksiyonu (T), nöronun üreteceği çıktıyı hesaplayan aktivasyon fonksiyonu (F) ve çıktı (y)'dir.

Toplama fonksiyonu olarak kullanılabilecek fonksiyonlar, ağırlıklı değerlerin toplamı, ortalaması, mod, en büyüğü ve en küçüğü fonksiyonlarıdır. Herhangi bir probleme uygulanabilecek en uygun toplama fonksiyonunun belirlenmesinde belirli bir yöntem yoktur. Bu nedenle deneme yöntemi ile probleme en uygun toplama fonksiyonu belirlenir. Denklem 3.21 toplama fonksiyonlarının içerisinde en yaygın olarak kullanılan ağırlıklı toplama fonksiyonudur (Aşık, 2013).

$$T = \sum_{i=1}^n x_i w_i + b \quad (3.21)$$


Burada b, eşik değerini, x değerleri girdi değerlerini ifade ederken w değerleri ise her bir girdinin ağırlık değerlerini ifade etmektedir.

Aktivasyon fonksiyonu, yapay sinir hücresinin çıktısının büyüklüğünü sınırlandırarak çıktıları [0, 1] gibi belirli değerler arasında tutan sürekli bir fonksiyondur. Aktivasyon fonksiyonu olarak sigmoid, doğrusal fonksiyon, hiperbolik tanjant fonksiyon, eşik fonksiyonu gibi farklı fonksiyonlar uygulanabilmektedir. Fakat sigmoid fonksiyonu (Denklem 3.16) sürekli ve türevi alınabilir bir fonksiyon olmasından dolayı doğrusal olmayan problemlerin ve türev bilgisi isteyen algoritmalarda avantaj olduğu için tercih edilen aktivasyon fonksiyonu olmaktadır. Yapay sinir ağı hücresinin birden fazla girdisi olmasına rağmen aktivasyon fonksiyonu ile belirlenen tek bir çıktı değeri vardır ve bu değer diğer yapay sinir hücrelerine girdi olarak gönderilir veya dış ortama gönderilir (Sarı, 2016).

3.1.2.1. Yapay sinir ağlarının yapısı

Yapay sinir ağlarının en temel elemanı bilgi işleme birimi olan yapay nöronların birbirleriyle bağlantısı ile ilişkilendirilmesi katmanlar halinde olmaktadır. Bu nedenle

yapay sinir ağlarının yapısını katmanlar oluşturmaktadır. Bir yapay sinir ağının yapısı tek veya çok katmanlı olabilmektedir. Katmanları giriş katmanı, gizli katman ve çıkış katmanı oluşturmaktadır. Böylece nöron yığını oluşturmak yerine nöronlar katmanlar halinde gruplandırılmakta ve katmanlar arası bağlantı kurulabilmektedir. Yapay sinir ağları, yapay sinir hücrelerinin bu şekilde birbirlerine bağlanması ile oluşmaktadır. Yapay sinir ağlarının temel yapısı Şekil 3.6.'da verilmektedir.



Şekil 3.6. Yapay sinir ağları temel yapısı (Kılıç, 2015)

Yapay sinir ağlarının genel mimari yapısındaki gizli katman sayısı uygulamaya göre artırılabilir. Şekil 3.6.'da 6 girişten oluşan yapay sinir hücresi giriş katmanı, 3 yapay sinir hücresinden oluşan gizli katman ve 2 yapay sinir hücresinden oluşan çıkış katmanlı yapay sinir ağı verilmiştir. Verilerin ağa girişinin yapıldığı katman giriş katmanında veriler herhangi bir işleme alınmadan bir sonraki katman olan gizli katmana iletilir. Probleme göre değişiklik gösteren gizli katmanda giriş katmanından gelen ileti uygun fonksiyon ile işlenerek bir sonraki gizli katman veya çıkış katmana iletilir. Çıkış katmanında gizli katmandan gelen veriler fonksiyonla işlenerek çıktı oluşur (Kılıç, 2015).

3.1.2.2. Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağları literatürde iki farklı şekilde sınıflandırılmaktadır. Birinci sınıflandırma nöronlar arasındaki bağlantı ve akış yönüne göre yapılırken, ikinci sınıflandırma öğrenme algoritmalarına göre yapılmaktadır. Bağlantı ve akış yönüne

göre yapay sinir ağları ileriye beslemeli ağlar ve geri beslemeli ağlar olmak üzere ikiye ayrılırken öğrenme yöntemlerine göre yapay sinir ağları danışmalı ve danışmasız öğrenme olmak üzere ikiye ayrılmaktadır.

İleri beslemeleri ağlar sınıfında tek katmanlı, çok katmanlı ve radyal tabanlı fonksiyon sinir ağları; geri beslemeli ağlar sınıfında ise rekabetçi ağlar, kohenen ağı, holpfield ağı ve art modeli yer almaktadır. Danışmalı öğrenme sınıfında danışmalı öğrenme, perceptron, çok katmanlı perceptron, geri yayılım ağı, daha yüksek düzeyli sinir ağı ve işlevsel bağ ağı; danışmasız öğrenme sınıfında ise holpfield ağı, olasılıksal sinir ağı, uyarlanır rezonans ağı, öz örgütlemeli harita ağı, Boltzmann makinesi, hamming ağı, geri yayma içine öz örgütlemeli harita ağı, iki yönlü çağrışım belleği, yığın ağı, karşı yayma ağı, öğrenme vektör nicelendirmesi ve rekabetçi öğrenme ağları yer almaktadır (Kılıç, 2015)

İleri beslemeli yapay sinir ağlarında girdi ve çıktı katmanları arasında doğrusal olmayan yapıda gizli katman yer almaktadır ve nöronlar katmanlar arasında ileri yönlü bağlantı kurarak aynı katman içerisinde bağlantı kurmadan hareket etmektedir. Nöronlar arası akışların tek yönlü olmasından dolayı ileri beslemeli yapay sinir ağlarında veriler hızlı çıktı üretmektedir. Geriye beslemeli yapay sinir ağlarında ise veri akışı ileri ve geri yönlü olmak üzere çift yönlüdür. Çıktı veya gizli katmanların nöron çıkışları önceki katmanlara girdi olarak tekrar iletilir. Bundan dolayı geri beslemeli yapay sinir ağı daha dinamik ve daha güçlü bir hafızaya sahiptir. Dinamik ve güçlü hafızaya sahip olması geri beslemeli yapay sinir ağlarının tahmin yeteneğini güçlü ve uygun kılmaktadır (Aşık, 2013).

Yapay sinir ağlarında öğrenme, nöronların ağırlıklarının güncellenmesidir. Bu şekilde ağırlık katsayıları yapay sinir ağı tarafından öğrenilmektedir. Ağırlıkların güncellenmesinin artması ile öğrenme performansı da doğru orantılı artmaktadır. Ağırlıkların güncellenmesi işlemi kullanılan öğrenme algoritmasına göre şekillenmektedir. Danışmalı öğrenme algoritması, yapay sinir ağları bağımsız değişkenlerle ile bağımsız değişkenlerin sisteme gösterilmesiyle yapay sinir ağları tarafından üretilen çıktı değerine istinaden oluşan hata değerini minimize etmeye dayanmaktadır.

Hata değeri kabul edilebilir bir seviyeye ulaşınca kadar ağırlıklar güncellenerek yapay sinir ağının danışmana benzemesi sağlanır. Bu süreçte eğitim seti danışman görevindedir. Danışmasız öğrenme algoritması ise yapay sinir ağlarına sadece bağımsız değişkenlerin gösterilmesi ile çıktı üretilmesidir. Arzu edilen çıktı değerleri ağı gösterilmeden öğrenme sağlanmaktadır. Eğitim setinde sadece girdi değerleri yer almaktadır. Üretilen çıktılar ile desenler oluşturulur ve ağırlıklar bu desene göre güncellenerek her bir veri kümesi için vektör üretilir (Aşık, 2013).

3.1.2.3. Yapay sinir ağlarının öğrenme kuralları

Yapay sinir ağlarının öğrenme aşamasında ağırlıkların değişimini belirleyen matematiksel algoritmalara öğrenme kuralı denmektedir. Yapay sinir ağları için geliştirilen algoritma kuralları Hebb kuralı temel alınarak geliştirilmiş ve sayıları oldukça fazladır. Hebb kuralı, Hopfield kuralı, Delta kuralı, Kohonen kuralı ve Genelleştirilmiş Delta kuralı yapay sinir ağlarında temel öğrenme kurallarıdır (Aşık, 2013).

Hebb kuralında, bağlantılı sinyal alıcı ve gönderilici nöronların eş zamanlı aktivite olup olmamasına göre nöronların bağlantı ağırlığının artırılıp artırılmayacağı belirlenmektedir. Sinyal alıcı ve gönderici nöronlar eş zamanlı aktivite oluyorsa nöronlar arası bağlantı ağırlığı artırılırken, eş zamanlı aktivite yoksa bağlantı ağırlığı azaltılır.

Hopfield kuralında, bağlantılı sinyal alıcı ve göndericili nöronların eş zamanlı aktivite olup olmamasına göre bağlantılı ağırlığın değişiminin artırılıp azaltılmayacağı değişim miktarı ile belirtilmektedir. Burada belirtilen değişim miktarı öğrenme oranıdır.

Delta kuralında, Elde edilen çıktılar ile hedef yani istenilen çıktılar arasındaki fark minimuma ulaşınca kadar ağırlıklar değiştirilmektedir.

Kohonen kuralında, nöronlar arası rekabet söz konusudur. Tıpkı biyolojik öğrenmede olduğu gibi yarış halinde olan nöronlarda kazanan nöron ile bağlantı ağırlıkları değişimi gerçekleşir.

Genelleştirilmiş delta kuralında, bağlantı ağırlıkların değiştirilmesi, uygulanan delta kuralının genelleştirilerek geriye yayılım mantığında aktivasyon fonksiyonunun birinci türevinin alınması ile gerçekleşir.

3.1.2.4. Geri yayılım algoritması ve çok katmanlı algılayıcılar

Çok katmanlı ve katmanlar arası bağlantıları tam olarak danışmanlı ve ileri beslemeli olarak eğitimi gerçekleştirilen ağlara çok katmanlı algılayıcı (ÇKA) denmektedir. Çok katmanlı geriye beslemeli olan bu ağlarda, bir geri besleme noktası bulunmamakla beraber bilgi yayılımı geriye doğru gerçekleşerek öğrenme süreci işlenir. Doğrusal olmayan veri ilişkilerinin analizlerinde kullanılan en yaygın algoritma olmasına karşın en etkin sonuçların elde edilmesinde başarısı görülmektedir. Çok katmanlı yapıya sahip olan ÇKA modelinin en az üç katmanı bulunmaktadır. Bu katmanlar giriş katmanı, gizli katman ve çıkış katmanıdır. Çok katmanlı ağlarda, ağda yer alan bütün nöronların doğrusal olmaması ki bu sigmoid fonksiyonu ile gerçekleştirilir, gizli nöronların yer alması, ağ bağlantıları ortak ve ayırıcı özelliklerdir. ÇKA'larda danışmanlı öğrenme ile ileri besleme ve geri yayılım olmak üzere iki safhadan oluşan delta kuralı hakimdir (Sarı, 2016).

Geri yayılım ve çok katmanlı algılayıcıların temel yapısı ileri besleme ve geri yayılım aşamalarını içermektedir. İleri besleme aşamasında girdi katmanından ağa verilen verilerin çıktı katmanına doğru akışı gerçekleşmektedir. Böylece ağın çıktıları hesaplanmaktadır. İleri besleme aşamasında toplama fonksiyonu (Denklem 3.21) ile geri yayılım için gerekli olan sigmoid fonksiyonu (Denklem 3.16) uygulanmaktadır. (Aşık, 2013).

Geri yayılım aşamasında, ileri besleme aşamasında elde edilen çıktı değeri ile beklenen çıktı değeri arasındaki fark yani hata değerini minimize edilmesi için ağın geriye doğru

hareket ederek ağırlıkların güncellenmesidir. Çıktı katmanı için oluşan toplam hata Denklem 3.22 de verilmektedir (Aşık, 2013).

$$E_k = \frac{1}{2} \cdot \sum_{i=1}^n (y_i - t_i)^2 \quad (3.22)$$


Burada, n çıktı katmanındaki nöron sayısı, y üretilen çıktı değeri ve t istenilen çıktı değerini ifade etmektedir.

Hatanın minimum değerine ulaştırılması için güncellenen ağırlıklar delta kuralı ile ayarlanmaktadır. Ağın ağırlıkları, ara katman ile çıktı katman arasındaki ağırlığın güncellenmesi, gizli katmanlar arası veya gizli katman ile girdi katman arasındaki ağırlıkların güncellenmesi şeklinde olabilir.

Öğrenme oranı ve momentum katsayısı ağırlığın güncellenmesine etki eden en önemli faktörlerdir. Bir iterasyon ilk olarak ileri daha sonra geriye doğru hesaplamalar ile tamamlanır. Öğrenme tamamlanıncaya kadar işlemler devam eder.

3.1.3. Biyolojik Sinir Hücresi ile D-PNN ve YSA yapısına genel bakış

Biyolojik sinir hücresi, sinir sisteminin en temel işlem parçasıdır. Çekirdek, soma, akson, dendrit ve sinaps bir biyolojik sinir sisteminin başlıca yapı taşlarıdır. Dendritler, diğer sinir hücrelerinden sinapslara gelen bilgileri alan uzantılara verilen addır. Soma hücresi yani hücre gövdesi, dendritlerin topladığı bilgileri alarak işleyen ve işlenen bilgilerin eşik değerine ulaştığı an akson aracılığı ile diğer hücrelere ileten kısma verilen addır. Sinapslar ise akson ve diğer hücreler arası dendritlerin bağlantılarının sağlanmasında görevli birimlere verilen addır. Şekil 3.7.'te biyolojik sinir hücresi verilmiştir.



Şekil 3.7. Biyolojik sinir hücresi (www.erguvan.net)

En basit sinir sistemi yapısı sinir hücresi yani nöronlardır. Nöron hücreleri beyin ile vücudun hareket ilişkileri için bilgi alışverişi yaptığı kilit hücrelerdir. İnsan beyinde yaklaşık 10.000.000.000 sinir hücresi olduğu bilinirken bir hücreye düşen bağlantı sayısının 10.000 olduğu söylenmektedir. Bu bilgiler, insan beyninin diferansiyel polinom sinir ağı ve yapay sinir ağından daha karmaşık ve bilinmeyen yapısı olduğunu göstermektedir (Aşık, 2013).

Yapay sinir ağları, yapay sinir hücreleri ile biyolojik sinir ağı ve insan beyninin çalışma prensibini örnek alarak geliştirilen bilgi işleme merkezleridir. Bu nedenledir ki biyolojik sinir hücresinin işlem elemanlarının karşılığı yapay sinir hücre elemanları ile ilişkilendirilebilir.

Biyolojik sinir hücresindeki işlem parçalarının yapay sinir ağındaki karşılıkları daha önce anlatıldığı üzere özet şeklinde Tablo 3.1.'de verilmiştir.

Tablo 3.1. Biyolojik sinir sistemi ve YSA işlem elemanları (Sarı, 2016)

Biyolojik Sinir Sistemi	Yapay Sinir Ağı
Akson	Yapay nöron çıkışı
Nöron	İşlemci eleman
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Sinapslar	Ağırlıklar

Karmaşık problem ve sayısal hesaplama gerektiren durumlarda YSA, biyolojik ağlardan yani insanlardan hata yapma olasılığı göz önünde bulundurulduğunda daha üstün olmasına rağmen eksik bilgi durumunda değerlendirme, hata düzeltme, tanıma gibi olaylarda insan beyni daha üstündür (Aşık, 2013).

Diferansiyel polinom sinir ağıları, insan beyninin öğrenmesinde yer alan biyolojik sinir hücresinin işlevselliği ile geliştirilen ağ sistemidir. Diferansiyel polinom sinir ağıları, bilinmeyenler beyin gibi değişkenlerin mutlak değerlerini kullanmayarak göreceli değişkenleri kullanarak tanımlamaktadır. Diferansiyel polinom sinir ağının çalışmasındaki en küçük birim nöronların oluşturduğu bloklardır.

Biyolojik sinir hücresindeki işlem parçalarının D-PNN'deki karşılıkları özet şeklinde Tablo 3.2.'de verilmiştir.

Tablo 3.2. Biyolojik sinir sistemi ve DPNN işlem elemanları

Biyolojik Sinir Sistemi	Diferansiyel Polinom Sinir Ağı
Akson	Diferansiyel polinom nöron çıkışı
Nöron	İşlemci eleman
Dendrit	Diferansiyel denklem
Hücre gövdesi	Birleşik diferansiyel denklem
Sinapslar	Ağırlıklar

3.1.4. Çalışmada kullanılan istatistiksel değerlendirme yöntemleri

Talep tahmin çalışmalarında elde edilen değerlerin gerçek değerler ile karşılaştırılması, tekniklerin tahmin performansının kıyaslanması için istatistiksel deperlendirme yöntemlerine başvurulmaktadır. Hata karelerinin ortalamasının karekökü (RMSE), ortalama mutlak yüzde hata (MAPE) ve belirleme katsayısı (R^2) kullanılan değerlendirme yöntemlerinden başlıcalarıdır. Belirleme katsayısı (R^2) lineer korelasyon derecesini belirlemede önemli bir araçtır (Kaytez ve ark., 2015)

Çalışmada elde edilen test sonuçlarının gerçek değerler ile karşılaştırılması ve değerlendirilmesi hata karelerinin ortalamasının karekökü (RMSE), ortalama mutlak yüzde hata (MAPE) ve belirleme katsayısı (R^2) kullanılmıştır.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \bar{Y}_i|}{Y_i} \quad (3.23)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2 \quad (3.24)$$

Burada hesaplamaya girecek veri sayısını, $\bar{Y}_i$ değeri tahmin değerlerini ifade etmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y}_o)^2} \quad (3.25)$$

Burada hesaplamaya girecek veri sayısı, $\bar{Y}_i$ değeri tahmin değerlerini ve $\bar{Y}_o$ değeri gerçek değerlerin ortalamasını ifade etmektedir.

Bu denklemlerden elde edilen sonuçlar her iki yöntemin performansını değerlendirmede kullanılmıştır. Ayrıca söz konusu bağımsız değişkenler ile bağımlı değişken arasındaki ilişkiyi ölçmek adına korelasyon katsayısı (Denklem 3.26) hesaplanmıştır.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.26)$$

Burada x_i bağımsız değişkeni, $\bar{x}$ bağımsız değişken ortalamasını, y_i bağımlı değişkeni, $\bar{y}$ ise bağımlı değişken ortalamasını ifade etmektedir.

3.2. Elektrik Tüketim Tahmini Uygulaması

Elektrik enerjisinin talebini karşılayacak şekilde üretilmesi için kullanılan milli kaynakların uzun dönem esas alındığında yetersiz kalacağı noktada ithal enerji

kaynaklarının çeşitlendirilmesi veya yerli kaynakların artırılması planlarının yapılması için bir ülkenin yıllık elektrik enerjisi talebinin en doğru şekilde öngörülmesinin önemi arz güvenliği için kritik noktadır. Enerji politikalarının belirlenmesi için ülkenin yıllık elektrik talebinin tahmininde iki önemli yöntem ele alınmaktadır.

Türkiye'nin yıllık elektrik enerjisinin talebinin tahmini uygulaması, yıllık elektrik tüketim verileri ve elektrik tüketimine etki eden parametreler ile D-PNN yönteminin ve YSA yönteminin yazılımı bilgisayar paket programları ile yapılmıştır.

Bu bölümde kullanılan veri, D-PNN ve YSA yöntemleri ile Türkiye'nin yıllık elektrik enerjisi talep tahmininin uygulama aşamaları anlatılarak elde edilen tahminleme performansı test edilmiştir.

3.2.1. Uygulamada kullanılan veriler

Literatür incelendiğinde yapılan çalışmalarda elektrik talebinin tahmini için ele alınan bağımsız değişkenlerin her çalışma adına farklı kombinasyonlarının yapıldığı GSYH, ithalat, ihracat, nüfus, ve kurulu güç gibi değişkenlerin elektrik tüketimi için ele alınması gereken ve elektrik tüketimine doğrudan etkisi olan güvenilir parametreler olduğu anlaşılmıştır. Çalışmada kullanılan bağımsız değişkenlerin seçilme nedenleri ile birlikte kaynaklarının ayrıntıları Tablo 3.3.'te verilmiştir. Kullanılan bu parametreler Türkiye'nin elektrik enerjisinin talebine etki eden güvenilir parametrelerdir.

Uygulamada kullanılan değişkenler her iki yöntem için de D-Min-maks yöntemi (Denklem 3.19) ile normalize edilmiştir. Diferansiyel polinom sınır ağında normalizasyon ve denormalizasyon (Denklem 3.20) işlemleri program tarafından otomatik olarak hesaplandığı için veriler ham olarak sisteme tanımlanır. Yapay sinir ağlarında ise normalizasyon ve denormalizasyon işlemi veriler programa tanıtılmadan önce yapılmaktadır.

Tablo 3.3. Çalışmada ele alınan değişkenler

Değişken Adı	Değişken Seçilme Nedeni	Değişken kaynağı
Nüfus	Enerji tüketimi miktarı nüfusun değişimi ile değişim göstermektedir. Bu sebepten dolayı nüfus elektrik enerjisinin tahmininde bağımsız değişken olarak alınmıştır.	TÜİK
İthalat	Ticaret kavramlarından biri olan ithalat, ticaret aşamalarındaki enerji tüketiminde meydana getirdiği değişimler nedeniyle elektrik enerjisinin tahmininde bağımsız değişken olarak alınmıştır.	TÜİK
İhracat	Üretim, enerji tüketimini direkt etkileyen unsurlardan biridir. Ticaretin yani ihracatın artması üretimin dolayısı ile elektrik tüketiminin artmasına neden olur. Bu nedenle elektrik tüketiminin tahmininde bağımsız değişken olarak ele alınmıştır.	TÜİK
GSYH	GSYH, bir ülkenin büyümesini yansıtmaktadır. Bir ülkenin büyümesi ile o ülkede ekonomik faaliyetlerin artması ile elektriğe olan talebin de artması beklenir. Bu nedenle elektrik tüketiminin talebinin tahmininde bağımsız değişken olarak ele alınmıştır.	TÜİK
Kurulu Güç	Kurulu güç, elektrik enerjisi üretimi ve dolayısı ile tüketimine etki eden önemli faktörlerden biridir. Bu nedenle bağımsız değişken olarak ele alınmıştır.	TEİAŞ

Tablo 3.3.'te de görüleceği üzere çalışmada kullanılan değişkenlerin çoğu Türkiye İstatistik Kurumu (TÜİK) ve Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ)'tan alınan verilerden derlenerek kullanılmıştır. Uygulamaya alınan bağımlı değişken olan elektrik tüketim verilerinin bağımsız değişkenler ile ilişkileri korelasyon ile hesaplanmıştır ve ilgili değerler Tablo 3.4.'te verilmiştir. Korelasyon katsayısı Denklem 3.25'in karekökü alınarak hesaplanmıştır.

Tablo 3.4. Elektrik tüketimi ve girdi değişkenleri arasındaki korelasyon katsayısı

	Kurulu güç	Nüfus	GSYH	İhracat	İthalat
Korelasyon katsayısı	0,99	0,95	0,97	0,96	0,95

Literatürdeki birçok çalışmada elektrik tüketim tahmininde bağımsız değişken olarak alınan kurulu güç, nüfus, GSYH, ihracat ve ithalatın elektrik tüketim ile arasındaki ilişki korelasyon katsayısı ile değerlendirildiğinde tüm değişkenlerin elektrik tüketimi aralarında güçlü bir ilişki olduğu görülmüştür.

Kullanılan veri seti ise Tablo 3.5.'te sunulmuştur.

Tablo 3.5. Uygulamada kullanılan veriler

Yıl	Kurulu güç (Megawatt)	Nüfus (*1.000)	GSYH (1.000 000\$)	İhracat (1.000\$)	İthalat (1.000\$)	Enerji tüketimi (GWH)
1965	1.491	30.970	8.419	464	572	4.953
1966	1.644	31.720	9.997	491	718	5.576
1967	1.959	32.480	11.144	522	685	6.217
1968	1.967	33.260	18.008	496	764	6.936
1969	1.967	34.060	20.128	537	801	7.838
1970	2.235	34.880	18.825	588	948	8.623
1971	2.578	35.720	16.847	677	1.171	9.781
1972	2.711	36.590	21.319	885	1.563	11.242
1973	3.193	37.470	26.854	1.317	2.086	12.425
1974	3.732	38.370	36.985	1.532	3.778	13.477
1975	4.187	39.280	46.300	1.401	4.739	15.719
1976	4.364	40.190	52.996	1.960	5.129	18.615
1977	4.727	41.110	60.613	1.753	5.796	21.056
1978	4.869	42.040	66.277	2.288	4.599	22.347
1979	5.119	42.990	80.960	2.261	5.069	23.566
1980	5.119	43.980	67.457	2.910	7.909	24.616
1981	5.538	44.990	70.419	4.703	8.933	26.288
1982	6.639	46.030	63.485	5.746	8.843	28.325
1983	6.935	47.070	60.373	5.728	9.235	29.567
1984	8.462	48.110	58.643	7.134	10.757	33.267
1985	9.122	49.130	66.408	7.958	11.343	36.361
1986	10.115	50.130	75.018	7.457	11.105	40.471
1987	12.495	51.100	85.638	10.190	14.158	44.925
1988	14.521	52.050	90.495	11.662	14.335	48.430
1989	15.808	52.990	106.123	11.625	15.792	52.601
1990	16.318	53.920	149.195	12.959	22.302	56.812
1991	17.209	54.840	149.156	13.593	21.047	60.499
1992	18.716	55.750	156.656	14.715	22.871	67.217
1993	20.338	56.650	177.332	15.345	29.428	73.432
1994	20.860	57.560	131.639	18.106	23.270	77.783
1995	20.954	58.490	168.080	21.637	35.709	85.552
1996	21.249	59.420	181.077	23.224	43.627	94.789
1997	21.892	60.370	188.735	26.261	48.559	105.517
1998	23.354	61.330	270.947	26.974	45.921	114.023
1999	26.119	62.290	247.544	26.587	40.671	118.458
2000	27.264	63.240	265.384	27.775	54.503	128.276
2001	28.332	64.190	196.736	31.334	41.399	126.871
2002	31.846	65.140	230.494	36.059	51.554	132.553
2003	35.587	66.090	304.901	47.253	69.340	141.151
2004	36.824	67.010	390.387	63.167	97.540	150.018
2005	38.844	67.900	481.497	73.476	116.774	160.794
2006	40.565	68.760	526.429	85.535	139.576	174.637
2007	40.836	69.600	648.754	107.272	170.063	190.001
2008	41.817	70.440	742.094	132.027	201.964	198.085
2009	44.761	71.340	616.703	102.143	140.928	194.079
2010	49.524	72.327	731.608	113.883	185.544	210.434
2011	52.911	73.410	773.980	134.907	240.842	230.306
2012	57.059	74.570	786.283	152.462	236.545	242.370
2013	64.008	75.788	823.044	151.803	251.661	246.357
2014	69.520	77.031	799.370	157.610	242.177	257.220
2015	73.147	78.272	719.620	143.839	207.234	265.724
2016	78.497	79.513	745.304	142.530	198.618	279.286

3.2.2. Diferansiyel polinom sinir ağı ile tahmin uygulaması

Yapay zeka tekniklerinin yeni bir çeşidi olan Diferansiyel Polinom Sinir Ağları ile Türkiye'nin yıllık elektrik tüketiminin tahmini için 1965-2016 yılları arasındaki 52 adet veri kullanılmaktadır. 1965-2001 yıllarına ait 37 adet veri ağı eğitimi için, 2002-2016 yıllarına ait 15 adet veri ağı testi için kullanılmaktadır. Ağa tanımlanan verilerin normalizasyonu yazılımın içerisinde var olan D-Min-Maks yöntemi ile otomatik olarak yapılmıştır. Ağ yapısı girdi katmanı, gizli katmanlar ve çıktı katmanı şeklindedir. Girdi katmanında ağa tanımlanan 5 bağımsız değişken yer almaktadır. 5 bağımsız değişkenden dolayı ağ yapısına en uygun olduğu için 5 gizli katman ve her gizli katmanda bir önceki ağdan bir sonraki ağa girdi olarak gelen değişkenlerin ikili kombinasyonlarının olduğu bloklar yer almaktadır. Çıktı katmanında ise tek blok yer almaktadır. Gizli katmanda yer alan blokların sayısı problemin yapısına göre değişkenlik göstermektedir. Ancak ikili kombinasyonlu yapısı nedeniyle minimum olması gereken blok sayısı 3'tür. Uygulamada 5 bağımsız değişken kullanıldığı için maksimum blok sayısı 10 olmalıdır. Ağı en ideal değerlerini belirlerken bu parametre deneme yanılma ile bulunacaktır.

Eğitim ve test için veriler ağa sunularak her iterasyon için hesaplanan hata değeri hata karelerinin ortalamasının karekökü (RMSE) ve ortalama yüzde mutlak hata (MAPE) formülleri ile hesaplanarak en küçük hata değerini veren ağ model olarak alınmış, bu ağa göre test değerleri hesaplatılmıştır.

Ağın çalışma prensibi gereği iterasyon sayısına müdahale edilememektedir. Ağın eğitiminde ve testinde ağ çalışmaya başladığında her 1000 iterasyonda eğitim gerçekleşmekte ve her 1000. İterasyonda test aşaması olmaktadır. Eğitim hata değerinin minimum değeri ile her iterasyonun hata değeri kıyaslanmakta; daha düşük değer elde edildiğinde hafızaya alınmaktadır. Daha yüksek hata değeri ile karşılaşıyorsa eğitim parametreleri güncellenmektedir. Optimum değer ise her iterasyonda elde edilen hata değerlerinin minimumu yakaladığı nokta olmaktadır. Bu nedenle çevrim sayısı belirlenmesi gereken parametrelerden olmamaktadır. Gizli katman sayısı belirlenmesi gereken parametrelerden biridir ve girdi sayısı ile aynı

olmalıdır. Uygulamada 5 bağımsız değişken kullanıldığı için gizli katman sayısı da 5 olarak ayarlanmıştır. Geriye doğru yapısından dolayı sigmoid fonksiyonu da etkin hale getirilmiştir. Belirlenmesi gereken diğer bir parametre başlangıç öğrenme oranıdır. Bu oran her bir iterasyonda iterasyon yapısına göre otomatik olarak azalım göstermektedir. Başlangıç öğrenme oranı 0,01 ile 0,5 arasında denemeler ile en uygun değeri 0,5 öğrenme oranı verdiği için bu değer alınmıştır.

Diferansiyel polinom sinir ağı programı bilgisayar paket programı kullanılarak geliştirilmiştir. Uygulamaya alınan 5 girdi ve 1 çıktı değeri .txt uzantılı dosyaya kaydedilir. Dosyanın ilk satırında veri sayısı ve girdi değişken sayısı, programın datayı doğru alabilmesi için mutlaka yazılmalıdır. Verilerin .txt uzantılı dosyaya yazılma formatı Şekil 3.8.'de gösterilmektedir. Toplam veri sayısı 52'dir. Programa %70 eğitim, %30 test olarak tanımlandığı için 52 satırdan 37 satırını eğitim olarak geri kalan satırları ise test olarak alacaktır. En sağ sütunda yer alan elektrik tüketim yani çıktı verisi ise eğitim ve test sırasında elde edilen çıktı ile aradaki farkı bularak hata değerinin hesaplanmasını sağlayabilmek adına programa verilmektedir. Daha önce de belirtildiği üzere veriler ham hali ile programa verilir ve program ham verilerin normalizasyon işlemini yaparak eğitim ve test aşamalarını gerçekleştirerek tekrar veriyi ham haline dönüştürüp bizlere sunar.

uygulamaveri.txt - Not Dettin

Dosya	Düzen	Biçim	Görünüm	Yardım	
52	5				
1.491	30.970	8.419	464	572	4.953
1.644	31.720	9.997	491	718	5.576
1.959	32.480	11.144	522	685	6.217
1.967	33.260	18.008	496	764	6.936
1.967	34.060	20.128	537	801	7.838
2.235	34.880	18.825	588	948	8.623
2.578	35.720	16.847	677	1.171	9.781
2.711	36.590	21.319	885	1.563	11.242
3.193	37.470	26.854	1.317	2.086	12.425
3.732	38.370	36.985	1.532	3.778	13.477
4.187	39.280	46.300	1.401	4.739	15.719
4.364	40.190	52.996	1.960	5.129	18.615
4.727	41.110	60.613	1.753	5.796	21.056
4.869	42.040	66.277	2.288	4.599	22.347
5.119	42.990	80.960	2.261	5.069	23.566
5.119	43.980	67.457	2.910	7.909	24.616
5.538	44.990	70.419	4.703	8.933	26.288
6.639	46.030	63.485	5.746	8.843	28.325
6.935	47.070	60.373	5.728	9.235	29.567
8.462	48.110	58.643	7.134	10.757	33.267
9.122	49.130	66.408	7.958	11.343	36.361
10.115	50.130	75.018	7.457	11.105	40.471
12.495	51.100	85.638	10.190	14.158	44.925
14.521	52.050	90.495	11.662	14.335	48.430
15.808	52.990	106.123	11.625	15.792	52.601
16.318	53.920	149.195	12.959	22.302	56.812
17.209	54.840	149.156	13.593	21.047	60.499
18.716	55.750	156.656	14.715	22.871	67.217
20.338	56.650	177.332	15.345	29.428	73.432
20.860	57.560	131.639	18.106	23.270	77.783
20.954	58.490	168.080	21.637	35.709	85.552
21.249	59.420	181.077	23.224	43.627	94.789
21.892	60.370	188.735	26.261	48.559	105.517
23.354	61.330	270.947	26.974	45.921	114.023
26.119	62.290	247.544	26.587	40.671	118.458
27.264	63.240	265.384	27.775	54.503	128.276
28.332	64.190	196.736	31.334	41.399	126.571
31.846	65.140	230.494	36.059	51.554	132.553
35.587	66.090	304.901	47.253	69.340	141.151
36.824	67.010	390.387	63.167	97.540	150.018
38.844	67.900	481.497	73.476	116.774	160.794
40.565	68.760	526.429	85.535	139.576	174.637
40.836	69.600	648.754	107.272	170.063	190.001
41.817	70.440	742.094	132.027	201.964	198.085

Şekil 3.8. Verilerin programa transferini gerçekleştiren .txt uzantılı dosya

Verilerin belirlenmesinden sonra paket programda ayarlanması gereken ve daha önce de anlatılan parametreler ayarlanmıştır. Deneme yanılma ile ayarlanması gereken blok sayısının optimum sonuç verdiği değer 8 olduğu için her katmandaki blok değeri 8, başlangıç öğrenme katsayısı 0,5 olarak alınmıştır. Daha sonra program çalıştırılmıştır.

3.2.3. Yapay sinir ağı ile tahmin uygulaması


Elektrik tüketimine doğrudan etkisi olan veriler yapay sinir ağı uygulamasında tanıtılmak üzere D-Min-Maks yöntemi (Denklem 3.21) ile normalizasyon işlemi yapılmıştır. Normalizasyon işleminden sonra uygulamanın yapıldığı bilgisayar paket programına veriler işlenmiştir. Verilerin ilk 37'si eğitim için, kalan 15'i ise test için ayrılmıştır. Şekil 3.9.'da programa işlenmek üzere hazırlanan eğitim girdi verileri yer almaktadır.

0.1000	0.1016	0.1049	0.1049	0.1050	0.1077	0.1113	0.1127	0.1177	0.1233	0.1280
0.1299	0.1336	0.1351	0.1377	0.1377	0.1420	0.1535	0.1566	0.1724	0.1793	0.1896
0.2143	0.2354	0.2487	0.2540	0.2633	0.2790	0.2958	0.3012	0.3022	0.3053	0.3119
0.3271	0.3559	0.3678	0.3789	0.1000	0.1124	0.1249	0.1377	0.1509	0.1644	0.1783
0.1926	0.2071	0.2220	0.2370	0.2519	0.2671	0.2824	0.2981	0.3144	0.3311	0.3482
0.3653	0.3825	0.3993	0.4158	0.4317	0.4474	0.4629	0.4782	0.4934	0.5084	0.5232
0.5382	0.5535	0.5689	0.5845	0.6003	0.6162	0.6318	0.6475	0.1000	0.1016	0.1026
0.1093	0.1114	0.1101	0.1082	0.1125	0.1179	0.1278	0.1368	0.1433	0.1507	0.1562
0.1705	0.1574	0.1603	0.1535	0.1505	0.1488	0.1564	0.1647	0.1751	0.1798	0.1950
0.2368	0.2368	0.2441	0.2642	0.2198	0.2552	0.2678	0.2753	0.3552	0.3324	0.3498
0.2830	0.1000	0.1001	0.1003	0.1002	0.1004	0.1006	0.1011	0.1021	0.1043	0.1054
0.1048	0.1076	0.1065	0.1093	0.1091	0.1124	0.1215	0.1268	0.1267	0.1339	0.1380
0.1355	0.1494	0.1568	0.1567	0.1634	0.1666	0.1723	0.1755	0.1895	0.2075	0.2155
0.2309	0.2346	0.2326	0.2386	0.2567	0.1000	0.1005	0.1004	0.1006	0.1007	0.1012
0.1019	0.1032	0.1048	0.1102	0.1133	0.1145	0.1166	0.1128	0.1143	0.1234	0.1266
0.1264	0.1276	0.1325	0.1343	0.1336	0.1433	0.1439	0.1485	0.1692	0.1652	0.1710
0.1919	0.1723	0.2120	0.2372	0.2529	0.2445	0.2278	0.2718	0.2301		

Şekil 3.9. Paket programa işlenmek üzere hazırlanan eğitim girdi verileri

Veri girişinin tamamlanmasından sonra ağı oluşturulması gerçekleştirilmiştir. Uygulama ileri beslemeli geri yayılım ağı ile gerçekleştirilmiştir. Eğitim fonksiyonu olarak momentum kullanarak gradyant düşürme (traingdm), adaptasyon öğrenme fonksiyonu olarak geriye yayılım ağırlıklı (learnngdm) fonksiyon kullanılmıştır. Deneme yanılma ile en iyi sonuçları veren tek gizli katman ile uygulama yapılmıştır. Transfer fonksiyonlarından en iyi sonucu veren sigmoid fonksiyonu içeren logsig

fonksiyonu uygulamada kullanılmıştır. Uygulama model yapısı Şekil 3.10.'da verilmiştir. Model 5 girdi ve 1 çıktı şeklindedir.



Şekil 3.10. Uygulama model yapısı

Deneme yanılma yöntemi ile optimal öğrenme katsayısı 0.7, momentum katsayısı 0.6, çevrim sayısı 3.250, nöron sayısı 5 ve gizli hücre sayısı 4 olarak belirlenmiştir.

BÖLÜM 4. BULGULAR VE TARTIŞMA

4.1. Diferansiyel Polinom Sinir Ağı ile Elektrik Tüketim Tahmini

Deneme yanılma ile belirlenen parametreler ile programın çalıştırılması gerçekleştirilmiştir. Şekil 4.1.'de programın çalıştırılmasından sonra her blokta oluşan nöron sayısı, toplam blok sayısı, sütun veri aralıkları ve her katmanda yer alan blokların aktif ve pasif olmasına göre nöron durumları belirtilmektedir.

```
37 15
Number of Layers = 5    Combinations in neurons = 3
Layer #1: Number of blocks = 8 Neurons = 5
Layer #2: Number of blocks = 8 Neurons = 15
Layer #3: Number of blocks = 8 Neurons = 35
Layer #4: Number of blocks = 8 Neurons = 75
Layer #5: Number of blocks = 8 Neurons = 155
Total number of blocks = 40 Neurons = 2280

Data columns ranges:
1.491->78.497  30.97->79.513  0.419->023.044  1.317->085  1.171->948  4.953->279
.286

Layer 1:      Number of Blocks = 8
#1 -> 1  2  1 2  : 1.04 1.01 1.19 0.5 0.78 0.61
1 1 1 0 1
#2 -> 1  3  1 3  : 1.46 0.73 0.57 1.23 0.68 1.44
0 1 0 0 1
#3 -> 3  5  3 5  : 1.31 0.82 1.11 1.37 1.19 0.75
1 1 1 0 1
#4 -> 2  3  2 3  : 0.61 1.04 1.46 1.19 1.34 0.59
0 1 0 0 1
#5 -> 1  5  1 5  : 1.11 0.98 0.94 1.44 0.97 0.56
0 1 0 0 1
```

Şekil 4.1. Oluşan ağı yapısı


Şekil 4.1.'de görülebileceği üzere her katmanda 8 blok ve 5 katman yer almaktadır. 1. Katmanda 5 nöron, 2.katmanda 15 nöron, 3. Katmanda 35 nöron, 4.katmanda 75 nöron ve 5.katmanda 155 nöron oluşmuştur. Her değişken sütununda yer alan verilerden minimum ve maksimum değerler de Şekil 4.1.'de yer almaktadır.

Eğitim ve testi gerçekleşen verilerin optimum test sonuçları Şekil 4.2.'de yer almaktadır. Çalışmada hata karelerinin ortalamasının karekökü (RMSE), ortalama mutlak yüzde hata (MAPE) ve R^2 performans ölçütleri kullanılmıştır. Elde edilen hata değerlerinden RMSE değeri 8.653, MAPE değeri % 3,04' tür.

†1	->	132.553	-	138.691
†2	->	141.151	-	143.786
†3	->	150.018	-	147.819
†4	->	160.794	-	150.572
†5	->	174.637	-	169.057
†6	->	190.001	-	192.046
†7	->	198.085	-	210.735
†8	->	194.079	-	197.276
†9	->	210.434	-	222.535
†10	->	230.306	-	233.472
†11	->	242.37	-	241.035
†12	->	246.357	-	251.168
†13	->	257.22	-	254.483
†14	->	265.724	-	250.79
†15	->	279.286	-	250.043


Şekil 4.2. Optimum test sonuçları

Teste ayrılan 15 gerçek veri ve çalışma sonucunda elde edilen test değerleri Şekil 4.3.'de yer almaktadır.



Şekil 4.3. Test gerçek değerleri ve D-PNN test değerlerinin kıyaslanması


2002 ile 2016 yılları gerçekleşen elektrik tüketim değerleri ile D-PNN tekniği ile elde edilen tüketim tahmin değerlerinin saçılım grafiği Şekil 4.4'te verilmiştir. Denklem 3.25.'ten hesaplanan belirleme yani determinasyon katsayısı da grafikten de görüldüğü üzere 0,96 olarak elde edilmiştir.



Şekil 4.4. Test gerçek değerleri ve D-PNN test değerlerinin dağılım grafiği

4.2. Yapay Sinir Ağı ile Elektrik Tüketim Tahmini


Deneme yanılma yöntemi ile elde edilen parametreler alınarak gerçekleştirilen eğitim ve test sonucunda verilerin optimum test sonuçları ve gerçek değerler Şekil 4.5.'te yer almaktadır.



Şekil 4.5. Gerçek test seti ve YSA test değerlerinin kıyaslanması

Çalışmada hata karelerinin ortalamasının karekökü (RMSE), ortalama mutlak yüzde hata (MAPE) ve R^2 performans ölçütleri kullanılmıştır. Elde edilen hata değerlerinden RMSE değeri 18.225, MAPE değeri % 7,36 'dır. Şekil 4.6.'da gerçek tüketim değerleri

ile test sonucunda elde edilen değerin saçılım grafiği yer almaktadır. Bu grafikten de görülebileceği üzere R^2 değeri ise 0,84' tür.



Şekil 4.6. Gerçek test seti ve YSA test değerlerinin dağılım grafiği

BÖLÜM 5. SONUÇLAR VE ÖNERİLER

Enerji sektöründe üretim, talebin karşılanması ve ekonomi için tahminleme oldukça önemlidir. Elektrik enerjisi ülke ekonomisini ve kalkınmasını yansıtan faktör olmakla beraber depolanamıyor olması nedeniyle elektrik enerjisi sektöründe tahminlerin doğru bir şekilde yapılması kaynakların doğru bir şekilde yapılmasını gerektirir. Yapılan tahminlerin doğruluğu ise planlama çalışmalarının geçerliliğine doğrudan etki ederek arz-talep ilişkisini doğru bir şekilde yönetilmesini sağlayacaktır.

Yapay zeka teknikleri, lineer ilişki bulunmayan değişkenlere bağlı problemlerin çözümünde diğer yöntemlere kıyasla etkili sonuçlar vermektedir. Bu nedenle bu çalışmada Türkiye'nin elektrik enerjisi tüketimi tahmini, yapay zeka sınıfının yeni bir sınıfını oluşturan D-PNN ve başarısı literatürde birçok çalışmada geçerliliği sunulan YSA ile yapılmıştır. Bir ülkenin elektrik enerjisi tüketimine etki eden GSYH, ithalat, ihracat, kurulu güç ve nüfus bağımsız değişkenleri ele alınarak elektrik enerjisi tüketimi tahmini her iki yöntem ile yapılmıştır.

Çalışmada 1965-2016 yılları arasındaki veriler ele alınarak 1965-2001 yıllara ait veriler eğitim verisi, 2002-2016 yıllara ait veriler ise test verisi olarak işlenmiştir. 2002-2016 yılları için her iki yöntemle elde edilen tahmin değerleri gerçekleşen optimum değerler ile analiz edildiğinde elde edilen tüketim değerleri Tablo 5.1.'de verilmiştir.


Elde edilen sonuçlar ve performans değerleri gözetildiğinde, D-PNN yöntemi ile elde edilen değerlerin YSA ile elde edilen değerlerden gerçekleşen değerlere daha yakın olduğu tespit edilmiştir. Yapılan çalışma neticesinde elde edilen analiz değerlerinde

D-PNN metodunun YSA metodu gibi kabul edilebilir ve yüksek doğrulukta tahminler gerçekleştirebildiği saptanmıştır.

Tablo 5.1. Türkiye elektrik enerjisi gerçekleşen ve tahmin tüketim değerleri

Yıllar	Gerçekleşen (GWH)	YSA Tahmin (GWH)	D-PNN tahmin (GWH)
2002	132.553	128.010	138.691
2003	141.151	143.189	143.786
2004	150.018	146.748	147.819
2005	160.794	150.005	158.572
2006	174.637	163.442	169.057
2007	190.001	163.586	192.046
2008	198.085	184.381	210.735
2009	194.079	181.276	197.276
2010	210.434	193.211	222.535
2011	230.306	210.992	233.472
2012	242.370	217.305	241.035
2013	246.357	228.663	251.168
2014	257.220	232.194	254.483
2015	265.724	244.633	250.790
2016	279.286	248.087	258.043

Mevcut tüketim değerleri ile test için ayrılmış olan ilgili yıla ait D-PNN ve YSA teknikleri ile elde edilen tahmin değerlerinin grafiği Şekil 5.1.'de verilmiştir.



Şekil 5.1. Türkiye elektrik enerjisi tüketim modellerinin karşılaştırılması

Uygulama sonucu elde edilen test kümesinin istatistiksel yöntemlerle performansları hesaplanmıştır. Tablo 5.2.'de uygulama sonucunda elde edilen değerlerin gerçekleşen değerlerle ölçülmesinden elde edilen değerler yer almaktadır.

Tablo 5.2. Modellerin istatistiksel sonuçları

RMSE	MAPE(%)	R^2
------	---------	-------

D-PNN	8.653	3,04	0,96
YSA	18.225	7,36	0,84

Kaytez ve ark. (2015) elektrik tüketim tahmini üzerine yaptıkları çalışmada 1970-2009 yıllarına ait verileri %70 eğitim, %30 teste ayırarak gerçekleştirmişlerdir. YSA yöntemi ile elde ettikleri MAPE ve R^2 değeri sırasıyla 1,19 , 0,99 olmuştur. Çalışmamızda D-PNN tekniği ile elde edilen değerler sırasıyla 3,04 ve 0,96 ; YSA tekniği ile elde edilen değerler ise sırasıyla 7,36 ve 0,84'tür. Bu farklılık çalışmaya konu olan veri yılı aralıklarının farklı olması veya bağımsız değişkenlerin farklılığından kaynaklanabilir.

İleriye dönük yapılacak yeni çalışmalarda çeşitli mimariye sahip YSA modelleri ve tahmin performansı açısından değerlendirilebilecek diğer tahmin yöntemleri ile tahmin çalışması yapılarak yöntemler arası performanslar irdelenebilir.

KAYNAKLAR

- Ardakani, F. J., Ardehali, M. M., 2014a. Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. *Energy Conversion and Management* 78 (1):745–752.
- Ardakani, F.J., Ardehali, M.M., 2014b. Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types. *Energy* 65(1):452-461.
- Aşık, E., 2013. Lokal Jeoit Belirlemede Yapay Sinir Ağları Ve Kriging Yöntemlerinin Karşılaştırılması. Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Başoğlu, B., Bulut, M., 2017. Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Mühendislik Mimarlık Fakültesi Dergisi* 32(2):575-583.
- Bayraç, H. N., 2011. Küresel Rüzgar Enerjisi Politikaları ve Uygulamaları, Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 30(1):37-57.
- Berneti, S.M., 2016. Optimal design of adaptive neuro-fuzzy inference system using genetic algorithm for electricity demand forecasting in Iranian industry. *Soft Comput* 20(1):4897–490.
- Bilgili, M., 2009. Estimation of net electricity consumption of Turkey. *Journal of Thermal Science and Technology* 29(2):89-98.
- Boltürk, E., 2013. Elektrik talebi tahmininde kullanılan yöntemlerin karşılaştırılması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Chang, P.C., Fan, C.Y., Lin, J. J., 2011. Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach. *Electrical Power and Energy Systems* 33(1):17-27.
- Demirel, Ö., Kakilli, A., Tektaş, M., 2010. ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Dergisi* 25(3):601-610.
- Durmuşoğlu, S., 2016. 21.Yüzyılın Enerji Denklemi ve Türkiye, İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi, 29(2): 283-303.

- Es, H. A., Kalender, F.Y., Hamzaçebi. C., 2017. Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini. Gazi Üniversitesi Mühendislik Fakültesi Dergisi, 23(3):495-504.
- Geem, Z.W., Roper, W.E., 2009. Energy demand estimation of South Korea using artificial neural network. Energy Policy 37(1):4049-4054.
- Hussain, A., Rahman, M., Memon, J.A., 2016. Forecasting electricity consumption in Pakistan: the way forward. Energy Policy 90(1):73–80.
- İçen, D., Günay, S., 2014. Uzman sistemler ve istatistik. İstatistik ile Aktüerya 7 (1): 37-45.
- İşçi, Ö., Korukoğlu, S., 2003. Genetik algoritma yaklaşımı ve yöneylem araştırmasında bir uygulama. Yönetim ve Ekonomi, 10(2):191-208.
- Kaboli, S.H.A., Selvaraj, J., Rahim, N.A., 2016. Long-term electric energy consumpition forecasting via artificial cooperative search algorithm. Energy 115(1):857-871.
- Karabulut, K., Alkan, A., Yılmaz, A.S., 2008. Long term energy consumption forecasting using Genetic Programming. Mathematical and Computational Applications 13(2):71-80.
- Karaca, C., Karacan, H., 2016. Çoklu regresyon metoduyla elektrik tüketim talebini etkileyen faktörlerin incelenmesi. Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi 4(3):182-195.
- Kaynar, O., Taştan, S., 2009. Zaman serisi analizinde mlp yapay sinir ağları ve arıma modelinin karşılaştırılması. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 33(2):161-172.
- Kaytez, F., Taplamacioglu, M.C., Cam, E., Hardalac, F., 2015. Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines. Electrical Power and Energy Systems 67(1): 431–438.
- Kılıç, G., 2015. Yapay Sinir Ağları İle Yemekhane Günlük Talep Tahmini, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Mestekemper, T., Kauermann, G., Smith, M.S., 2013. A comparison of periodic autoregressive and dynamic factor models in intraday energy demand forecasting. International Journal of Forecasting 20(1):1-12.
- Pao, H.T., 2009. Forecasting energy consumption in Taiwan using hybrid nonlinear models. Energy 34(1):1438-1446.

- Saraç, E., 2012. Yapay Sinir Ağları Metodu İle Gayrimenkul Değerleme, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Sarı, M., 2016. Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Yöneylem Araştırması Bilim Dalı, Yüksek Lisans Tezi.
- Srinivasan, D., 2008. Energy demand prediction using GMDH Networks. *Neurocomputing* 72 (1):625–629.
- Suhono, A., Sarjiya, A., 2014. Long-term electricity demand forecasting of Sumatera system based on electricity consumption intensity and Indonesia population projection 2010-2035. *Energy Procedia* 68(1):455-462.
- TEİAŞ, Türkiye Elektrik Üretim İstatistikleri, <https://teias.gov.tr/tr/turkiye-elektrik-uretim-iletim-istatistikleri/2015>, Erişim Tarihi: 18.07.2017.
- Türkay, B.E., 2015. Türkiye'nin uzun dönem puant yük talebinin ve enerji ihtiyacının tahmin edilmesi. *Elektrik Mühendisliği*, 453(1):31-33.
- Verdejo, H., Awerkin, A., Becker, C., Olguin, G., 2017. Statistic linear parametric techniques for residential electric energy demand forecasting, A review and an implementation to Chile. *Renewable and Sustainable Energy Reviews* 74(1):512-521.
- Yavuzdemir, M., 2014. Türkiye'nin Kısa Dönem Yıllık Brüt Elektrik Enerjisi Talep Tahmini. Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Yüksek Lisans Tezi.
- Yılmaz, M., 2012. Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi* 4(2):33-54.
- Yigit, V., 2011. Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini. *International Journal of Engineering Research and Development*, 3(2):37-41.
- Zjavka, L., 2010. Learning simple dependencies by polynomial neural network. *Journal of Information, Control and Management Systems*, 8(3): 285-296.
- Zjavka, L., 2011. Construction and adjustment of differential polynomial neural network. *Journal of Engineering and Computer Innovations*, 2(3): 40-50.
- Zjavka, L., Pedrycz, W., 2016. Constructing general partial differential equations using polynomial and neural Networks. *Neural Networks*, 73 (1): 58–69.

Xiao, L., Wang, J., Dong, Y., Wu, J., 2015. Combined forecasting models for wind energy forecasting:A case study in China. Renewable and Sustainable Energy Reviews 44(1):271-288.

www.erguvan.net/ Eriřim Tarihi:05.04.2017.

www.teias.gov.tr/ Eriřim Tarihi:15.07.2017.

www.tuik.gov.tr/ Eriřim Tarihi:10.06.2017.



ÖZGEÇMİŞ

Ecem Bayar, 01.11.1992 tarihinde İstanbul’da doğdu. İlk, orta ve lise eğitimini İstanbul’da tamamladı. 2011 yılında Küçükçekmece Anadolu Lisesi’nde Fen Bilimleri dalından mezun oldu. 2011 yılında başladığı Sakarya Üniversitesi Endüstri Mühendisliği bölümünü 2015 yılında bitirdi. 2016 yılında başladığı Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Endüstri Mühendisliği Bölümü’nde halen yüksek lisans öğrencisidir. 2017-2018 yılları arasında Flo Mağazacılık ve Pazarlama A.Ş. firmasında ürün yönetimi departmanında görev yaptı. Şuanda DeFacto Perekende Tic. A.Ş.firmasında Tedarik Uzmanı olarak görev yapmaktadır.

