

T.C.
İZMİR DEMOKRASİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Yüksek Lisans Tezi
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Elektrik-Elektronik Mühendisliği Bilim Dalı

**Sembolik Regresyon Temelli Öznitelik Çıkarımı ile Yüksek
Mertebeden Sinir Ağı Tasarımı: Elektrik Tüketim Tahmini**

Senem YILDIZ

Danışman
Doç. Dr. Selami BEYHAN



İZMİR-2022

İçindekiler

1 Giriş	9
1.1 Enerji Tüketim Verisi	9
1.1.1 Zaman Serisi Tahminleme	9
1.2 Literatür Özeti	11
1.2.1 Enerji Tüketim Tahminlemesi	11
1.2.1.1 Literatürde Elektrik Enerjisi Tüketimi Tahminlenmesine Yönelik Çalışmalar	18
2 Kullanılan Metotlar	26
2.1 Yapay Sinir Ağları	26
2.1.1 Standart Yapay Sinir Ağı	27
2.1.2 Yüksek Mertebeden Yapay Sinir Ağları	28
2.1.2.1 Pi-Sigma Sinir Ağları	32
2.1.2.2 Sigma-Pi Sinir Ağları	35
2.2 Regresyon Yöntemleri	39
2.2.1 Sembolik Regresyon Yöntemi	39
2.3 Parametre Optimizasyon Yöntemi	43
2.3.1 Levenberg-Marquardt Yöntemi	45
2.4 Önerilen Öznitelik Çıkarımı Temelli Modeller	46
2.4.1 Sembolik Resresyon Temelli Yapay Sinir Ağları	47
2.4.2 Sembolik Resresyon Temelli Sigma-Pi Sinir Ağları	49
2.4.3 Sembolik Resresyon Temelli Pi-Sigma Sinir Ağları	50
3 Benzetim Çalışmaları	51
3.1 Öznitelik Çıkarımı Kullanılmadan Elde Edilen Sonuçlar	53
3.2 Öznitelik Çıkarımı Kullanılarak Elde Edilen Sonuçlar	56
4 Sonuçların Değerlendirilmesi ve Gelecek Çalışmalar	58

TEŞEKKÜR

Çalışmanın her aşamasında bana destek olan, bilgi ve deneyimleri ile yol gösteren danışman hocam Sayın Doç. Dr. Selami Beyhan’a, gerek veri seti sağlama konusunda gerek çalışma izinlerim konusunda desteğini eksik etmeyen müdürlerim Serkan Kaba, Evren Yunusoğlu’na ve KLEMSAN firmasına, çalışmalarım sırasında manevi desteğini her zaman hissettiğim değerli arkadaşım Matematik Öğretmeni Kübra Kaptanoğlu’na, öğrenim hayatım boyunca beni maddi ve manevi olarak destekleyen ve hep yanımda olan aileme yürekten teşekkür ederim.

Senem YILDIZ
İZMİR, 2022

Özet

Yüksek Lisans Tezi

Sembolik Regresyon Temelli Öznitelik Çıkarımı ile Yüksek Mertebeden Sinir

Ağı Tasarımı: Elektrik Tüketim Tahmini

Senem YILDIZ

İzmir Demokrasi Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği AnaBilim Dalı

Danışman: Doç. Dr. Selami BEYHAN

Teknolojinin gelişmesiyle birlikte endüstride ve akademide verilerin depolanması büyük ölçüde kolaylaşmış olup işlenebilirliği de önem kazanmıştır. Bu veriler kullanılarak sistemlerin modellenmesi ile kestirim, hassas kontrol, hata teşhisi gibi çalışmalar yapılmaktadır. Örnek olarak elektrik tüketim verilerinin tahmin edilmesi kolay olmayan ama tahmin edildiğinde önceden üretim miktarının belirlenmesini ve gereksiz tüketimin önüne geçilmesini sağlayacak bilgiler içerir. Şimdiye kadar bu güçlü veriyi işlemek için farklı yöntemler kullanılmış ancak yeterli performanslar elde edilememiştir. Bu tez çalışmasında, elektrik tüketim verisinden sembolik regresyon yöntemi ile özniteliklerin çıkarımı yapılmakta ve bu öznitelikler kullanılarak tek katmanlı sinir ağları ile tahminleme yapılmaktadır. Temel amaç, tasarlanan modelleri karşılaştırmak değil az parametrelili yapay sinir ağı modellerinin performansını, öznitelik çıkarımı ile artırmak ve yüksek başarımlı tahmin sonuçları elde etmektir. Elde edilen tahmin sonuçları, öznitelik çıkarımı olmadan elde edilen sonuçlar ile karşılaştırılmıştır.

Anahtar Kelimeler: Yüksek mertebeden sinir ağı, öznitelik çıkarımı, sembolik regresyon, elektrik tüketim tahmini.

Abstract

M. Sc. Thesis

High-Order Neural Network Design with Symbolic Regression Based Feature Extraction: Electricity Consumption Forecasting

Senem YILDIZ

Izmir Demokrasi University

**Graduate School of Applied and Natural Sciences Department of Electric and
Electronics Engineering**

Supervisor: Assoc. Prof. Dr. Selami BEYHAN

With the development of technology, the storage of data in industry and academia has become much easier and its workability has gained importance. By using these data, studies such as prediction, precise control and fault diagnosis are carried out by modelling the systems. For instance, electricity consumption data contains information that is not easy to predict, but when it is predicted, it will enable to determine the amount of production in advance and to prevent unnecessary consumption. So far, different methods have been used to process this powerful data, but sufficient performances have not been achieved. In this thesis, features are extracted from electricity consumption data with symbolic regression method and prediction is made with single-layer neural-networks using these features. The main purpose is not to compare the designed models, but to increase the performance of artificial neural network models with few parameters by feature extraction and to obtain high performance prediction results. The prediction results obtained were compared with the results obtained without feature extraction.

Keywords: Higher-order neural-networks, feature extraction, symbolic regression, prediction of electricity consumption.

Acronyms

ARFIMA Otoregresif Kesirli Entegre Hareketli Ortalama Modeli

ARMA Otoregresif Hareketli Ortalama Modeli

BP Geri Yayılım

CNN-LSTM Konvolüsyonel Sinir Ağı-Uzun Kısa Süreli Bellek

DDPG Derin Deterministik Politik Gradyan

DNN Derin Sinir Ağları

DRL Derin Takviyeli Öğrenme

EFA-ANN Elektromanyetizma Tabanlı Ateşböceği Algoritması- Yapay Sinir Ağı

ELM Aşırı Öğrenme Mekanizması

EMD Ampirik Mod Ayrıştırma

FFNN Bir İleri Beslemeli Sinir Ağı

GA Genetik Algoritma

GP Genetik Programlama

HONN Yüksek Dereceli Sinir Ağları

LM Levenberg-Marquardt Metot

LSTM Uzun Kısa Süreli Bellek

MIMO Çok Girdili Çok Çıktılı

MAE Ortalama Mutlak Hata

MAPE En Düşük Ortalama Mutlak Yüzde Hatası

ML Makine Öğrenmesi

MLP Çok Katmanlı Algılayıcı

MR Çoklu Regresyon

PSNN Pi-Sigma Sinir Ağları

RDPG Tekrarlayan Deterministik Politik Gradyan

RF Random Forest

RNN Tekrarlayan Sinir Ağları

SPNN Sigma-Pi Sinir Ağları

SR Sembolik Regresyon

TLBO Öğretme Öğrenmeye Dayalı Optimizasyon

YSA Yapay Sinir Ağları

Şekil Listesi

1	Ana fabrikanın örnek günlük enerji tüketimi	11
2	Ana fabrikanın örnek haftalık elektrik enerjisi tüketimi	12
3	Biyolojik olarak bir sinir ağı yapısı [1]	26
4	Biyolojik sinir ağının modeli [1]	28
5	Pi-Sigma Sinir Ağı Modeli [21].	33
6	Sigma-Pi Sinir Ağı örneği [66]	36
7	Önerilen Metotlarda kullanılan veri seti görseli.	47
8	Önerilen Metotun Sinir Ağı Modeli.	49
9	Önerilen Metotun Sinir Ağı Modeli.	50
10	Benzetim çalışmalarında kullanılan veri.	51
11	Standart ANN (10 nöron): öznitelik çıkarımı olmayan modelleme ve kestirim sonuçları	53
12	Sigma-Pi sinir ağı (3 düğüm): öznitelik çıkarımı olmayan modelleme ve kestirim sonuçları	54
13	Sigma-Pi sinir ağı (3 düğüm): öznitelik çıkarımı kullanarak modelleme ve kestirim sonuçları	57

Tablo Listesi

1	Öznitelik çıkarımı kullanılmadan elde edilen performans sonuçları	55
2	Öznitelik çıkarımı kullanılarak elde edilen performans sonuçları	56
3	Öznitelik operator ve fonksiyonları	56



1 Giriş

Bir proses, bir veya daha fazla girdiyi bir veya daha fazla çıktıya dönüştüren bir dizi bağlantılı faaliyetleri oluşturmaktadır. Tüm iş faaliyetleri süreçlerde gerçekleştirilir ve tahmin de bir istisna değildir. Tahmin süreci problemin tanımlanmasıyla başlar. Problem tanımlanması yapıldıktan sonra gerekli veri toplanır ve analizi yapılır. Analizi yapılan ve ön işlemlerden geçirilerek temizlenmiş olan veri seçilen modele göre revize edilir ve modele uygulanır. Modelin oluşturduğu çıktıya göre modelin doğruluğunun kontrolü yapılır [41]. Kontrol işlemi gerçekleştirildikten sonra model iyileştirilmesine yönelik optimizasyon yöntemleri kullanılır.

1.1 Enerji Tüketim Verisi


Enerji tüketim verisi endüstride çoğunlukla karşımıza çıkan depolaması ve işlenmesi son zamanlarda önem kazanmış bir veri tipidir. Bu verinin incelenmesi yapıldığında zamanla değişim gösteren bir veri tipi olduğu gözlemlenmektedir. Bu nedenle verinin tanınması ve tahminlenmesinin yapılabilmesi için öncelikle zaman serileri bilinmeli ve zamanla değişen verilerin özelliklerinin tanınması gerekmektedir.

1.1.1 Zaman Serisi Tahminleme

Tahmin, işletme ve sanayi, devlet, ekonomi, çevre bilimleri, tıp, sosyal bilimler, siyaset ve finans gibi birçok alanı kapsayan önemli bir sorundur. Tahminleme problemleri genel olarak kısa, orta vadeli ve uzun vadeli olacak şekilde ayrıştırılmaktadır. Kısa vadeli tahmin problemleri, olayları yalnızca birkaç zaman diliminde (günler, haftalar ve aylar) geleceğe tahmin etmeyi içerir. Orta vadeli tahminler 1 ila 2 yıl süreye kadar uzanır, uzun vadeli tahminler ise bu sürelerden daha uzun olduğu durumu kapsamaktadır. Operasyon yönetiminden bütçelemeye ve yeni araştırma ve geliştirme projelerinin seçilmesine kadar uzanan faaliyetlerde kısa ve orta vadeli tahminler gerekmektedir. Uzun vadeli tahminler, stratejik planlama gibi konularda dikkate alınmaktadır. Kısa ve orta vadeli tahminler geçmiş verilerini baz alarak sistemleri tanımlamaya, modellemeye ve tahmin etmeye dayanmaktadır. Bu tarihsel veriler genellikle atalet sergilediğinden ve çok hızlı bir şekilde değişmediğinden,

istatistiksel yöntemler kısa ve orta vadeli tahminler için çok faydalıdır. Çoğu tahminleme problemi, zaman serisi verilerinin kullanılıp, işlenmesini içermektedir. Bir zaman serisi, incelenmekte olan ve değişen bir parametre üzerinde zaman yönelimli veya kronolojik bir izlenim dizisidir. Hız değişkeni, çoğu zaman serisinde ve tahmin uygulamasında tipik olduğu gibi, eşit aralıklı zaman periyotlarında toplanır. Tahmin edilen parametre birçok iş uygulamasında günlük, haftalık, aylık, yıllık verilerinde kullanılır, ancak herhangi bir raporlama aralığında kullanılabilir durumdadır. Zaman serileri endüstriyel süreçler kapsamında ele alındığında ise, üretim sürecinin kritik parametrelerinin özelliklerinin gelecekteki değerlerinin tahminlerinde, süreçteki önemli kontrol edilebilir değişkenlerin ne zaman değiştirilmesi gerektiğinde veya sürecin kapatılıp elden geçirilmesi gerekip gerekmediğini belirlemekte yardımcı olabilir. Geri besleme ve ileri beslemeli yapılarını içeren kontrol modelleri, endüstriyel süreçlerin izlenmesinde ve ayarlanmasında yaygın olarak kullanılmaktadır ve süreç çıktısının tahminleri bu proseslerin ayrılmaz bir parçasıdır [41]. Endüstriden örnek verecek olursak, şekil 1’de ana fabrikanın elektrik enerji tüketimini gösterir.

Genel zaman serisi modelleri, resmi bir model belirtmek için geçmiş verilerin istatistiksel özelliklerini kullanır ve daha sonra bu modelin bilinmeyen parametrelerini (genellikle) en küçük karelerle veya çeşitli optimizasyon yöntemleriyle tahmin eder. Buna ek olarak, zaman serisi denildiğinde, zaman serisi grafikleri, rastgele, eğilimler, seviye kaymaları, dönemler veya döngüler, olağandışı gözlemler veya kalıpların bir kombinasyonu gibi kalıpları ortaya çıkarabilir [41]. Endüstride ve ticarete fiilen karşılaşılan birçok seri, durağan olmayan davranış sergiler ve özellikle sabit bir ortalamaya göre değişmez[10]. Bu davranışa örnek olarak şekil 2’de gösterilebilir.




Şekil 1: Ana fabrikanın örnek günlük enerji tüketimi

1.2 Literatür Özeti

1.2.1 Enerji Tüketim Tahminlemesi

Artan enerji tüketimi, insan sağlığını, tarımı, doğal ekosistemleri ve dünya sıcaklığını etkileyen sera gazları gibi kirleticilerin salınmasına yol açmıştır. Yenilenebilir enerjinin doğru tahmin edilmesi ve ön görülmesi, enerji sektöründe politika ve karar verme süreci için hayati önem taşımaktadır. Bu nedenle, çevresel ve ekonomik faktörleri göz önünde bulundurarak yenilenebilir enerji tüketiminin optimum tahmini için Yapay Sinir Ağı (YSA) yaklaşımı sunulabilir. Buna göre, [4] çalışmada YSA, verileri En Düşük Ortalama Mutlak Yüzde Hatası (MAPE) sahip Çok Katmanlı Algılayıcı (MLP) yaklaşımıyla eğitir ve test edilir. Önerilen yaklaşım, mevcut ölçüm ekipmanının bulunmadığı yerler için kullanılmıştır ve yenilenebilir enerji tüketiminin tahmini için en iyi modeli seçmek için tam duyarlılık analizi yapılmıştır. Elde edilen sonuçlar yaklaşık %99,9'luk yüksek doğruluk



řekil 2: Ana fabrikanın  rnek haftalık elektrik enerjisi t k timi

g stermiřtir.  nerilen modelin sonu ları, avantajlarını ve  st nl   n  g stermek i in geleneksel ve bulanık regresyon modelleri ile karřılařtırılmıřtır. Yapay sinir a larının kullanıldı ı bir di er  alıřmaya  rnek verecek olursak, [11]  alıřmasında, binalardaki enerji t k timini tahmin etmek i in Elektromanyetizma Tabanlı Ateřb ce i Algoritması- Yapay Sinir A ı (EFA-ANN) adlı yeni bir hibrit model incelenmiřtir. Model, verilen farklı iki veri toplulu unun kullanımı ile birlikte ısıtma y k n  (HL) ve so utma y k n  (CL) de erlendirmek i in uygulanmaktadır. Ayrı ayrı her bir veri seti, sırasıyla cephe sisteminin ve binanın boyutlarının enerji t k timi  zerindeki etkisi g zlemlenerek elde edilmiřtir. EFA-ANN'nin performansı, elde edilen sonu ların di er y ntemlerle karřılařtırılmasıyla do rulayıp, EFA-ANN'nin HL ve CL i in daha hızlı ve daha do ru bir tahmin sa ladığı g sterilmiřtir. Her bir girdinin binanın enerji performansı  zerindeki etkisini belirlemek i in bir duyarlılık analizi yapılmıřtır ve sonu  olarak, EFA-ANN'nin enerji verimli binaların erken tasarımılarında inřaat m hendislerine ve inřaat y neticilerine yardımcı ola-

bileceği öne sürülmüştür. Binalardaki enerji verimliliğini ele alan bir diğer çalışmada [46], birden fazla binada saatlik çözünürlükte kısa vadeli enerji tüketimini tahmin etmek için Random Forest (RF) tabanlı bir tahmin modeli önerilmiştir. Eğitim ve test süreçleri zarfında RF modelinin performansını incelemek ve test etmek için saatlik bina enerji tüketimine ilişkin beş tane yıllık veri seti kullanılmıştır. Değerlendirme sonuçları, RF modelinin tahminde başarılı bir tahmin doğruluğu sergilediğini göstermektedir. Dört değerlendirme senaryosunda, ortalama Ortalama Mutlak Hata (MAE) değerleri 1 adım ileri tahmin için 0,430 ila 0,501 kWh, 12 adım ileri tahmin için 0,612 ila 0,940 kWh ve 24 adım ilerisi tahmin için 0,626 ila 0,868 kWh arasında değiştiği gözlemlenmiştir. RF modeli, M5P ve Random Tree (RT) modellerinden daha üstün sonuçlar verdiği savunulmuştur. RF, 1 adım ileri bina enerji tüketimini tahmin etmede RT modelinden yaklaşık %49.21, MAE’de %46.93 ve ortalama mutlak yüzde hatasında (MAPE) daha iyi sonuç verdiği gözlemlenmiştir. RF modeli, M5P modeline kıyasla MAE’de sırasıyla 12 adım ileri ve 24 adım ileri enerji kullanımında %49.95 ve %29.29’luk performansı göstermiştir. Bu nedenle önerilen RF modeli, incelenen Makine Öğrenmesi (ML) modelleri arasında etkili bir tahmin modeli oluşturduğu öne sürülmüştür. Bir diğer çalışmada [18] ise, gelişmiş tekrarlayan sinir ağı tabanlı stratejilerin yararlılığını araştırılmıştır. Her strateji, iki düzeyde benzersiz özellikler sunmakla birlikte, yüksek düzeyde, özyinelemeli yaklaşım, doğrudan yaklaşım ve Çok Girdili Çok Çıktılı (MIMO) yaklaşım dahil olmak üzere kısa vadeli tahminler üretmek için üç çıkarım yaklaşımı kullanılmıştır. Düşük seviyede, tek boyutlu evrişimli işlemlerin kullanımı, çift yönlü işlemler ve farklı tipte yinelenen birimlerin kullanımı gibi tekrarlayan model geliştirme için en son teknikler kullanılmıştır. Farklı stratejik modellerin performansı, gerçek bina operasyonel verilerine dayanarak farklı perspektiflerden değerlendirilerek test edilmiştir. Araştırma sonuçları, inşaat uzmanları ile gelişmiş büyük veri analitiği arasındaki bilgi boşluğunu gidermeye yardımcı olacağına değinilmiştir. Elektrik santralde üretilirken aynı anda tüketildiğinden, kararlı güç kaynakları için enerji tüketimini önceden doğru bir şekilde tahmin etmek önemli bir noktadır.

Yapılan başka bir çalışmada, konut enerji tüketimini yüksek başarı oranına sahip bir şekilde tahmin etmek için mekansal ve zamansal özellikleri çıkarabilen bir Konvolüsyonel Sinir Ağı-Uzun Kısa Süreli Bellek (CNN-LSTM) sinir ağı kullanımı önerilmiştir. Çalışma

sonuçları ve yapılan testler, konvolüsyonel sinir ağını (CNN) ve Uzun Kısa Süreli Bellek (LSTM) birleştiren CNN LSTM sinir ağına, enerji tüketiminin karmaşık özelliklerini çıkarabildiğini ortaya koymaktadır. CNN katmanı, enerji tüketimini etkileyen çeşitli değişkenler arasındaki özellikleri çıkarabilir ve LSTM katmanı, zaman serisi bileşenlerindeki düzensiz eğilimlerin zamansal bilgilerini modellemek için uygun bulunmuştur [31].

Buna ek olarak, Takviyeli öğrenme ve derin öğrenmenin bir kombinasyonu olarak, Derin Takviyeli Öğrenme (DRL) tekniklerinin doğrusal olmayan ve karmaşık sorunları çözmesi beklenmektedir. Ancak, bina enerji tüketimini tahmin etmede DRL teknikleri hakkında çok fazla çalışma bulunmamaktadır. Bu nedenden dolayı, bina enerji tüketimini tahmin etmek için yaygın olarak kullanılan üç DRL tekniğini kullanan bir ofis binasının örnek proses incelemesi üzerine çalışma yapılmıştır. Asenkron Avantaj Aktör-Kritik (A3C), Derin Deterministik Politik Gradyan (DDPG) ve Tekrarlayan Deterministik Politik Gradyan (RDPG) şeklinde farklı modeller kullanılmıştır. DRL modelleri ile yaygın olarak denetlenen modeller arasında kapsamlı bir karşılaştırma da sağlanmış olup, önerilen DDPG ve RDPG modellerinin şu alanlarda bariz avantajlara sahip olduğunu göstermektedir. Ortak denetimli modellere kıyasla bina enerji tüketimini tahmin ederken, model eğitimi için daha fazla hesaplama süresini hesaba katmıştır. Ölçülen tahmin performansları MAE, tek adımlı tahmin için %16-24 ve çok adımlı tahmin için %19-32 oranında iyileştirme yapıldığı gözlenmiştir. Ayrıca A3C'nin düşük tahmin doğruluğu gerçekleştirdiğini de göstermekte olup, DDPG ve RDPG'den çok daha yavaş yakınsama yaptığı göstermiştir. Bununla birlikte, A3C bu üç DRL yöntemi arasında hala en verimli teknik olduğu öne sürülmüştür [38].

Yıllık enerji tüketimini en aza indirmeyi ve termal konforu en üst düzeye çıkarmayı amaçlayan ısıtma, havalandırma ve iklimlendirme (HVAC) sistem operasyonlarını kontrol etmek amacıyla, Yapay sinir ağı (YSA) ve çok amaçlı genetik algoritmanın (MOGA) kombinasyonu, bir binada iki soğutmalı sistemin çalışmasını optimize etmek için uygulanmıştır. Binaya kurulan HVAC sistemi, radyan soğutma sistemi, değişken hava hacimli (VAV) soğutma grubu sistemi ve özel dış hava sistemi (DOAS) gibi enerjinin izleneceği ve kontrolünün sağlanacağı sistemler içermektedir. Sıcaklık ayarı, pasif güneş enerjisi tasarımı ve soğutucu çalışma sistemi kontrolü gibi çeşitli parametreler karar değişkenleri olarak

kullanılmıştır. Daha sonra, memnun olmayan insanların yüzdesi (PPD) ve yıllık bina enerji tüketimi amaç fonksiyonu olarak seçilmiş ve kullanılmıştır. Sistemi iki amaç fonksiyonu ile optimize etmek için çok amaçlı optimizasyon yöntemi kullanılması öyle bir durum için uygun bulunmuştur. Sonuç olarak YSA, karar değişkenleri ile amaç fonksiyonu arasında iyi bir ilişki kurmuştur. Ayrıca, MOGA, termal konfor ve yıllık enerji tüketimi açısından optimum sistemi elde etmek için çeşitli alternatif olası tasarım değişkenlerini başarıyla sağlandığı öne sürülmüştür [52].

Otomatik gerilemeli entegre hareketli ortalama, yapay sinir ağı, bulanık çıkarım sistemi modeli, uyarlanabilir nöro bulanık çıkarım sistemi, destek vektörü regresyonu, aşırı makine öğrenimi ve toplu, uzun vadeli enerji talebini tahmin etmek için genetik algoritma içeren yeni bir topluluk metodolojisi önerilmiştir. Çerçeveyi, ortalama kare hatası ve ortalama mutlak yüzde hatası ile hata fonksiyonlarıyla kıyaslama yöntemiyle karşılaştırdıktan ve bir model doğrulama seti uyguladıktan sonra, önerilen yöntemin önceki yaklaşımlara göre tahmin doğruluğunu iyileştirdiği gösterilmiştir. Önerilen yaklaşım, örnek bir çalışmada en iyi yapay zeka ve ekonometrik modellere göre ortalama %22,3 RMSE ve %33.1 ortalama mutlak hata yüzdesi ile sonuçlanmıştır. Bu metodolojide tahmin grubunun işlem sonrası optimizasyonu, tahmin doğruluğunu artırmıştır. Geliştirilen yaklaşım, nasıl hibridize edildiğine dair alana bir ek sağlamıştır [47].

Binalar, küresel enerji tüketiminin ve küresel sera gazı emisyonlarının büyük bir kısmında önemli bir rol oynamaktadır. Akıllı cihazlardaki ve sensörlerdeki büyüme göz önünde bulundurulduğunda, yeni nesil daha akıllı, daha bağlam farkında, bina kontrolörleri geliştirme fırsatı olduğu görülmüştür. Hava durumu, doluluk ve iç ortam sıcaklığını girdi olarak alındığında, bölge düzeyinde yapay sinir ağları oluşturulmuştur. Bu gibi parametreler, enerji tüketimini en aza indirmek amacıyla bir genetik algoritma tarafından değerlendirme amaçlı kullanılmıştır. Cardiff, İngiltere'deki küçük bir ofis binasında her bölge için özel olarak hazırlanmış 24 saatlik ısıtma ayar noktası programları kurulmuştur. Optimizasyon stratejisi, gün öncesi optimizasyon veya her bir saat başladığında yeniden optimize edilen bir model tahminleyicisi kontrolü olacak şekilde iki modda dağıtılmıştır. Optimizasyonun temel bir ısıtma stratejisine göre enerji tüketimini yaklaşık %25 oranında azalttığı gözlemlenmiştir. Kullanım süresi tarifiesi değerlendirildiğinde, optimizasyon enerji tüketi-

minden ziyade maliyeti en aza indirecek şekilde değiştirildiği görülmüştür. Optimizasyon stratejisi, yükü daha ucuz fiyat dönemlerine başarıyla kaydırılmış olup, temel stratejiye kıyasla enerji maliyetini yaklaşık olarak %27 oranında azalttığı gözlemlenmiştir [50].

Bir destek vektör makinesi, enerji tüketimi tahmin modeli kurarak binalarının enerji tüketimini incelemekte ve analiz etmektedir. Destek vektörü makine modeli, iklimlendirme sisteminin hava parametrelerini ve çalışma parametrelerini giriş değişkenleri olarak kullanmıştır ve aykırı değerlerin etkisini engellemek için normal dağılım aralığını belirleyip değiştirerek giriş parametrelerinin kritik değerini hesaplayabilmektedir. RBF çekirdek modeli, destek vektör makinesinin çekirdek modeli olarak seçilmiş ve çekirdek parametrelerinin optimize edilmesiyle birlikte model tahmininin doğruluğu iyileştirilmiştir. Sonuçlarda elde edilen model tahmininin MSE değeri %2.22 ve R^2 0.94 olacak şekilde sonuçlandırılmıştır [53].

Enerji tüketim bilgisi, birçok gerçek sistemde periyodiklik içeren bir tür zaman serisi iken, genel tahmin yöntemleri periyodiklik ile ilgili değildir. Periyodik enerji tüketimini tahmin etmek ve performansını incelemek için uzun kısa süreli bellek (LSTM) ağına dayalı yeni bir yaklaşım önerilmiştir. İlk olarak, gerçek endüstriyel veriler arasındaki otokorelasyon grafiği oluşturulmuştur. Korelasyon analizi ve mekanizma analizi, model olarak uygun ikinci parametrelerin bulunmasına yardımcı olmuştur. Buna ek olarak, periyodikliği tam olarak yakalamak için zaman değişkeni kullanılmıştır. Ardından, sıralı verileri modellemek ve tahmin etmek için bir LSTM ağı oluşturulmuş ve kullanılmıştır. Belirli bir soğutma sistemi üzerindeki test sonuçları, önerilen yöntemin, Otoregresif Hareketli Ortalama Modeli (ARMA), Otoregresif Kesirli Entegre Hareketli Ortalama Modeli (ARFIMA) ve geri yayılım sinir ağı (BPNN) gibi birkaç geleneksel tahmin yöntemiyle kıyaslandığında daha yüksek tahmin performansına sahip olduğunu göstermiştir. LSTM'nin RMSE'si test verilerinde BPNN, ARMA, ARFIMA'dan %19.7, %54.85, %64.59 daha düşük değerlerde olduğu görülmüştür. Ayrıca, eksik belirli ölçüm ekipmanlarının sınırlaması göz önünde bulundurularak, azaltılmış ikincil değişkenlere sahip yeni tahmin modelleri, tahmin doğruluğu ve potansiyel girdi değişkenleri arasındaki ilişkiyi keşfetmek için yeniden eğitilebileceği önerilmiştir [57].

Doluluk davranışı binalarda enerji tüketiminde önemli bir parametre olmuştur. Sığ

doluluk oranı, tahmin edilen ve ölçülen enerji kullanım değeri arasında önemli bir performans eksikliğine yol açtığı gözlemlenmiştir. Bu nedenle kör sistem tanımlamasına (BSI) dayalı doluluk tahmini için bir yaklaşım önerilmiş ve bir iklimlendirme sistemi tarafından elektrik tüketiminin tahmin modeli, yolcu sayısının BSI tahmini ile bir yapay sinir ağına dayalı olarak geliştirilmiştir ve raporlanmıştır. Kütle korunumu kanunundan ve havalandırma seviyelerinden türetilen iç mekan CO2 dinamiklerinin tanımlanmasından başlanılmıştır. Doluluk oranı ve model parametreleri de dahil olmak üzere bilinmeyen parametreler, bir sıklık maksimum olabilirlik algoritması ve Bayes tahmini kullanılarak tahmin değerleri oluşturulmuştur. İkinci aşama ise, Bir İleri Beslemeli Sinir Ağı (FFNN), Aşırı Öğrenme Mekanizması (ELM) ve ayrıca topluluk modelleri kullanarak iklimlendirme sisteminin elektrik tüketimini tahmin eden modeli oluşturmaktır. Yapı parametrelerinin, girdi seçimi alternatiflerinin etkisini belirlemek için ve karşılaştırma testinin bazı yönlerini analiz etmek için, (1) temel bileşen analizine dayalı tahmin edici seçiminin etkisi, (2) tahmini doluluk oranının etkisinin etkisi ve (3) sinir ağı topluluğunun etkisi üzerine üç çalışma yapılmıştır. Girdi olarak doluluk sayısının kullanıldığı bir sinir ağı modeli kullanarak enerji tüketimini tahmin etmekteki doğruluğu artırabildiğini gösterilmiştir [61].

Düzensiz insan davranışları ve tek değişkenli veri kümeleri, bireysel haneler için veriye dayalı enerji tüketimi tahminlerinin iki ana etken olmaya devam etmektedir. Bu konu hakkında yapılan bir çalışmada, hibrit bir derin öğrenme modeli bir topluluk uzun kısa süreli bellek (LSTM) sinir ağının sabit dalgalı dönüşümü (SWT) tekniği ile birleştirilmesi önerilmiştir. SWT, süreksizlik azaltılmış ve potansiyel olarak LSTM tahmin doğruluğunu iyileştirmeye yardımcı olan veri boyutlarını arttırmıştır. Ayrıca, topluluk LSTM sinir ağı, önerilen yöntemin tahmin performansını daha da geliştirmiştir. Doğrulama deneyleri, "UK-DALE" tarafından toplanan gerçek zamanlı hanehalkı enerji tüketimi veri setine dayalı olarak uygulanmıştır. Rekabetçi bir eğitim verimliliği ile önerilen yöntemin, kalıcı yöntem, destek vektör regresyonu (SVR), uzun kısa süreli bellek (LSTM) sinir ağı ve konvolüsyonel sinir ağı dahil olmak üzere tüm karşılaştırılan son teknoloji yöntemlerden daha iyi performans gösterdiğini gösterilmek istenmiştir [62].

Derin Sinir Ağları (DNN), birçok zorlu yapay zeka görevinde son teknoloji doğruluğu ortaya koyduğu görülmektedir. Hesaplamanın çoğu şu anda bulutta bulunsa da, gizlilik,

güvenlik ve gecikme endişeleri veya iletişim bant genişliğindeki sınırlamalar nedeniyle DNN işleminin sensörün yakınına yerel olarak yerleştirilmesi talep edilmektedir. Buna göre, enerji verimli DNN'ler tasarlamaya yönelik araştırma topluluğunda artan bir ilgi vardır. Ancak, DNN modelinden enerji tüketimini tahmin etmek, depolama maliyeti (model boyutu) ve verim (işlem sayısı) gibi diğer ölçütlerden çok daha zordur. Bunun sebebi, enerjinin önemli, büyük bir bölümünün direkt olarak DNN modelinden çıkarılması zor olan veri hareketi tarafından kullanılmasıdır. Mimariye, seyrekliğine ve bit genişliğine dayalı olarak bir DNN'nin enerji tüketimini tahmin edebilecek bir enerji tahmin metodolojisi oluşturulması önerilmiştir. Bu metodoloji, şu anda sahada önerilen çeşitli DNN mimarilerini ve enerji verimli teknikleri değerlendirmek ve enerji verimli DNN'lerin tasarımına rehberlik etmek için kullanılmaktadır [63].

1.2.1.1 Literatürde Elektrik Enerjisi Tüketimi Tahminlenmesine Yönelik Çalışmalar

Bina sektörünün enerji talebindeki artan eğilim, güvenilir ve sağlam enerji tüketimi tahmin modellerini gerektirmektedir. Londra, Birleşik Krallık'ta bulunan bir yönetim binasının elektrik tüketimini tahmin ederek beş farklı akıllı sistem tekniğinin tahmin yeteneklerini karşılaştırmayı amaçlayan bir çalışma yapılmıştır. Bu çalışmada kullanılan teknikler şu şekildedir; Çoklu Regresyon (MR), Genetik Programlama (GP), Yapay Sinir Ağı (ANN), Derin Sinir Ağı (DNN) ve Destek Vektör Makinesi (SVM). Tahmin etme modelleri, güneş radyasyonu, rüzgar hızı, sıcaklık, nem ve hafta içi indeksi gibi farklı parametrelerin beş yıllık gözlenen verilerine dayalı olacak şekilde gerçekleştirilmiştir. Hafta içi endeksi, çalışılan ve çalışılmayan günleri ayırt etmek için tanıtılan bir parametre olarak önemli rol oynamaktadır. Modellerin eğitilmesi ve beşinci yıl için tahmin verilerinin elde edilmesi için ilk dört yıl verileri kullanılmıştır. Son olarak, tüm modellerin elektrik tüketimi tahmini, beşinci yılın gerçek tüketimi ile kıyaslanmıştır. Sonuçlar göz önünde bulundurulduğunda, ANN'nin %6 Ortalama Mutlak Yüzde Hatası (MAPE) ile diğer dört tekniğin hepsinden daha iyi performans gösterdiğini, oysa MR, GP, SVM ve DNN'nin sırasıyla %8.5, %8.7, %9 ve %11 MAPE'ye sahip olduğunu gösterilmektedir. Bu çalışmanın uygulanabilirliği diğer bina kategorilerini kapsayabilmektedir ve enerji yönetimi ekiplerinin çeşitli binaların enerji tüketimini tahmin etmesine yardımcı olacağı

düşünülmektedir [2].

Diğer bir çalışmada, stokastik prosedürlerin kullanıldığı, elektrik talebini tahmin edildiği entegre bir Genetik Algoritma (GA) ve yapay sinir ağı(YSA) önerilmiştir. Bu çalışmada kullanılan parametreler fiyat, katma değer, müşteri sayısı ve önceki dönemlerdeki tüketim şeklindedir. Model, parametre değerlerini optimize ederek gelecekteki enerji talebini tahmin etmek için kullanılabilir. Bu çalışmada uygulanan GA, tüm parametreleri için ayarlanmış ve tüm parametre değerleri aynı anda test edilirken, en az hataya sahip en iyi katsayılar belirlenmiştir. Genetik algoritma modelinin tahmin hataları, regresyon yöntemi ile tahmin edilenden daha az olduğu gözlemlenmektedir. Her bir bağımsız değişkeni tahmin etmek için YSA kullanılmış olup, ardından 2008 yılına kadar elektrik tüketimi tahmin edilmek için çalışılmıştır. Entegre GA ve YSA'nın daha az MAPE (Mean Absolute Percentage Error) hatası vermesi açısından zaman serisi yaklaşımına hakim olduğu gösterilmiştir. Ayrıca, bu çalışmanın diğer bir özelliği, enerji tüketimi için daha iyi tahminler elde etmek için zaman serileri yerine YSA'nın kullanılmasıdır. 1981'den 2005'e kadar İrandaki tarım sektörünün elektrik tüketimi bu çalışmanın veri seti olarak ele alınmıştır [5].

Elektrik tüketimi, malzeme üretimi sektörü, sağlık ve eğitim sektörü gibi ulusal ekonomik, sosyal ve teknolojik faaliyetleri içeren alanlar için büyük önem taşımaktadır. Bu nedenden dolayı, daha iyi stratejik planlama yapılması, enerji kullanımı, atık yönetimi, gelirlerin iyileştirilmesi ve güç sistemlerinin bakımı gibi süreçler için verimli elektrik talebi tahmini ve yönetimi gerekli görülmektedir. Ampirik Mod Ayırıştırma (EMD) tabanlı bir derin öğrenme önerilen yöntemler arasındadır. Belirli bir mevsim, gün ve bir günün zaman aralığı için elektrik talebini tahmin etmek için EMD yöntemini LSTM modeliyle birleştiren yaklaşım kullanılmıştır. Bu hedef dahilinde, EMD algoritması, bir zaman serisi sinyalinin birkaç içsel mod işlevine (IMF'ler) ve parametrelere ayırmıştır. Daha sonra, çıkarılan her bir IMF ve artık için ayrı ayrı bir LSTM modeli eğitilmiştir. Son olarak, tüm IMF'lerin tahmin sonuçları, elektrik talebi için toplam çıktıyı ortaya koymak için toplama yoluyla birleştirilmiştir. Önerilen yaklaşımın uygulanabilirliğini göstermek ve performansını değerlendirmek için Chandigarh şehrinin elektrik tüketim verileri değerlendirmeye alınmıştır. Ayrıca, önerilen yaklaşımın performansı, tahmin sonuçları Tekrarlayan Sinir Ağları (RNN), LSTM ve EMD tabanlı RNN (EMDCRNN) modelleri ile karşılaştırılarak

değerlendirilmiştir [6].

Ayrıca, optimum elektrik talebi tahminini gerçekleyebilmek için çeşitli simülasyon programları, mühendislik ve yapay zeka tabanlı yöntemler kullanılmaktadır. Mühendislik yöntemleri tahmin için dinamik denklemler kullanırken, yapay zeka tabanlı yöntemler gelecekteki talebi tahmin etmek için geçmiş verileri kullanır. Bununla birlikte, mevcut yöntemler yalnızca kısa vadeli bağımlılıkları ele almak için yararlı olduğundan, doğrusal olmayan elektrik talep modellerinin modellemesi, sağlam çözümler için hala az gelişmiştir. Ayrıca, mevcut yöntemler, tamamen tarihsel verilere dayalı oldukları için doğaları gereği statiktir. Uzun vadeli tarihsel bağımlılıkları dikkate alarak elektrik talebini tahmin etmek için derin öğrenmeye dayalı bir çerçeve önerilen bir çalışma yapılmıştır. İlk olarak, tüm ayların elektrik tüketim verileri üzerinde küme analizi yapılarak sezon bazında segmente edilmiş veriler elde edilmiştir. Ardından, kümelerin her birine düşen ana veriler hakkında daha derin bir anlayışa sahip olmak için yük eğilimi karakterizasyonu gerçekleştirilmiş ve değerlendirilmiştir. Ayrıca, LSTM çok girişli çok çıkışlı modeller, mevsim, tarih ve aralık verilerine dayalı olarak elektrik talebini tahmin etmek için uygulamaya alınmıştır. Bu çalışmada, tahmin sonuçlarını iyileştirmek için hareketli pencere tabanlı aktif öğrenme kavramı da dahil edilmiştir. Önerilen yaklaşımın uygulanabilirliğini ve etkinliğini göstermek için Hindistan, Union Territory Chandigarh'ın elektrik tüketim verilerine uygulanmıştır. Önerilen yaklaşımın performans ölçütü, tahmin sonuçları Yapay Sinir Ağı, Tekrarlayan Sinir Ağı ve Destek Vektör Regresyon modelleri gibi birçok model ile karşılaştırılarak değerlendirilmiştir [7].

Bir yenilik olan elektrik enerjisi sektörüne daha doğru talep tahminleri elde etmek için Bootstrap agregasyon (Bagging) ve tahmin yöntemlerini de içeren çalışmalar yapılmıştır. Farklı ülkelerden aylık elektrik enerjisi tüketimi zaman serileri kullanılarak karşılaştırmalı bir örneklem dışı analiz yapılmıştır. Sonuçları, önerilen metodolojilerin hem gelişmiş hem de gelişmekte olan ülkelerde enerji son kullanım hizmetleri talebinin tahmin doğruluğunu önemli ölçüde iyileştirdiğini göstermektedir [16].

Model tahmini için kullanılan veri seti çok kaynaklı, heterojen veya yetersiz olduğu durumda, tek veriye dayalı model yakınsama sorunu ortaya çıkabilir veya düşük model doğruluğundan dolayı olabilir. Gelişmiş evrimsel algoritmaların (EA'lar) ve veriye dayalı

modellerin kombinasyonunun, tahmin doğruluğu ve sağlamlık iyileştirmeleri açısından etkili olduğu kanıtlanmıştır. Ancak, bazılarının yakınsama yöntemleri çok zaman almaktadır. Bu yazıda, kısa vadeli bina enerji kullanımı tahmini için yeni bir EA, yani Öğretme Öğrenmeye Dayalı Optimizasyon (TLBO) önerilen yöntemler arasındadır. Yakınsama hızını ve optimizasyon doğruluğunu değerlendirmek ve artırmak için, temel TLBO algoritması farklı açılarda değiştirilerek değerlendirilmiştir. Geliştirilen algoritma, yapay sinir ağı (YSA) ile birleştirilmiş ve sırasıyla ABD ve Çin’de bulunan iki eğitim binasının saatlik elektrik enerjisi tahminine uygulanmıştır. Performans karşılaştırmaları, önerilen modelin yakınsama hızını ve tahmin doğruluğunu daha önce bildirilen GA-ANN ve PSO-ANN yöntemlerle kıyaslandığı durumda değerlendirildiğinde daha üstün performanslara sahip olduğu ve gelecekte çevrimiçi enerji tahmini için uygun olduğu öne sürülmüştür [37].

Aynı zamanda farklı bir çalışmada, geleneksel istatistiksel yöntem (doğrusal regresyon) ve yapay sinir ağı (YSA) algoritmalarını kullanan bina elektrik enerjisi tahmin yaklaşımlarını karşılaştırmaktadır. Doluluk oranları, sıcaklık, nem değeri, bulut türü, güneş radyasyonu gibi yerel çevre koşulları tüketim tahmini boyuttundaki önemi araştırılmış ve değerlendirilmiştir. Rüzgar hızı, hem çalışma hem de çalışma dışı günler için bir kampüs binasında gerçek elektrik enerjisi tüketimini ne boyutta etkilediği incelenmiştir. Her girdi veri türü öğesinin etki derecesini analiz etmek için bu veri kümelerine bir etki değeri faktörü uygulanmıştır. Uygulama sonuçlarına değinildiğinde, YSA modellemesinin, istatistiksel yöntemlere göre modellemelerden daha doğru ve kararlı olduğunu görülmüştür. İş günleri için elektrik tüketimi tahmin etmede doğrusal regresyon yöntemi kullanılmıştır. Çalışma günleri için etki faktörü analizi ile, binadaki elektrik tüketimine doluluk oranlarının güçlü bir şekilde hakim olduğu, sıcaklık ve nemin de sonuçları etkilediği bulunmuştur. Bununla birlikte, farklı veri türü öğelerinin çalışma dışı gün sonuçları üzerinde benzer etkileri olduğu için, çalışma dışı günlerde elektrik tüketimini tahmin etmede iki model arasında doğruluk farkı yoktur. İki modelde —doğrusal regresyon ve Levenberg–Marquardt Geri Yayılım (LM-BP) algoritmasına sahip YSA— uzun vadeli ve gerçek zamanlı verilerin analizinde gereksinimleri karşılayabilmiştir. Doluluk oranlarına ve yerel çevresel koşullara dayalı olarak fiili bir binanın elektrik tüketimi için saatlik tahmin gereksinimleri gösterilmiştir. Girdi elemanı değişikliklerinin makroskopik bir ölçekte analizi, sayısal etki

faktörü ile her bir elemanın binalarda elektrik enerjisi tüketimini nasıl etkilediğini tahmin etmede yardımcı olmuştur. LM-BP algoritması ile önerilen YSA yöntemi, bir binanın elektrik tüketimini tahmin etmek için doğrusal regresyon modellemesine kıyasla güvenilir bir yaklaşım olarak kullanılabilirliği önerülmüştür [29].

Genel işletmelerin günlük elektrik tüketimini tahmin etmek için EEMD-RF adlı topluluk ampirik mod ayrıştırma (EEMD) ile birleştirilmiş bir rastgele orman (RF) modeli sunulmuştur. Aday veriler ilk önce EEMD tarafından birkaç içsel mod işlevine (IMF'ler) ayrıştırılır. Hızlı Fourier dönüşümü yöntemi ile , her bir IMF'deki özelliklerin zaman-frekans alanındaki değerleri hesaplanmış, ardından simüle edilmiş ve RF modeli tarafından tahmin edilmiştir. Buna ek olarak, her bir IMF'nin sonuçları, bu işletmeler için günlük elektrik tüketiminin genel dağılımına entegre edilmiştir. Önerilen bu yöntem, Jiangsu Yüksek Teknoloji Bölgesi'nde bulunan iki işletmeye farklı farklı olacak şekilde uygulanmıştır ve toplanan verilerin süresi 1 Ocak 2015'ten 3 Mayıs 2016'ya kadar değerlendirilmiştir. EEMD-RF yaklaşımının uygulanabilirliğini ve üstünlüğünü göstermek için iki temel karşı-

laştırma için modeller bir geri yayılım sinir ağı (BPNN) ve en küçük kareler destek vektör regresyonu (LSSVM) ve beş model deney (EEMD-BPNN, EEMD-LSSVM, RF, BPNN ve LSSVM) olacak şekilde seçilmiştir. Bu yaklaşımlar arasında önerilen model sergilenmiştir. Ortalama mutlak hata, ortalama mutlak yüzde hatası ve ortalama karekök hatası açısından en iyi tahmin performansı gösterdiği önerülmüştür [35].

Bir saatlik çözünürlükte ticari ve konut binalarındaki elektrik tüketim profillerinin orta ila uzun vadeli tahminlerini, yani 1 haftalık zaman ufkunu modellemek için tekrarlayan bir sinir ağı modeli sunulan bir çalışma yapılmıştır. ABD'deki toplam enerji tüketiminin önemli bir kısmında konut ve ticari binalar önemli bir faktör olarak görülmektedir. Sensörler ve akıllı teknolojilerdeki gelişmelerle birlikte, karar vermeyi desteklemek için konut ve ticari binalarda saatlik aralıklarla orta ila uzun vadeli elektrik tüketimi tahminine ihtiyaç duyulmaktadır. Yapılan çalışmalar, talep stratejileri ve dağıtılmış üretim sistemlerinin işletilmesi ile ilgilidir. Model, binanın programları ve ekipmanları gibi parametrelere sınırlı erişime sahiptir. Mevcut enerji tüketimi verileri, zaman serisi tahminlerini zorlaştıran eksik veri blokları da içerebilir. Bu nedenle, çalışmanın ana hedefleri şu şekilde

sunulmuştur: (a) Bir saatlik çözünürlükte orta ila uzun vadeli elektrik yükü tahminini hedefleyen yeni derin tekrarlayan sinir ağı (RNN) modellerini geliştirmek ve optimize etmek; (b) Farklı elektrik tüketimi modelleri için modelin göreceli performansını analiz etmek; ve (c) Eksik değerlerin segmentlerini içeren bir elektrik tüketimi veri kümesi üzerinde değerlendirme yapmak için derin NN'yi kullanmak. Önerilen modeller, Salt Lake City, Utah'daki Kamu Güvenliği Binası için saatlik elektrik tüketimini ve Austin, Teksas'taki konut binalarındaki toplam saatlik elektrik tüketim tahmin elde etmek için kullanılmıştır. Ticari binanın yük profillerini tahmin etmek için, önerilen RNN diziden diziye modeller, geleneksel çok katmanlı algılayıcı sinir ağı ile karşılaştırıldığında genellikle daha düşük bağıl hataya karşılık gelmiştir. Konut binalarında toplam elektrik tüketimini tahmin etmek için, önerilen model genellikle çok katmanlı modele kıyasla doğrulukta kazanç sağlamamakta olduğu sonucuna varılmıştır [48].

Bir diğer çalışmada, geleneksel regresyon analizine ek olarak, karar ağacı ve sinir ağları da değerlendirmeye alınmıştır. Model seçimi, ortalama kare hatasının kareköküne ağırlık olarak değerlendirilmiştir. Bir elektrik enerjisi tüketimi çalışmasına yönelik ampirik bir uygulamada, karar ağacı ve sinir ağı modelleri, enerji tüketim modellerini anlamada ve enerji tüketim seviyelerini tahmin etmede adım adım regresyon modeline uygun alternatifler olarak görünmektedir. Tahmine dayalı modelleme için veri madenciliği yaklaşımının ortaya çıkması ile birlikte, birçok platformda farklı tipte modeller oluşturulabilir. Bu nokta da önemli olan çeşitli modelleme tekniklerini uygulamak, farklı modellerin performansını değerlendirmek ve gelecek tahmini için en uygun modeli seçmektir [58].

Elektrik enerjisi tüketimi (EEC), hükümetin makul enerji politikası kapsamında büyük etkiye sahiptir ve elektrik sektöründe rekabetin serbestleşmesi ile birlikte elektrik üretim gruplarının farklı bir boyutta ilgisini çekmektedir. Aslında elektrik tüketimi, iklim faktörü ve gayri safi yurtiçi hasıla dahil birçok faktörden kolaylıkla etkilenmektedir. Bu nedenle, elektrik enerjisi tüketiminin kesin olarak tahmin edilmesi kolay bir uygulama değildir. Bu çalışma, elektrik enerjisi tüketimini tahmin etmek için geliştirilmiş bir yankı durum ağı kullanan ESN-DE adlı etkili ve kararlı bir model önermeyi amaçlamaktadır. Diferansiyel evrim algoritması kullanılmaktadır. Önerilen ESN-DE modelinin uygulanabilirliğini ve doğruluğunu kanıtlamak için iki farklı karşılaştırma yöntemi kullanılmış

ve genişletilmiş bir örnek oluşturulmuştur. ESN-DE'nin ortalama mutlak yüzde hataları sırasıyla %1.516 ve %0.570 şeklindedir. Karşılaştırmalı örneklerin hataları, ESN-DE'nin geleneksel yankı durumu ağı ve mevcut en iyi modelden daha iyi performans gösterdiğini öne sürmektedir. ESN-DE'nin ortalama mutlak yüzde hatası, Zhengzhou Şehri'nin elektrik enerjisi tüketimi tahmini için %2.156 şeklinde hesaplanmıştır. Önerilen ESN-DE, kolay uygulanabilirliği ve kararlılığından dolayı elektrik enerjisi tüketiminin etkin tahmini için potansiyel bir aday olarak görülmüştür [60].

Optimize edilmiş bir Geri Yayılım (BP) sinir ağına dayalı bir binada elektrik tüketimi tahmin etmek için birleşik kontrol yaklaşımlarını ele alınan bir çalışma yapılmıştır. Yönetim sistemleri, güç dağıtımını ve güvenli üretimi doğrudan etkilediği için elektrik tüketimi tahminine ayrı bir önem vermektedir. BP sinir ağı tahmin yöntemi, yüksek performansı ve basit yapısı nedeniyle bu amaç için yaygın olarak kullanılmıştır, fakat yavaş yakınsama, dalgalanmalar ve eğitim sırasında salınım gibi dezavantajları da bulunmaktadır. Tahminlerin doğruluğunu artırmak için Levenberg-Marquardt geri yayılım (LM-BP) sinir ağının kullanılmasını önerilmiştir. Gradyan iniş ve Quasi-Newton yöntemlerini birleştirerek oluşturulan model, hızlı yakınsama hızının sağlanması ve daha iyi genel performansın korunması amaçlamaktadır. Buna ek olarak, ağ ağırlıkları, dik gradyan iniş yöntemi ile Gauss-Newton yöntemi arasında uyarlamalı ayarlama ile optimize edilebilir hale getirilmiştir, böylece ağın etkin bir şekilde yakınsaması sağlanmıştır. Bu nedenden dolayı, Levenberg-Marquardt Metot (LM) algoritmasının doğruluğu ve kararlılığı iyileştirilmiş olup, geliştirilmiş BP sinir ağına dayalı olarak bir bina elektrik tüketimi tahmin modeli oluşturulmuştur. Sonuçlara bakıldığında, LM-BP sinir ağına dayalı tahmin modelinin, tahminlerin doğruluğunu ve kararlılığını geliştirdiğini ve bina elektrik tüketiminin kısa vadeli tahmini için uygun olduğunu gösterilmiştir [64].


Tekrarlanan sinir ağı modeline dayalı elektrik enerjisi tüketim tahminin yapıldığı bir çalışma da bulunmaktadır. Modeli geliştirirken, aşağıdaki baskın faktörler dikkate alınmıştır: tahmin dönemi boyunca enerji tüketimine ilişkin veriler; meteorolojik etki parametreleri (bulutluluk, hava sıcaklığı, yağış miktarı, rüzgar hızı, gün ışığının uzunluğu vb.) şeklindedir. Buna ek olarak, tarih (gün, ay), üretim takvimlerinin verileri (haftanın gününe ilişkin bilgiler: hafta içi / hafta sonu / tatil / kısaltılmış), söz konusu bölgedeki

endüstrinin özgüllüğü (federal bölgelerin ana merkezlerine ilişkin istatistiksel bilgilerin birleştirilmesi) gibi parametrelerde değerlendirilmiştir. Bu parametreler, sabit konfigürasyonlu sinir ağı üzerinden yapılan uygulamaları kapsamında seçilmiştir. Çalışmanın ilgi düzeyi, tahminin büyük hatası daha pahalı tarifelere neden olduğunda, Rusya enerji piyasasının ana parametrelerini tahmin edebilmek için doğru yöntemleri aramanın pratik önemi ile değinilmiştir. Oluşturulan tekrarlayan sinir ağı, regresyon bağımlılıklarına dayalı olarak yaygın kullanılan matematiksel tahmin modellerinden daha doğru tahmin sonuçları oluşturmuştur. Elde edilen bilimsel sonuç, Rusya’da toptan elektrik enerjisi ve kapasitesinde elektro-enerji konularının maliyetlerini düşürmeye ve enerji verimliliğini artırmaya yardımcı olmuştur [65].

2 Kullanılan Metotlar

2.1 Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), biyolojik organizmalarda öğrenme mekanizmasını simülasyonu yapan popüler makine öğrenme teknikleridir. İnsan sinir sistemi, nöronlar olarak adlandırılan hücreler içerir. Nöronlar, akson ve dendritlerin kullanımı ile birbirine bağlanır ve aksonlar ve dendritler arasındaki bağlantı bölgelerine sinaps adı verilir. Sinaptik bağlantıların gücü genellikle dış uyaranlara yanıt olarak değişir. Bu değişim, öğrenmenin canlı organizmalarda nasıl gerçekleştiğidir. Bu biyolojik mekanizma, nöronlar olarak adlandırılan hesaplama birimlerini içeren yapay sinir ağlarında simüle edilir. Hesaplama birimleri, biyolojik organizmalardaki sinaptik bağlantıların gücüyle aynı rolü üstlenen ağırlıklar aracılığıyla birbirine bağlanır. Bir nörona her girdi, o birimde hesaplanan işlevi etkileyen bir ağırlıkla ölçeklenir [1].



Şekil 3: Biyolojik olarak bir sinir ağı yapısı [1]

Şekil 3, biyolojik bir sinir ağına örnek olarak verilirken, şekil 4, bu sinir ağının fiziksel modellemesini göstermektedir.


Bir yapay sinir ağı, giriş nöronlarından hesaplanan değerleri çıkış nöron(lar)ına yayarak ve ağırlıkları ara parametreler olarak kullanarak girdilerin bir fonksiyonu hesaplanır. Öğrenme, nöronları birbirine bağlayan ağırlıkların değiştirilmesiyle gerçekleşir. Biyolojik

organizmalarda öğrenme için dış uyaranlara ihtiyaç duyulduğu gibi, yapay sinir ağlarında dış uyaran, öğrenilecek fonksiyonun girdi-çıkı çiftlerinin örneklerini içeren eğitim verileriyle sağlanır. Örnek verilecek olduğunda, eğitim verileri, çıktı olarak görüntülerin (giriş) ve açıklamalı etiketlerinin (örneğin havuç, muz) piksel temsillerini içerebilir [1]. Bu eğitim seti veri çiftleri, çıktı etiketleri hakkında tahminler yapmak için giriş temsilleri kullanarak sinir ağına giriş olarak verilir. Eğitim verileri, belirli bir girdi için tahmin edilen çıktının (örnekteki gibi havuç olasılığı) eğitim verilerindeki işaretli çıktı etiketiyle ne kadar iyi eşleştiğine bağlı olarak sinir ağındaki ağırlıkların doğruluğuna ilişkin geri bildirim oluşturur. Bir işlevin hesaplanmasında nöral ağ tarafından yapılan hataları, biyolojik bir organizmada sinaptik güçlerde bir ayarlamaya yol açan bir tür hoş olmayan geribildirim olarak görebilir. Benzer şekilde, nöronlar arasındaki ağırlıklar, tahmin hatalarına cevap olarak bir sinir ağında ayarlanmaktadır. Ağırlıkları değiştirmenin temel amacı, gelecekteki tekrarlamalarda tahminleri daha doğru hale getirmek için hesaplananı değiştirmektir. Bu nedenden dolayı, bu örnekteki hesaplama hatasını azaltmak için ağırlıklar matematiksel olarak doğrulanmış ve onaylanmış bir şekilde dikkatlice değiştirilmektedir. Birçok girdi-çıkı çifti üzerinde nöronlar arasındaki ağırlıklar art arda ayarlanılarak, sinir ağı tarafından hesaplanan fonksiyon, daha doğru tahminler oluşturması için zaman içinde iyileştirilir. Bu nedenle, sinir ağı birçok farklı muz görüntüsü ile eğitildiğinde, sonunda daha önce görmediği bir görüntüdeki bir muzun doğru bir şekilde tanıyabilecek hale gelmektedir. Sonlu bir girdi-çıkı çifti verileri üzerinde eğitim vererek görünmeyen girdilerin fonksiyonlarını doğru bir şekilde hesaplama becerisi, model genellemesi olarak isimlendirilir. Tüm makine öğrenimi modellerinin birincil kullanışlılığı, öğrenmelerini görülen eğitim verilerinden görünmeyen örneklere genelleştirme yeteneklerinden elde edilir [1].

2.1.1 Standart Yapay Sinir Ağı

Diğer bir açıdan bakıldığında şekil 4, modeli tek katmanlı bir sinir ağı olarak adlandırılır ve Bu sinir ağının matematiksel modellemesi yapıldığında şu şekilde denklemlleştirilir:

$$\hat{y} = sig\{\overline{W} \cdot \overline{X}\} = sig\left\{\sum_{j=1}^d w_j x_j\right\} \quad (1)$$



Şekil 4: Biyolojik sinir ağının modeli [1]

Bu noktada $\bar{X} = [x_1 \dots x_d]$ ve $\bar{W} = [w_1 \dots w_d]$ şeklinde giriş ve ağırlık matrisleridir.

$$e = y - \hat{y} \quad (2)$$

Denklem (2) modelin giriş ve çıkış arasındaki farklılığı, uyumsuzluğu diğer bir deyişle hatayı ifade eder. Model eğitimi yapılırken bu bahsi geçen hata oranının azalması göz önünde bulundurulur ve modele uygun optimizasyon yöntemleri seçilerek ağırlık matrisi güncellenir.

2.1.2 Yüksek Mertebeden Yapay Sinir Ağları

Geleneksel YSA modelleri, örüntü eşleştirme, örüntü tanıma ve matematiksel fonksiyon yaklaşımındaki mükemmel performanslarıyla tanınmalarına rağmen, genellikle küresel minimumdan ziyade yerel minimumda takılıp kalırlar. Ek olarak, YSA'ların pratikte yakınsaması kabul edilemeyecek kadar uzun zaman almaktadır [19]. Ayrıca, YSA'lar, finansal zaman serisi simülasyonu ve tahmininde düzgün olmayan, süresiz eğitim verilerini ve karmaşık eşlemeleri yönetemez. YSA'lar doğaları gereği "kara kutu"dur, bu da çıktıların açıklamalarının açık olmadığı anlamına gelir. Bu, Yüksek Dereceli Sinir Ağları (HONN) üzerine yapılan çalışmalar için motivasyona yol açar. HONN, girdilerinin daha yüksek kombinasyonlarını kullanan ağlardır [66].

HONN, hızlı öğrenme yetenekleri, daha güçlü yaklaşım, daha büyük depolama kapasitesi, daha yüksek hata toleransı yeteneği ve tek katmanlı eğitilebilir ağırlıkların güçlü haretalanması ile karakterize edilir. Daha yüksek dereceli terimler tanıtıldığından, doğrusal olmayan karar sınırları sağlarlar, dolayısıyla doğrusal nörona kıyasla daha iyi sınıflandırma yeteneği sunarlar. Doğadan ilham alan optimizasyon algoritmaları, gradyan iniş tabanlı arama tekniklerinden daha iyi arama yapabilir. Yapılan bir çalışmada, temel model olarak Pi-Sigma, Sigma-Pi, Jordan Pi-Sigma sinir ağı ve Fonksiyonel bağlantı yapay sinir ağı gibi dört HONN dikkate alınarak bazı hibrit modeller geliştirmektedir. Bu sinir ağlarının optimum parametreleri, Parçacık sürüşü optimizasyonu ve bir Genetik Algoritma tarafından değerlendirilmektedir. Modeller, stok verileriyle ilişkili aşırı dağılımlı, doğrusal olmama ve belirsizliği yakalamak için kullanılmıştır. Bu hibrit modellerin performansı, bazı reel borsaların bir adım ilerideki döviz kurları tahmin edilerek değerlendirilmektedir. Modellerin verimliliği, Radyal tabanlı fonksiyonel sinir ağı, çok katmanlı algılayıcı ve çok doğrusal regresyon yöntemi ile karşılaştırıldı ve üstünlükleri belirlendi. Sonuçların bilimsel olarak anlamlılığı için Friedman testi ve Nemenyi post-hoc testi uygulanmıştır [42].

Literatürde, modelleme ve simülasyon için yüksek mertebeden sinir birimlerinin (HONUs) ve daha yüksek mertebeden sinir ağlarının (HONNs) temel ilkelerine de değinilmiştir. HONN'lerin temel bir parçacığı, giriş değişkeni s ve HONU arasındaki daha yüksek dereceli ağırlıklı kombinasyonlarda veya korelasyonlarda oluşturulabilir. Statik HONU'ların yüksek kaliteli doğrusal olmayan yaklaşımı dışında, dinamik HONU'ların dinamik sistemleri modelleme yeteneği gösterilir ve pratik bir öğrenme algoritması kullanıldığında geleneksel tekrarlayan sinir ağlarıyla karşılaştırılır. Ayrıca, değiştirilebilir zaman gecikmeleri uygulanabileceğinden dolayı, sürekli dinamik HONU'ların yüksek dinamik sıralı sistemlere yaklaşma potansiyeli incelenmiştir. Bu bölüm, bazı tipik örnekleri kullanarak, sistemlerin modellenmesi için daha yüksek dereceli kombinasyonların veya korelasyonların nasıl ve neden etkili olabileceğini açıklanmıştır [23].

Doğru ve güvenilir üretim tahmini, petrol rezervlerinin yönetimi ve planlaması için kuşkusuz önemli bir adımdır. Diğer bir çalışmada, bir petrol rezervuarının petrol üretimini tahmin etmek için yüksek dereceli sinir ağı (HONN) adı verilen yeni bir sinirsel yaklaşım sunulmuştur. HONN'de, sinirsel girdi değişkenleri, geleneksel sinir ağının

sınırlamasının üstesinden gelen, doğrusal ve doğrusal olmayan bir şekilde bağıntılıdır. Bu nedenle, HONN, yeterli ağ eğitim verisi olmadan petrol rezervuarı üretim tahmini için umut verici bir tekniktir. HONN'lerin yetersiz veri ile petrol üretimi tahminindeki etkinliğini kanıtlamak için simülasyon çalışmaları için Hindistan'ın Gujarat kentinde bulunan bir kumtaşı rezervuarı seçildi. Petrol sahasından ölçülen verilerdeki gürültüyü azaltmak için alçak geçiren filtreden oluşan bir ön işleme prosedürü kullanılmıştır. Ayrıca optimum giriş değişkenlerini belirlemek için bir otokorelasyon fonksiyonu(ACF) ve buna ek olarak, çapraz korelasyon fonksiyonu(CCF) kullanılmıştır. Bu simülasyon çalışmalarından elde edilen sonuçlar, HONN modellerinin petrol üretiminin tahmininde daha yüksek doğrulukla gelişmiş tahmin kabiliyetine sahip olduğunu göstermiştir [12].

Aynı zamanda, yüksek mertebeden bağlantılara sahip tekrarlayan sinir ağları, kombinatoriyal optimizasyon problemlerinin çözümü için kullanılabilir. Gezgin satıcı probleminin (TSP) bir HONN rasgele sipariş üzerine eşlenmesi geliştirilmiştir, böylece TSP'yi çözmek için kullanılabilecek bir ilgili ağlar ailesi oluşturulmuştur. Yapılan çalışmada, TSP'nin HONN tarafından sağlanan ağ karmaşıklığı ve çözüm kalitesi arasındaki takas yapısı araştırılmaktadır. Takas, keyfi bir HONN düzeninde TSP'ye yönelik geçerli çözümlerin kararlılığının bir analizini üstlenerek araştırılır. Durağanlık analizini değerlendirmek için kullanılan teknikler son dönemde ortaya çıkan teknikler değildir, fakat literatürde başka yerlerde yaygın olarak kullanıldığı görülmektedir. Asıl üzerinde durulmak istenen temel amaç, bu tekniklerin TSP'yi çözmek için kullanılan bir HONN rasgele düzene uygulanması şeklindedir. Kararlılık analizinin sonuçlarına değinildiğinde ise, ağın sırası ile ölçüldüğünde, ağ karmaşıklığının arttırılmasıyla çözüm kalitesinin iyileştirildiğini öne sürülmektedir [15].

Şimdiye kadar yapılan çalışmalarda, birinci mertebeden sinir ağlarının fonksiyon yaklaşım yetenekleri titizlikle araştırılmıştır, ancak daha yüksek mertebeden sinir ağları ile ilgili birkaç çalışma rapor edilmiştir. Yapılan bu çalışmada, aktivasyon fonksiyonunun C^0 'ye ait olması ve polinom olmaması koşuluyla, yüksek dereceli sinir ağlarının, kompakt bir küme üzerindeki herhangi bir sürekli fonksiyona keyfi bir doğruluk derecesi ile yaklaşabileceğini kanıtlanmak istenmiştir. Bu teoriye göre, kısmen bağlantılı yüksek de-

receli sinir ağlarının, tam bağlı sinir ağlarının yapabildiği gibi, herhangi bir sürekli fonksiyona yaklaşabileceğini bilinmektedir. Bu bilgiye dayanarak, yaklaşık olarak aynı sayıda bağlantıyı sürdürürken birinci dereceden ağ ile karşılaştırma yapmak için kısmen bağlı yüksek dereceli bir ağ tasarlanmıştır. Teori, güneş lekeleri serisine uygulanarak doğrulanır ve simülasyon sonuçları, kısmen bağlantılı yüksek dereceli ağın birinci dereceden ağa kıyasla daha iyi yakınsama oranı ve genelleme yeteneği sergilediğini gösterilmiştir [36].

Diğer bir açıdan ele alındığında, borsa, doğası gereği karmaşıktır, dinamiğini ve rastgele dalgalanmalarını modellemek için bir araştırma konusu olmuştur. Yüksek mertebeden sinir ağı (HONN), girdi temsil alanını genişletmek, yüksek öğrenme yetenekleri ortaya koymak gibi yeteneklere sahiptir ve birçok karmaşık veri madenciliği problemini çözmek için kullanılmaktadır. Buna örnek olarak, hisse senedi verileri değerlendirme konusu olduğunda aşırı dalgalı oluşu, doğrusal olmayışı ve belirsizliği yakalamak için çalışma yapılmıştır. Bu çalışma, beş gerçek hisse senedi piyasasının kapanış fiyatlarının tahmini hesaplamak için iki uyarlanabilir evrimsel optimizasyon tabanlı pi-sigma sinir ağını (AE-PSNN) karşılaştırmaktadır. Bu çalışma için kısa, orta ve uzun vadeli tahminleri değerlendirmek için BSE, DJIA, FTSE, NASDAQ ve TAIEX hisse senedi endeksleri parametre olacak şekilde kullanılmıştır. AE-PSNN modellerinin performansı, gradyan iniş tabanlı PSNN (GD-PSNN) modelinin performansı ile karşılaştırılmış, tahmin doğruluğu ve yön değişikliği tahmini açısından üstün olduğu bulunmuştur [43].

Yüksek dereceli sinaptik işlemlere (NU-HSO'lar) sahip sinir birimlerini kullanan günlük nehir deşarjını tahmin etmek için yeni bir sinirsel modelleme metodolojisi de yapılan diğer çalışmalardan biridir. Hidrolojik tahmin için, literatürdeki mekanik yaklaşımlara dayanan geleneksel yağış-akış modelleri, aşırı parametrelendirme ve karmaşıklıklarına atfedilebilen sınırlamalar göstermiştir. İkinci dereceden sinaptik işlem (NU-QSO) ve kübik sinaptik işlem (NU-CSO) ile sinir birimlerinin kullanımı ile, rafine sinirsel modelleme metodolojisi, geleneksel modellerin karmaşıklığının ve verimsizliğinin üstesinden gelebilir. Yapılan çalışmada, nehir deşarjını tahmin etmek için NU-HSO'lu sinir ağı (NN) modelleri, lineer sinaptik işlemler (NU-LSO) sinir birimlerine sahip geleneksel NN'ler ile karşılaştırılmıştır. Bu çalışma, yüksek dereceli sinir ağlarının (HO-NN'ler) etkinliğini değerlendirmek için Naraj ölçüm sahasındaki Mahanadi Nehri havzasında 1 ila 5 günlük teslim süresi tahmini

kullanılarak gerçekleştirilmiştir. Günlük deşarj tahmininin tahminine yönelik performans endeksleri, NU-CSO'lu NN'lerin ve NU-QSO'lu NN'lerin daha az sayıda gizli nöronla bile NU-LSO'lu NN'lerden daha iyi performans gösterdiğini göstermiştir. Dolayısıyla bu çalışma, HO-NN'lerin hidrolojik tahminde etkili olabileceğini göstermektedir [56].

Otomatik hedef tanıma ve endüstriyel robotik görme gibi uygulamalar için örüntü tanımadaki en son teknoloji, dijital görüntü işlemeye dayanmaktadır. Otomasyon örüntü tanıma için dijital görüntü işleme, büyük matris işlemleri yoluyla gerçekleştirilen özellik çıkarmayı içeren, hesaplama açısından oldukça yoğundur. Nesneleri konumlarından, ölçeklerinden ve açısal yönelimlerinden bağımsız olarak tanımaya yönelik dijital teknikler, sayısal algoritmalarındaki matris denklemlerini hesaplamak için gereken uzun süre nedeniyle kolayca uyarlanamaz. Otomatik örüntü tanıma için gerekli olan tam özellik çıkarma örüntü sınıflandırma paradigmasını gerçekleştiren daha yüksek dereceli bir sinir ağı modeli yapılan çalışmalar arasındadır. Üçüncü dereceden bir sinir ağı kullanarak, ölçek, konum ve düzlem içi dönüş bozulmalarına karşı tam, %100 doğru değişmezliği gösterilmiştir. Daha yüksek dereceli sinir ağlarında, özellik çıkarımı ağda yerleşiktir ve öğrenilmesi gerekmez. Sadece basit sınıflandırma adımı öğrenilmelidir. Bu, çok hızlı bir eğitim elde etmenin anahtarını oluşturduğu öne sürülmektedir. Eğitim seti, standart sinir ağı yazılımından çok daha küçüktür, çünkü üst düzey ağa, öğrenilecek her nesnenin olası her görünümü değil, yalnızca bir görünümü gösterilmelidir. Yazılım ve grafiksel kullanıcı arayüzü, herhangi bir Sun iş istasyonunda çalışılabilir seviyededir. Ayrıca, sinirsel yazılımın otonom bir robotik görme sisteminde kullanımının sonuçlarına da değinilmiştir. Bu tür bir sistem, robotik üretiminde kapsamlı bir uygulamaya ihtiyaç duyabileceği ortaya konulmuştur [49].

2.1.2.1 Pi-Sigma Sinir Ağları


Ghosh ve Shin, normal olarak daha yüksek dereceli ağlarla ilişkilendirilen ağırlıkların ve işlem birimlerinin sayısındaki üstel artışı önleyen 'pi-sigma' ağı olan başka bir yüksek dereceli ağı ilk tanıtan olarak bilinirler [21]. Pi-sigma terimi, bu ağların girdi bileşenlerinin toplamalarının ürünlerini kullanması gerçeğinden gelir. PSN'ler yalnızca bir ayarlanabilir ağırlık katmanına sahip olmakla birlikte, çıktı katmanının ağırlıkları normal olarak 1'de sabitlenmektedir, bu da PSN'lerin hızlı öğrenmesiyle sonuçlanmaktadır [21]. Bir pi-sigma

ağının çıktısı aşağıdaki gibi hesaplanır,

$$O_k = f\left(\prod_{j=1}^J y_{kj}\right) \quad (3)$$

$$y_{kj} = \sum_{i=1}^I w_{kji} x_i \quad (4)$$

burada f aktivasyon fonksiyonudur, $X_i, \dots, X_I$ giriş sinyalleridir, X_{i+1} öngerilim birimine bir giriştir, W_{kji} kth çıkış birimi için giriş birimi X_i ve gizli birim Y_{kj} arasındaki ağırlıktır $O_k, W_{k,j,l+l}$ eşik (veya sapma), y_{kj} gizli Y_{kj} biriminin çıktısıdır ve o_k, O_k çıktı biriminin çıktısıdır. Her bir gizli birim, Y_{kj} 'deki k alt simgesiyle gösterildiği gibi sadece bir çıkış birimine bağlı olmaktadır. Bu nedenle denklem 3 ayrıca çoklu çıkış PSN'leri için her bir çıkış birimi için bağımsız bir toplama biriminin gerekli olduğunu gösterir. PSN'ler, ağa giriş sayısı arttıkça daha yüksek dereceli terimlerin birleşimsel patlamasını gösterir.



Şekil 5: Pi-Sigma Sinir Ağı Modeli [21].

Şekil 5, tipik bir Pi-Sigma ağını göstermektedir; burada W_{ij} , giriş birimi x_i ve gizli birim h_k , fe arasındaki ağırlıktır) çıkış birimlerine uygulanan standart lojistik fonksiyon-

dur ve çıkış birimine giden tüm ağırlıklar 1'e sabitlenmiştir. Gizli katman, toplama birimlerinden ve çarpım birimleri de çıktı katmanından oluşmaktadır. Y_{kj} , kth çıkış biriminin lh toplama biriminin çıkışını ifade eder. Gizli birimler için doğrusal bir aktivasyon olduğu varsayılmaktadır. Bir PSN, bir güç serisinin yalnızca sınırlı bir yaklaşımını sağlar, bu da PSN'nin kompakt bir kümede tanımlanabilen tüm sürekli çok değişkenli işlevleri tek biçimli olarak yaklaşmamasına neden olur. Bununla birlikte, farklı sıradaki birkaç PSN'nin çıktılarının toplanmasıyla evrensel yaklaşım elde edilebilir. Ortaya çıkan PSN ağına Ridge Polinom Ağı denir. Bir PSN, doğrusal olmayan etkinleştirme işlevlerini kullanarak hem analog hem de ikili giriş/çıkış olacak şekilde kullanılabilir. Lojik boyuttaki işlevi, doğrusal olmayan bir etkinleştirme işlevi olarak kullanılabilir ve ikili çıkışlar için işaret veya eşikleme işlevi görebilir. Ghosh ve diğerleri araştırmacılar tarafından PSN için kullanılan öğrenme kuralı, gradyan iniş prosedürünün rastgele olduğu bir versiyonudur. Bir PSN'nin her eğitim döngüsü esnasında, rastgele bir toplama birimi seçilmekte olup, bu toplama birimiyle ilişkili tüm ağırlıklar, gradyan inişi kullanılarak güncellenmektedir. Her eğitim döngüsünde tüm ağırlıklar yerine yalnızca bir ağırlık alt kümesini güncellemeye yönelik bu değişiklik, bir PSN'nin eğitim süresinin azalmasına neden oldu. Bu noktada, sadece üç veya dört toplama birimi kullanan pi-sigma ağlarının oldukça karmaşık yaklaşım ve sınıflandırma problemlerinin üstesinden gelebileceği de düşünülmüştür [21].

1991 yılında yapılan bir çalışmada, Pi-sigma ağı daha az sayıda ağırlık ve işlem birimi kullanırken daha yüksek dereceli ağların yeteneklerini dolaylı olarak dahil etmek için çıktı birimleri olarak ürün hücrelerini kullanır. Ağ düzenli bir yapıya sahiptir, çok daha hızlı öğrenme sergiler ve istenen karmaşıklık düzeyine ulaşmak için birimlerin kademeli olarak eklenmesine uygundur. Yapılan çalışmanın sonuçları, fonksiyon yaklaşımı için iyi yakınsama özellikleri ve doğruluğu gösterir. Pi-sigma ağlarının sınıflandırma yeteneklerini vurgulamak ve değerlendirmek için DARPA akustik geçici veri setini kullanan karşılaştırmalı sonuçlar oluşturulmuş ve değerlendirilmiştir [54].

Diğer bir çalışmada ise, Pi-sigma sinir ağını eğitmek için hibrit bir genetik öğrenme algoritması kullanılmış olup, bu algoritma, bir fonksiyon optimizasyon problemini çözmek için kullanılmıştır. Hibrit genetik öğrenme algoritması, daha güçlü global genetik algoritma aramasına kıyasla, esnek polihedron yönteminin daha güçlü yerel minimum ara-

masını dahil etmektedir ve global optimum noktasına standart genetik algoritmadan daha hızlı bir şekilde ulaşmaktadır. Yapılan çalışmalar, hibrit genetik algoritmanın daha iyi performans elde edebileceğini göstermektedir. Sonunda, hibrit genetik algoritmanın 1 olasılıkla global optimuma yakınsadığı kanıtlanmıştır [44].

Sıcaklık tahminin yapılmak istendiği diğer bir çalışmada ise temel amaç, tek adımlı sıcaklık tahmini için Pi-Sigma Sinir Ağı modelini yaygın olarak kullanılan Çok Katmanlı Algılayıcı (MLP) ile karşılaştırarak Pi-Sigma Sinir Ağları (PSNN)'nin performanslarını değerlendirmektir. Yüksek Dereceli Sinir Ağlarının (HONN) bir sınıfı olan PSNN, oldukça düzenli bir yapıya sahiptir, çok daha az ağırlık ve daha az eğitim süresi gerektirir. PSNN, yerel minimumlara kolayca sıkışabilen ve aşırıya kaçmaya meyilli olan MLP'nin dezavantajlarının üstesinden gelmek için kullanılır. Her iki ağ modeli de standart geri yayılım algoritması ile eğitilmiştir. Batu Pahat bölgesinin geçmiş sıcaklık verileri kullanılarak PSNN'nin yüksek bir uygulanabilirliğe ve bir adım ileri için daha iyi sıcaklık tahminine sahip olduğu gösterilmiştir [24].

Sinir ağlarındaki hızlı gelişme nedeniyle son birkaç yıldır bilim camiasında en önemli araştırma alanı olarak ortaya çıkmaktadır. Uzun eğitim süresi ve doğrusal olmayan verilerle başa çıkamama gibi sinir ağlarının sınırlamalarının üstesinden gelmek için, araştırmacı-

lar daha yüksek dereceli sinir ağlarına yönelmiştir. Daha az sayıda işlem birimi kullanan daha yüksek dereceli sinir ağının doğrusal olmayan haritalama yeteneği, çeşitli sınıflandırma yöntemlerinin üretkenliğinde ve performansında büyük artışa yol açmıştır. Pi-sigma sinir ağı adı verilen yüksek dereceli bir sinir ağının kapsamlı bir analitik çalışması ve sınıflandırma, tahmin, fonksiyon yaklaşımı, örüntü tanıma gibi çeşitli uygulama alanlarındaki varyasyonları incelemiştir. Ayrıca, yapılan çalışmada ayrıca çeşitli uygulama alanlarında Pi-sigma sinir ağının üstünlüğünü tanımlamak için araştırma alanındaki zorluklara ve çeşitli konulara odaklanmaktadır [55].


2.1.2.2 Sigma-Pi Sinir Ağları

Bir sigma-pi sinir ağının gizli katman birimleri, girdilerin bir çarpımını(veya birleşimini) hesaplamaktadır [22]. Sigma-pi sinir ağlarında, yalnızca her bir girdiye değil, aynı za-

manda ikinci ve muhtemelen daha yüksek dereceli çarpımlara veya girdilerin birleşimlerine de bir ağırlık uygulanmaktadır. Sigma-pi sinir ağlarındaki bağlantılar, bir birimin diğerine geçit vermesi noktasında kolaylık sağlamaktadır. Bu nedenden dolayı, çarpımsal bir birim çiftinin bir birimi sıfırsa, diğer üyenin çıktı üzerinde hiçbir etkisi olmamaktadır. Öte yandan, bir çiftin bir birimi 1 değerine sahipse, diğer birimin çıkışı değişmeden alıcı birime iletilir. Bu şekilde girdilerin bir polinom fonksiyonu çıktı katmanının transfer fonksiyonuna girdi olarak sunulur, yani çıkış biriminin değeri O_k

$$O_k = f\left(\sum_{q \in \text{conjunct}} w_q \prod_{k_j=1}^N z_{qk}\right) \quad (5)$$

burada f aktivasyon fonksiyonu, W_{qk} bir sinaptik ağırlık, $X_{q1}, X_{q2}, \dots, X_{qN}$, ürünü veya bağlacı oluşturmak için birleştirilen N giriş sinyalidir ve q, k biriminde kullanılan bağları veya ürünleri indeksler; bağlaç, girdiler için tüm alt simge bağlaçlarının kümesidir. Denklem 5’de türetilen mimari, daha yüksek dereceli ağlar oluşturma yöntemini sunar.



Şekil 6: Sigma-Pi Sinir Ağı örneği [66]

Şekil 6, gizli katmanda toplama yerine çarpmanın gerçekleştirildiği, ardından çıkış katmanında bir toplama biriminin takip edildiği iki girişli bir sigma-pi ağını göstermektedir. Bu, örneğin, $Y_2 = X_1 X_2$ ve $Y_1 = X_1$ 'dir, burada Y_j , y_j gizli biriminin çıktısıdır. Gizli birim y_j ile çıkış birimi O_k arasındaki ağırlık W_{kj} ile gösterilmekte olup, sigma-pi ağlarında girişlerin polinom bir fonksiyon çıkış katmanı aktivasyon fonksiyonuna girilmektedir.

$$O_1 = f(w_{11}y_1 + w_{12}y_2 + w_{13}y_3) = f(w_{11}x_1 + w_{12}x_1x_2 + w_{13}x_3) \quad (6)$$

Terimler girdilerin çarpımlarını içermesine rağmen, her girdinin birden fazla kuvveti olmaması, bu tür ifadelerdeki terimleri için çoklu doğrusal adının ortaya çıkmasına neden olur. Çoklu doğrusal parametrelere sahip düğümleri aktivasyonları birden büyük olan terimlere bağlı olduğundan dolayı, daha yüksek dereceli düğümler olarak da isimlendirilirler. Sigma-pi birimleriyle ilgili sorun, terimlerin sayısının ve dolayısıyla ağırlıkların girdi sayısıyla çok hızlı bir şekilde artması ve dolayısıyla birçok durumda kullanım için kabul edilemez ölçüde büyük hale gelmesidir [22]. Bu nedenle, bu tip mimarinin avantajı, eğer bağlamlar elle kodlanmazsa, ağırlık sayısında bir kombinasyonel patlamaya neden olabilir. Bu konu üzerine çalışan bilim insanları, verilen görevle ilgili ön bilgileri kullanarak, birim sayısını, diğer bir deyişle terim sayısını, istenilen doğruluk derecesine ulaştırabilmek için yeterli bir konfigürasyonla sınırlayarak bu sorunla mücadele etmeyi amaçlar. Normalde, bu terimlerden sadece biri veya birkaçı sinir ağılarıyla ilgili olmaktadır. En iyi mimariyi belirlemeye yönelik en yaygın kullanılan yaklaşım yöntemi, ağı aşamalı olarak büyümesidir. Bu yaklaşımda, birkaç terimden oluşan bir başlangıç ağı seçilmiş olup, mevcut mimari kullanılarak hata azaltılmadığı durumda ağa yeni terim eklenmiştir. Bu artımlı büyüme süreci, istenen hata düzeyine veya doğruluğa ulaşılan kadar devam etmektedir. Sigma-pi sinir ağı modelinin literatürdeki çalışmalarına örnekler incelendiğinde karşılaşılan çalışmalar şu şekilde özetlenebilir;

Sınıflandırma problemlerinde sigma-pi yapay sinir ağıları için mantıksal hata düzeltme yöntemlerinin uygulanması ele alınmaktadır. Mantıksal yöntemler, incelenen bir alandaki örtük düzenliliklerin tespitinde yaygın olarak kullanılmaktadır. Sigma-pi nöronunun yapısına göre bu tür düzenlilikleri ortaya çıkarmak için bir teknik önerilmiştir. Bu, özellikle tanıma sisteminin uyarlanabilir özelliklerini geliştirir. Kombine bir yaklaşımın tanıma sistemi performanslarına katkıda bulunduğunu iddia edilmiştir. Sigma-pi nöronlarının yanlış tepki vermesi durumunda mantıksal bir düzeltme yöntemi kullanılarak tanımlanan karakteristik özelliklerle en yakın nesneleri istenene göstererek çözüm olarak sağlanmaktadır [39].

Geçmişe bakıldığında hava tahmini halen bir sanattır ve tahmincilerin deneyimi ve sezgileri, tahminleme kalitesinin belirlenmesinde önemli bir rol oynamaktadır. Yapılan çalışmalarda, sinir ağlarını kullanarak yağış tahmini için yeni bir yaklaşımın geliştirilmesi

anlatılmaktadır. Kısa vadeli yağış tahmini göz önünde bulundurulduğunda radar görüntülerinden bilgilerin çıkarılması ve geçmiş yağmur ölçer kayıtlarının değerlendirilmesi için bir çalışma yapılmıştır. Bu çalışmada, tüm meteorolojik veriler Hong Kong Kraliyet Gözlemevi (ROHK) tarafından sağlanmaktadır. Bu sinir ağı yağış tahmini için veri öncelikle ön işleme prosedürlerine tabi tutulmuştur. Yağış tahmini, halka önceden bir fırtına uyarı sinyalinin iletilmesi için her yarım saatte bir yapılmıştır. Ağ mimarisi, tekrarlayan bir Sigma-Pi ağından oluşmaktadır. Sonuçlar çok umut verici ve bu sinirsel tabanlı yağış tahmin sistemi, Hong Kong halkına bir saat önceden yağmur fırtınası uyarı sinyali sağlayabiliyor hale gelmiştir [14].

Sigma-pi yapay sinir ağı kullanılarak duygu durumu tanıma problemleri de ele alınan çalışmalar arasındadır. Bahsi geçen bu sinir ağının kendine özgü özelliği, sigmoid ve çan biçimli iki farklı tipte aktivasyon fonksiyonundan oluşmasıdır. Sigma-pi ağı için bir öğrenme algoritması öne sürülmüş olup, bu algoritma, özellikle gerçek zamanlı olarak doğrusal olmayan süreçlerde yüksek yaklaşım doğruluğu ile ön plana çıkmıştır. Görüntü veri seti üzerinde eğitim ve test işlemleri gerçekleştirilip, değerlendirilmiştir [34].

Uçakların performansı ve kararlılığı, uçuş kontrolörünün yerleşik aerodinamik modeline duyarlıdır. Aşırı önyargı, ölçek faktörü veya tesisi etkileyen gürültü ile aerodinamik belirsizlik nedeniyle, küçük bir uçak tipik olarak sağlam bir uçuş kontrol sistemi tasarlamak için gereken modelleme doğruluğundan yoksundur. Bu eksiklikler, uyarlanabilir bir doğrusal olmayan kontrol yasası ile zenginleştirilmiş geleneksel bir doğrusal kontrol yasasının uygulanmasıyla aşılabılır. Geri beslemeli doğrusallaştırmaya sahip doğrusal olmayan bir dinamik ters çevirme kontrol yasası kararlıdır ancak modele modelleme belirsizliği eklendiğinde performanstan yoksundur. Hatalı ve modellenmemiş dinamikleri tahmin etmek için geleneksel yaklaşımlı bir sinir ağı ile dengelemek, daha önce uçak tarafından görülmeyen uçuş içi rejimler için bile sağlam bir kontrol tasarımı sağlamaktadır. Bu noktada yapılan çalışmada, uçak hız/irtifa kontrolünde hem motor hızı hem de asansör komutlarına uyum sağlamak için Sigma-Pi Sinir Ağları (SPNN) kullanımı araştırılmıştır. Sinir ağı modelinin eğitimi, özyinelemeli en küçük kareler tahmincisi (RLSE) kullanılarak gerçekleştirilmiştir ve SPNN kontrol tasarımları altı serbestlik derecesi (6DOF) dijital simülasyon üzerinde doğrulanmıştır [30].

Normal eğitim setlerinde mükemmel performans gösterebilmek için gizli katmanda sigma-pi birimleri ile üç katmanlı ileri beslemeli sinir ağlarının nasıl tasarlanacağına ilişkin çalışma yapılmıştır. Bu çalışmada, büyük ölçüde paralel örneklemeyle dayanmakta olan ve hiperbolik kardinal öteleme tipi enterpolasyon operatörleri tarafından indüklenmekte olan gerçek zamanlı tasarım modellerine değinilmiştir. Temel strateji gerçek zamanlı doğası, sinir ağı dilinde yaklaşım genel ve verimli tek seferlik öğrenme şemasından başka bir şey olmamasından kaynaklanmaktadır. Ayrıca, sigma-pi birimleri özel hiperbolik yapısı nedeniyle, genel olarak daha yüksek mertebeli ağlarda meydana gelen olağan dramatik parametre ve ağırlık artışına sahip olmamaktadır. Nihai ağlar yönetilebilir karmaşıklığa sahip olmakla birlikte, çok gruplu diskriminant problemlerine, görüntü tanıma ve görüntü işleme alanlarına uygulanabilir. Ayrıntılı olarak, XOR-problemi ve özel bir çoklu grup diskriminant problemi de bu çalışmanın konusu olmaktadır [24].

2.2 Regresyon Yöntemleri

Bir regresyon modelinin amacı çok basittir: bir veya daha fazla sayı girdi olarak alındığında, belirli işlem sonucunda farklı bir sayı elde etmektir. Basitten karmaşık fonksiyonlara kadar bu işlemi gerçekleştirmenin birçok yolu vardır. En basit durum doğrusal regresyondur. Çıktı bazı eğitim hatalarını en aza indirmek için seçilen katsayılarla, girdi değişkenlerinin doğrusal bir kombinasyonudur. Pek çok bağlamda bunun gibi basit bir model yeterli olacaktır, ancak değişkenler arasındaki doğrusal olmayan ilişkilerin ilgili olduğu durumlarda başarısız olacaktır. Gerçek hayat verileri bu duruma örnek olarak verilebilir. Model karmaşıklığı spektrumunun diğer tarafında bir sonuç vermeden önce girdi verilerini bir dizi hesaplamayla dönüştüren sinir ağları gibi kara kutu regresörleri de bulunmaktadır. Bu modeller, bir gün genel bir yapay zeka ile sonuçlanacakları vaadi ile bilgisayar görüşü gibi zor problemlerde çarpıcı başarıları nedeniyle günümüzde oldukça popülerdir.

2.2.1 Sembolik Regresyon Yöntemi

Doğrusal regresyon veya polinom regresyon kavramının bir genellemesi şeklinde ifade edilebilir. Girdi değişkenlerini kullanarak çıktı değişkenlerinin en iyi şekilde tahmin ede-

bilenler için olası tüm matematiksel formüllerin uzayını aramaya çalışmaktır. Toplama gibi bir dizi temel fonksiyonlardan başlayarak trigonometrik fonksiyonlar ve üstel fonksiyonlara kadar arama sıklası genişletilebilir. Sembolik bir regresyon optimizasyonunda, aynı doğruluğa sahip daha küçük bir formülle karşılaşırsa karmaşık olanın bir önemi kalmayacaktır. Bu yöntem, 2009 yılında ilgili formülleri aramak için genetik bir algoritma geliştirilmiştir. Bu yazılım nihayetinde ampirik verilerden yeni fizik yasaları çıkarmak için kullanılabilceği vaadiyle ün kazanmıştır [17]. Sembolik regresyon konusunu baz alarak kullanıldığı alanlara değinildiğinde, Bal arısı sürülerinin akıllı yiyecek arama davranışını simüle eden yapay arı kolonisi algoritması, en popüler sürü tabanlı optimizasyon algoritmalarından biridir. 2005 yılında tanıtılmış ve bugüne kadar farklı sorunları çözmek için çeşitli alanlarda uygulanmıştır. Sembolik regresyon üzerine yeni bir yöntem olarak Yapay Arı Kolonisi Programlama (ABCP) olarak adlandırılan yapay bir arı kolonisi algoritması ilk kez anlatılmaktadır. Sembolik regresyon, bağımsız değişkenlerin değerlerinin ve bağımlı değişkenlerin ilgili değerlerinin verilen sonlu örneklemesini kullanmakla birlikte matematiksel bir model elde etme süreci halinde tanımlanabilir. Bu çalışmada, yapay arı kolonisi programlama kullanılarak bir dizi sembolik regresyon kıyaslama problemi çözülmüş ve daha sonra performansı, çok iyi bilinen bilgisayar programlarını geliştirme yöntemi olan genetik programlama ile karşılaştırılmıştır. Simülasyon sonuçları, önerilen yöntemin, sembolik regresyonun dikkate alınan test problemlerinde oldukça uygulanabilir ve sağlam olduğunu göstermektedir [26]. Korunan operatörlerin kullanımı ve kare hata ölçüleri göz önünde bulundurulduğunda, sembolik regresyonda standart yaklaşımlardan birini oluşturmaktadır. Bir sembolik regresyon sisteminin küçük iki modifikasyonunun, büyük ölçüde geliştirilmiş tahmin performansı ve indüklenen ifadelerin güvenilirliği ile sonuçlanabileceği öne sürülmüştür. Bu noktaya ulaşmak için aralık aritmetiği ve doğrusal ölçekleme kullanılmıştır [27]. Rastgele sembolik ifadelerin çıktıları üzerinde doğrusal bir regresyon gerçekleştirmenin ampirik olarak büyük faydalar sağladığı ilgi konusu olmuştur. Burada lineer regresyonun bazı temel teorik sonuçlarına değinilecek olduğunda, sembolik regresyonda kullanım için uygulanabilirlikleri konusunda gözden geçirilmesi gerektiği düşünülmektedir. Ölçeklemeden sonra hatanın hesaplandığı ölçeklendirilmiş bir hata ölçüsünün kullanılmasının, tüm olası sembolik regresyon problemlerinde ölçeklenmemiş

muadilinden daha iyi performans göstermesinin beklendiği kanıtlanacaktır. Yöntem (i) bir sembolik regresyon çalışmasına ek parametreler getirmediğinden, (ii) çoğu sembolik regresyon probleminde sonuçları iyileştirmesi garanti edilir (ve başka hiçbir problemde daha kötü değildir) ve (iii) iyi tanımlanmış bir hatanın üst sınırı, ölçeklenmiş karesel hata, sembolik regresyonun pratik uygulamaları için standart hata ölçüsü olmak için ideal bir adaydır [28]. Bu bölüm, mevcut en gelişmiş sembolik regresyon motorlarında doğruluğun zayıf olduğunu iddia ediyor. Başka bir deyişle, son teknoloji sembolik regresyon motorları, iyi bir kondisyona sahip bir şampiyon döndürür; ancak, doğru formüle sahip bir şampiyon elde etmek, minimal karmaşık dilbilgisi derinliğine sahip tek bir temel işlev durumunda bile olası değildir. İdeal olarak, kullanıcılar gürültü olmadan, yalnızca belirtilen dilbilgisindeki işlevleri kullanarak, yalnızca bir temel işlevle ve bazı minimum dilbilgisi derinliğiyle oluşturulan test problemlerinde, son teknoloji sembolik regresyon sistemlerinin tam formülü (veya en azından bir izomorf) test verilerini oluşturmak için kullanılır. Ne yazık ki, bu beklenti şu anda yayınlanmış son teknoloji sembolik regresyon teknikleri kullanılarak elde edilememektedir. İnatçı olduğu kanıtlanan birkaç test formülü sınıfı incelenir ve neden inatçı olduklarına dair bir anlayış geliştirilir. Soyut ifade dilbilgisindeki teknikler, ayrı popülasyon adalarında çoklu hedefli epigenomların üremesi ile birlikte, evrimsel süreç sırasında epigenomun manipülasyonu da dahil olmak üzere, bu sorunları izlenebilir kılmak için kullanılır. Halihazırda zorlu olan seçilmiş bir dizi problemin, bu teknikleri kullanarak çözülebilir olduğu gösterilmiştir ve son teknoloji sembolik regresyon sistemlerinde doğruluğu geliştirmek için disiplin çapında bir program için bir öneri ileri sürülmüştür [33]. Sembolik Regresyon (SR), genetik programlama (GP) için yaygın bir uygulamadır. Sembolik regresyon için, gerçek dünya problemlerinde yetkin GP yaklaşımlarıyla karşılaştırıldığında, büyüklük sıraları daha hızlı olan (sadece birkaç saniye süren), daha basit modeller döndüren, görünmeyen veriler üzerinde karşılaştırılabilir veya daha iyi tahminlere sahip olan ve evrimsel olmayan yeni bir teknik sunmaktadır. Güvenilir ve deterministik olarak yakınsamakta olduğu önesürülmüştür. Hızlı İşlev Çıkarma için FFX yaklaşımını adlandırılmaktadır. FFX, büyük bir dizi aday temel işlevi kompakt modellere kadar hızla indirgemek için yeni geliştirilmiş bir makine öğrenimi tekniği, yola dayalı düzenli öğrenme kullanılmıştır. FFX, 13 ila 1468 girdi değişkenine sahip, GP'den

daha iyi performans gösteren ve aynı zamanda birkaç son teknoloji regresyon tekniğine sahip geniş bir gerçek dünya problemlerinde doğrulanmıştır [40]. Billard ve Diday 2000 yılında yaptığı çalışmalarında, sembolik aralık değerli verilere bir regresyon denklemi uydurmak için prosedürler geliştirmiştir. Yapılan bu çalışmada, yaklaşım klasik teknikler kullanılarak birkaç olası alternatif modelle karşılaştırılmıştır. Karşılaştırma sonucunda, sembolik regresyon yaklaşımı tercih edilmiştir. Bu sonuçtan dolayı, sembolik histogram değerli veriler için bir regresyon yaklaşımı sağlanmış olmuştur. Sonuçlar bir tıbbi veri seti ile test edilip değerlendirilmiştir [9]. Diğer bir çalışmada ise, genetik programlamaya (GP) dayanan bir sembolik regresyon uygulaması sunulmaktadır. Ne yazık ki, GP'nin derlenmiş dillerdeki standart uygulamaları genellikle en verimli olanları değildir. Mevcut yaklaşım, geleneksel GP uygulamalarıyla karşılaştırıldığında daha fazla basitlik ve daha iyi performans sağlayan doğrusal kodunu kullanarak ağaç benzeri yapılar için basit bir temsil kullanır. Bireylerin yaratılması, çaprazlanması ve mutasyonu resmileştirilmiştir. Rastgele katsayıların oluşturulmasına izin veren bir uzantı sunulmuştur. Önerilen uygulamanın etkinliği, çalışmada özetlenen hesaplama deneylerinde onaylanmıştır [3]. Makine öğrenimi modelleri oluşturulurken faydalı özellikler ortaya çıkarmak, makine öğrenimi uygulayıcısı için temel görev haline gelmiştir. İyi ve başarılı özellikler sadece bir modelin tahmin gücünü arttırmakla kalmayıp, aynı zamanda bir hedef değişkenin altında yatan itici güçleri aydınlatmada da fayda olduğu öne sürülmüştür. Yapılan bir diğer çalışmada, Sembolik regresyonun zaman içinde değişkenler toplamının fonksiyonları keşfedilmesi için izin veren bir "Aralık Terminali" ile donatıldığı yeni bir özellik öğrenme yöntemi önerilmiştir. Range Terminal'i, Kuzey Kutbu'nun bir bölümünde uydudan elde edilen sıcaklık ve kar verilerini kullanarak mevsimsel yeşilliği tahmin ettiği sentetik bir veri setidir ve gerçek dünya verileri üzerinde test işlemi gerçekleştirilmiştir. Sentetik veri setinde, Menzil Terminali ile Sembolik regresyonun standart Sembolik regresyon ve Kement regresyonundan daha iyi performans gösterdiğini görülmektedir. Arctic veri setinde, standart Sembolik regresyondan daha iyi performans gösterdiğini, Kement regresyonunu geçemediğini, ancak Arktik'teki Kara Yüzey Sıcaklığı, Kar ve mevsimsel vejetatif büyüme arasındaki etkileşimi tanımlayan faydalı özellikler bulduğunu önesürülmüştür [20]. Gizli akış fiziğini ayrık ve seyrek gözlemlerden damıtmak için modüler bir yaklaşım ortaya koyduk. Kara kutu ma-

kine öğrenimi yöntemlerinin önemli bir sınırlaması olan işlevsel ifade edilebilirliği ele almak için, temel süreçlerle ilgili ilişkileri ve operatörleri tanımlamak için bir ilke olarak sembolik regresyon kullanımı önerilmiştir. Bu noktada bahsi geçen yaklaşım, Euler referans çerçevesindeki akışkan akışlarının yörüngesine gömülü gizli parametreleştirmeleri ortaya çıkarmak için evrimsel hesaplamayı birleştirmektedir. Bu çalışmadaki yaklaşım, temel olarak gen ekspresyon programlaması (GEP) ve sıralı eşik ridge regresyon (STRidge) algoritmalarından oluşmaktadır. Sonuçlar üç farklı aşamada değerlendirilmektedir (i)denklem keşfi, (ii)kesme hatası analizi ve (iii)hem bir dizi seyrek gözlemden bilinmeyen kaynak terimlerini tahmin etmeyi hem de alt ızgara ölçeği kapanmasını keşfetmeyi dahil edildiği gizli fizik keşfi modellerini kullanmaktadır. Hem GEP hem de STRidge algoritmalarının Kraichnan türbülans problemini çözmede Smagorinsky modelini bir dizi uyarlanmış özelliğinden arındırıldığı gösterilmiştir. Sonuçlar, karmaşık fizik problemlerinde test edilmiş olup, bu tekniklerin büyük potansiyelini göstermekte ve model keşif yaklaşımlarında özellik seçiminin önemini ortaya koymaktadır [59].

Son zamanlarda ise sembolik regresyon kullanarak aşırı öğrenme mekanizmalarının başarısı yüksek derecede artırılmış [32] sistem tanılamada kullanılmıştır. Aynı şekilde robotik modelleme ve öngörülü kontrol ile kullanılarak tanılama temelli kontrol yapılmıştır [8].

2.3 Parametre Optimizasyon Yöntemi

Sosyal hayatta, yatırımcılar yüksek getiri oranı elde ederken aşırı riskten kaçınan portföyler oluşturmaya çalışırlar. Üreticiler, üretim süreçlerinin tasarımında ve işletilmesinde maksimum verimliliğe ulaşmayı hedeflemektedirler. Mühendisler ise, tasarımlarının performansını optimize etmek için parametrelerin ayarlanmasıyla ilgilenmektedirler. Fiziksel sistemler minimum enerji durumuna eğilim göstermektedirler. İzole bir kimyasal sistemdeki moleküller gibi, elektronların da toplam potansiyel enerjisi en aza indirilene kadar birbirleriyle reaksiyona girdiği gözlemlenir. Işık ışınları seyahat sürelerini en aza indiren kadar yolları takip etmeye devam ederler. Optimizasyon, karar biliminde ve fiziksel sistemlerin analizinde de önemli bir araç olarak kullanılmaktadır. Bu aracı kullanmak için, öncelikle incelenen sistemin performansının nicel bir ölçüsü olan bazı hedef-

lerin belirlenmesine değinilmesi gerekmektedir. Bu amaç, zaman, kâr potansiyel enerji veya tek bir sayı ile temsil edilebileceği gibi herhangi bir miktar veya miktar kombinasyonu da olabilir. Temel amaç, sistemin değişkenler veya bilinmeyen parametreleri olarak adlandırılan belirli özelliklerine bağlı olmasıdır. Ulaşılmak istenilen, sonucu optimize eden değişkenlerin değerlerinin bulunması durumudur. Çoğu zaman değişkenlerin bir şekilde kısıtlandığı görülmektedir. Örnek verilecek olunursa, bir moleküldeki elektron yoğunluğu ve bir kredideki faiz oranı gibi nicelikler negatif değer olamamaktadır. Belirli bir problem için temel amaç, değişkenleri ve kısıtlamaları belirleme sürecinin kısıllığı ve verimliliğidir. Uygun bir modelin oluşturulabilmek için, optimizasyon sürecindeki ilk adım, bazen de en önemli adımı oluşturmaktadır. Model çok basit olduğu takdirde, pratik problem hakkında faydalı bilgiler verilemeyecektir. Çok karmaşıksa, çözülmesi çok zor hale gelecektir. Model formüle edildikten sonra, genellikle bir bilgisayar yardımıyla çözümünü sağlanacak ve bir optimizasyon algoritması kullanılacaktır. Evrensel bir optimizasyon algoritması olmamakla birlikte, bunun yerine her biri belirli bir optimizasyon problemine uyarlanmış algoritmalar topluluğu bulunmaktadır. Belirli bir uygulamaya uygun algoritmayı seçme sorumluluğu genellikle kullanıcıya düşer. Bu seçim, sorunun hızlı mı yoksa yavaş mı çözüleceğini ve gerçekten de çözümün bulunup bulunmadığını belirleyebileceği için önemli bir seçimdir. Modele bir optimizasyon algoritması uygulandıktan sonra, modelin bir çözüm bulma görevinde başarılı olup olmadığı anlaşılabilir. Çoğu süreçte, mevcut değişkenler kümesinin gerçekten de sorunun çözümü olup olmadığını kontrol etmek için optimallik koşulları olarak bilinen zarif matematiksel ifadeler incelenmektedir. Optimallik koşulları sağlanmadığı durumda, en azından çözümün mevcut tahmininin nasıl iyileştirilebileceği konusunda faydalı bilgiler sunulabilmektedir. Çözümün modeldeki ve verilerdeki değişikliklere duyarlılığını ortaya koyan duyarlılık analizi gibi teknikler uygulanarak model geliştirilebilir. Çözümün uygulama açısından yorumlanması noktasında ise, modelin iyileştirilebileceği veya düzeltilebileceği yollar da önerebilir. Modelde herhangi bir değişiklik yapıldığı durumda optimizasyon problemi yeniden çözülmektedir ve süreç tekrarlanmaktadır [45]. Matematiksel olarak değinildiğinde, optimizasyon, değişkenleri üzerindeki kısıtlamalara tabi bir fonksiyonun minimizasyonu veya maksimizasyonudur. x bilinmeyenler veya parametreler olarak da adlandırılan değişkenlerin vektörüken, f

maksimize etmek veya minimize etmek istediğimiz x 'in bir (skaler) fonksiyonu olan amaç fonksiyonudur. c_i , x 'in bilinmeyen vektörünün karşılması gereken belirli denklemleri ve eşitsizlikleri tanımlayan skaler fonksiyonları olan kısıt fonksiyonlarıdır.

$$\min(f(x))_x \in R_n \quad (7)$$

$$c_i(x) = 0, i \in \epsilon \quad (8)$$

$$c_i(x) \geq 0, i \in I \quad (9)$$

Burada I ve ϵ , sırasıyla eşitlik ve eşitsizlik kısıtlamaları için indeks kümeleridir. Yukarıdaki optimizasyon problemi, karar değişkenlerinin "en iyi" vektörü x 'in tüm olası vektörler üzerinde setin içinde bulunmasını içeren bir karar problemi olarak görülebilir. "En iyi" vektör ile amaç fonksiyonunun en küçük değeriyle sonuçlanana kastedilmektedir. Çok sayıda küçültücü olması mümkündür. Bu durumda, küçültücülerden herhangi birini bulmak yeterli olacaktır [13]. Genel olarak bakıldığında modelde koşulu sağlayacak en uygun minimum noktayı bulabilmek için gradient tabanlı bir çok arama yöntemi geliştirilmiştir. Bu yöntemlerin çoğu doğrusal sistemlerde büyük başarılar elde etmiştir. Fakat veri boyutu arttıkça büyük gradient matrislerin hesaplanması zorlaşmış olmakla birlikte doğrusal olmayan sistemlerde iyi başarı sergileyemedikleri görülmüştür [45].

2.3.1 Levenberg-Marquardt Yöntemi

Levenberg-Marquardt Optimizasyonu, orta ölçekli problemler söz konusu olduğunda gradyan iniş ve eşlenik gradyan yöntemlerinden ziyade önemli ölçüde daha iyi performans gösterebilen ve doğrusal olmayan optimizasyon işlemlerinde bir standardı oluşturmaktadır. Bu yöntem, sadece fonksiyon hesaplamaları ve gradyan bilgisi ile çalışmaktadır, fakat gradyanların dış çarpımlarının toplamını kullanarak Hessian matrisini tahmin ettiği için sözde ikinci dereceden bir yöntemi ifade etmektedir [51]. Marquardt, bu yöntemi, tahmini yerel eğrilik bilgilerinin akıllıca dahil edilmesiyle geliştirmiştir ve Levenberg-Marquardt yöntemiyle sonuçlanmıştır.

$$w_{i+1} = w_i - (\nu)d \quad (10)$$

Bu noktada w fonksiyon parametrelerini ifade ederken, d türevi ifade etmekte ve ν hessian matrisini ifade etmektedir. Denklem 10, optimizasyon yöntemi olan, Newton yöntemlerinin genel güncelleme yöntemini ifade etmektedir.

$$w_{i+1} = w_i(H + \lambda I)^{-1}d \quad (11)$$


Bununla birlikte denklem 11, Levenberg-Marquardt yönteminin Hessian yaklaşımı ile birlikte ortaya konulmuş güncelleme denklemidir. Bu yöntemi kısaca şu şekilde sözde kod haline getirebiliriz.

1. İlk olarak kuralın belirttiği şekilde bir güncelleme yapılır.
2. Yeni ağırlık vektöründeki hatayı değerlendirilir.
3. Güncelleme sonucunda hata artışı gözlemlenirse, lamda geri çekilir (yani ağırlıklar önceki değerlerinde tutulur), 10 kat veya buna benzer önemli bir faktör kadar artırılır. Böyle bir durumda (1)'e gidilir ve güncelleme yeniden gerçekleştirilir.
4. Güncelleme sonucunda hata azaldıysa, adım kabul edilir (yani ağırlıkları koruyun yeni değerlerinde) ve 10 kat kadar azaltılır.

Eğer hata artıyorsa, ikinci dereceden yaklaşım iyi çalışmıyor ve muhtemelen minimuma yakın bir noktada bulunulmamaktadır, bu nedenle basit gradyan inişine daha fazla uyum sağlamak için lamda arttırılmalıdır. Tersine, eğer hata azalıyorsa, yaklaşım iyi çalışıyor ve minimuma yaklaşma beklenecektir [51].

2.4 Önerilen Öznitelik Çıkarımı Temelli Modeller

Bu noktaya kadar bahsi geçen yöntemler göz önünde bulundurulduğunda, zaman serisi tahminlemesi için çoğu alanda çalışmalar yapılmış ve değerlendirilmiştir. Bu çalışmalara ek olarak, bu çalışmada sembolik regresyon tabanlı öznitelik çıkarımı ile birlikte bu öz niteliklere dayanarak ve bahsi geçen sinir ağı modelleri kullanarak tahminleme işlemi gerçekleştirilmiştir.



Şekil 7: Önerilen Metotlarda kullanılan veri seti görseli.

Bu çalışma gerçekleştirilirken KLEMSAN firmasının ana fabrika binasının yaklaşık 5 yıllık, saatlik kaydedilen elektrik tüketim veri seti kullanılmıştır. Veri seti öncelikle ön işlem den geçirilerek kullanılacak formata uygun hale getirilmiştir. Kullanılan veri setinin örneği şekil 7’de gösterilmiştir.

2.4.1 Sembolik Resresyon Temelli Yapay Sinir Ağları

Önerilen yöntemlerden bir tanesi standart yapay sinir ağı modelini sembolik regresyon çıkışları olan öz niteliklerle eğitmektir. Sembolik regresyon göz önünde bulundurulduğunda bazı aritmetik fonksiyonlar ve operatörler kullanılmıştır. Bu işlemlerin öz nitelik olarak seçimi gerçekleştirilmiş ve değerlendirme sonucunda rasgele seçilen operasyon ve ya fonksiyonlar sinir ağı için öz nitelik olarak kullanılmıştır. Bu operatörler ve fonksiyonlar aşağıda listelenmiştir;

1. Rastgele Operatörler

$$a + b \quad (12)$$

$$a * b \quad (13)$$

$$\min(a, b) \quad (14)$$

$$\max(a, b) \quad (15)$$

$$\text{mod}(a, b) \quad (16)$$

2. Rastgele Fonksiyonlar

$$\sin(f_1) \quad (17)$$

$$\cos(f_1) \quad (18)$$

$$\sin(3f_1) \quad (19)$$

$$\cos(3f_1) \quad (20)$$

$$\text{sqr}t(f_1) \quad (21)$$

$$\exp(-f_1) \quad (22)$$

$$f_1 f_1 \quad (23)$$

$$\tanh(f_1) \quad (24)$$


$$1/(1 + \exp(-f_1)) \quad (25)$$

$$0.01 f_1 \quad (26)$$

$$f_1 \quad (27)$$

Başlangıç noktasında rasgele olarak seçilen bu fonksiyon veya operatörler güncellenen ağırlıklara göre tekrar seçilir ve optimum noktayı bulana kadar değişim gösterir. Optimum nokta bulunduğu anda işlem tekrar gerçekleştirilir ve eğitimin en optimum olduğu nokta için geçerli öznitelik ve indeks bulunmuş olur. Bulunan bu nokta test için kullanılır ve test işlemi gerçekleştirilerek hata parametreleri hesaplanır. Standart yapay sinir ağının parametrelerinin güncellenmesinde Levenberg-Marquardt metodu kullanılmakta olup, bütün gerekli parametreler aynı anda güncellenmektedir.

2.4.2 Sembolik Resresyon Temelli Sigma-Pi Sinir Ağları




Şekil 8: Önerilen Metotun Sinir Ağı Modeli.

Sunulan yöntemlerin bir diğeri ise Sembolik regresyon sonucunda elde edilen özneliklerin yüksek mertebeden sinir ağı olan Sigma-Pi sinir ağı kullanılarak eğitilmesidir. Şekil 8’de yöntem modellemesi gösterilmiş olup sinir ağının ağırlıkları Levenberg-Marquardt yöntemiyle güncellenmektedir. Bu yöntemler MATLAB programında yazılmış ve sonuçlar bu programda derlenmiştir.

2.4.3 Sembolik Resresyon Temelli Pi-Sigma Sinir Ağları

Sembolik regresyon temelli öznelik çıkarımı yapılp eğitimin farklı bir yüksek mertebeden sinir ağı olan Pi-Sigma sinir ağıyla eğitiminin yapıldığı bir diğ yöntem daha önerilen yöntemler arasındadır. Bu yöntemde farklı olarak kullanılan Pi-Sigma sinir ağı, çıkışların çarpımı işlemi gerçekleştirmektedir.




Şekil 9: Önerilen Metotun Sinir Ağı Modeli.

3 Benzetim Çalışmaları

Önerilen yöntemlerin MATLAB yazılımında yazılıp koşturulması ile elde edilen sonuçlar bu bölümde incelenecek ve değerlendirilecektir.

Verinin Hazırlanması

Benzetim çalışmalarında 4000 adet enerji tüketim verisi kullanılmıştır. Bu verilerin 2000 adeti modelleri eğitmede (training), 1000 adeti modellerin doğrulanmasında (validation), kalan 1000 adet veri ise modellerin test edilmesinde (testing) kullanılmıştır. Doğrulama



Şekil 10: Benzetim çalışmalarında kullanılan veri.

verisi sadece eğitim sayısını belirlemede kullanılmıştır. Yani modelin ezberlenmesi engellemek için doğrulama seti kullanılmıştır. Ayrıca tüketim verisi $[0, 1]$ aralığına $\tilde{y} = (y - y_{min}) / (y_{max} - y_{min})$ formülü kullanılarak normalize edilmiştir. Tüm veri Şekil 10'de gösterilmektedir. Veri incelenirse periyodik şekilde tüketimin gerçekleştiği görülmektedir. Fakat farklı tüketim nitelikleri, gürültüye benzer modellerin tahmin etmede zorlanacağı veriler üretmektedir.

Model Yapısı

Tasarlanan standart ANN ve diğer HONN modelleri, genel olarak NARMA (Nonlinear Autoregressive-Moving-Average) yapısındadır. Dolayısıyla modeller tasarlanır iken harici giriş verisi kullanılmamıştır. Sadece enerji tüketim verisinin geçmişteki son 3 değeri

kullanılmaktadır. Ayrıca giriş-çıkış ilişkisi doğrusal olmayan yapıdadır. Genel olarak tek-adım kestirim modeli alttaki gibi ifade edilmektedir.

$$\hat{y}_k = f_{model}(y_{k-1}, y_{k-2}, y_{k-3}) \quad (28)$$

Burada dikkat edilmesi gereken husus üstte ifade edilen NARMA modeli öznitelik çıkarımı olmadan girişlerin direkt kullanıldığı durumdur. Fakat öznitelik çıkarımı yapılarak modelleme yapılması durumunda bu girişler direkt kullanılmasının yanında bu girişlerin ikili kombinasyonlarının operatör ve fonksiyonlardan geçirilmesi ile elde edilen öznitelikler, modelin girişi olacaktır. Benzetimlerin sonunda en iyi modellemeyi sağlayan öznitelik operatör ve fonksiyonları iki farklı model için verilecektir.

Temel Performans Ölçütleri: RMSE ve MAPE

Modelleme ve kestirim çalışmalarında model başarısının ölçülmesinde en çok kullanılan iki performans ölçütü RMSE ve MAPE dir.

$$RMSE = \sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2 / N} \quad (29)$$

$$MAPE = \sum_{k=1}^N \frac{|y(k) - \hat{y}(k)|}{|y(k)|} \quad (30)$$

Burada, $y(k)$ orjinal tüketim verisi, $\hat{y}(k)$ tahmini tüketim verisi, N ise veri sayısıdır.

Model Karmaşıklığına Karşı Performans Ölçütü:MDL


Standart ANN modelenin gizli katmandaki nöron sayıları deneme yanılma yöntemi ile 10 ve 50 olarak belirlenmiştir. Fakat HONN modellerinde bu sayıda nöron kullanımı kötü sonuç verdiği bilinmektedir. Zaten HONN yapılarında amaç çok az sayıda nöron sayısı ile hızlı öğrenmenin sağlanmasıdır. Bu yüzden HONN yapılarında gizli katman 3 nöron ve 5 nöron olmak belirlenmiştir. Burada modellerin karmaşıklığı, parametre sayısı ve modelleme başarısını aynı anda ölçen Enkçük-Belirleyici-Uzunluk (MDL) ölçütü kullanılmıştır. Bu ölçüt bize gerçekte tasarlanan model yapısının ne kadar bilgiyi sakladığı yada taşıdığı ölçütünü vermektedir. Yani HONN yapılarında az parametre ve az nöron sayısı ile yakın performans sağlıyor ise fakat MDL değeri eksi olarak daha küçük ise o yapının daha verimli daha başarılı olduğunu göstermektedir. Bu ölçütü benzetim sonuçlarında tekrar değerlendireceğiz. MDL ölçütü şu formül ile hesaplanmaktadır.

$$MDL = N \log(MSE) + P \log(N) \quad (31)$$


Burada N giriş-çıkış veri sayısıdır, MSE modellemenin ortalama karesel hatasıdır, P ise parametre sayısıdır. Bu değerler modelin eğitime verileridir.

3.1 Öznitelik Çıkarımı Kullanılmadan Elde Edilen Sonuçlar


Bu alt bölümde öznitelik çıkarımı yapmadan direkt 3 giriş kullanılarak elde edilen eğitime ve test sonuçlarının RMSE, MAPE ve MDL değerleri verilmektedir. Burada doğru karşılaştırmanın yapılabilmesi için tüm modellerin ilk değerleri 10^{-1} olarak alınmıştır.




(a) Eğitime verisi.



(b) Doğrulama verisi.




(c) Eğitime tahmin sonuçları.




(d) Test tahmin sonuçları.

Şekil 11: Standart ANN (10 nöron): öznitelik çıkarımı olmayan modelleme ve kestirim sonuçları


Şekil 11’de standart ANN model tahminleme sonuçları verilmektedir. 10 nöron sayısı ile öncelikle doğrulama verisi kullanılarak optimal eğitime sayısı 110 olarak belirlenmiş olup daha sonra 110 eğitime sayısı ile model eğitilmiş ve test verisi üzerinde modelleme




(a) Eğitim verisi.



(b) Doğrulama verisi.



(c) Eğitim tahmin sonuçları.



(d) Test tahmin sonuçları.

Şekil 12: Sigma-Pi sinir ağı (3 düğüm): öznitelik çıkarımı olmayan modelleme ve kestirim sonuçları

yapılmıştır. Sonuç olarak elde edilen en iyi modelleme sonuçları grafikler ile eklenmiştir. Standart ANN modelin 50 nöron kullanılması durumunda önemli seviyede başarı artışı olmadığı gözlenmiştir.

Öznitelik çıkarımı olmadan elde edilen RMSE, MAPE ve MDL değerleri Tablo 1’de verilmiştir. RMSE ve MAPE değerleri test verisi üzerinden MDL değeri ise eğitim verileri üzerinden hesaplanmaktadır. Elde edilen sonuçlara göre standart ANN modelin daha iyi sonuç verdiği gözlenmiştir. Sigma-Pi sinir ağının çıkışında 3 düğümün kullanılması ile elde edilen modelleme ve tahmin sonuçları ise Şekil 12’de verilmiştir. Grafiklerden standart ANN modele göre daha hızlı öğrenmenin gerçekleştiği söylenebilir, fakat test verisi üzerindeki RMSE ve MAPE sonuçlarına göre daha kötü tahmin sonuçları ürettiği gözlenmiştir. MDL değerlerine bakıldığında az parametre sayısından dolayı Sigma-Pi ağları

Tablo 1: Öznitelik çıkarımı kullanılmadan elde edilen performans sonuçları

Test Verisi	RMSE	MAPE	MDL
ANN(10 nöron)	0.0349	0.0594	-5.63e+03
ANN(50 nöron)	0.0348	0.0599	-5.06e+03
Sigma-Pi (3 düğüm)	0.0418	0.0680	-5.41e+03
Sigma-Pi (10 düğüm)	0.0431	0.0711	-5.2762e+03
Pi-Sigma (3 düğüm)	0.1393	0.2255	-3.3183e+03
Pi-Sigma (10 düğüm)	0.1393	0.2255	-3.2391e+03

küçük MDL değeri üretmiştir. Fakat standart ANN modelin tahmin başarımı iyi olmasından dolayı en küçük MDL değerini üretmiştir.

Elde edilen tahminleme performansları göz önüne alındığında, standart ANN ve Sigma-Pi ağlarının %5'in altında RMSE hatası ürettiği için kabul edilebilir performanslar olduğu görülmektedir. Pi-Sigma ağlarının ise modelleme başarısı kötü olmasından dolayı sonraki bölümde benzetim çalışmalarında kullanılmayacaktır. Literatür çalışmalarında da Pi-Sigma ağları daha kötü tahmin sonuçları ürettiği gösterilmiş ve daha az kullanılmıştır.

Tablo 2: Öznitelik çıkarımı kullanılarak elde edilen performans sonuçları

Test Verisi	RMSE	MAPE	MDL
ANN(10 nöron)	0.0328	0.0542	-5.85e+03
Sigma-Pi (3 düğüm)	0.0365	0.0620	-5.61e+03


Tablo 3: Öznitelik operator ve fonksiyonları

Standart ANN öznitelik= $[exp(max(y_{k-1}, y_{k-2})), \sqrt{min(y_{k-1}, y_{k-3})}, sin(y_{k-2} \times y_{k-3})]$
Sigma-Pi öznitelik= $[\sqrt{y_{k-1} + y_{k-2}}, cos(3 \times max(y_{k-1}, y_{k-3})), exp(y_{k-2} + y_{k-3})]$


3.2 Öznitelik Çıkarımı Kullanılarak Elde Edilen Sonuçlar

Bu alt bölümde ise tez çalışmasında önerilen sembolik regresyon temelli öznitelik çıkarımı uygulanacak ve elde edilen öznitelik uzayı kullanılarak modelleme ve tahmin yapılacaktır. Önceki bölümde belirtildiği üzere en iyi sonuç veren iki model üzerinden sonuçlar tekrar kaydedilecektir. Öznitelik çıkarımında amaç giriş değerlerindeki gizli bilgiyi ortaya çıkarmak ve modelleme başarısını artırmaktır. Bilindiği üzere anlık giriş verisinin matris olduğu durumlarda, örneğin görüntü sınıflandırma çalışmalarında filtreler kullanılarak öznitelik çıkarımı sağlanmaktadır. Fakat zaman serisi tahmininde giriş verisi sadece serinin eski değerleri olduğu için böyle bir imkan yoktur. Ancak çok katmanlı ağ yapısı ile yani çok parametrik bir model ile mümkün olacaktır. Dolayısıyla tez çalışmasında giriş değerlerini farklı fonksiyon ve operatörlerden geçirerek başarı artırılabilceği öngörülmüştür. Genel amaç, önerilen öznitelik çıkarımı sayesinde az parametrelili basit modellerin başarısını artırmak ve gömülü sistemlerde kullanımını sağlamaktır.


Tablo 2’de öznitelik çıkarımı kullanılarak yapılan modelleme çalışmalarına ilişkin performans değerleri verilmektedir. Elde edilen sonuçlar incelendiğinde öznitelik çıkarımı Sigma-Pi ağı için %12.6 iyileştirme sağlar iken standart YSA model için %8 civarı iyileştirme sağlamaktadır. Tablo 3’de tasarlanan öznitelik operatör ve fonksiyonları verilmiştir. Görüldüğü üzere zaman serisinin geçmiş değerlerinin direk kullanılması yerine basit operatör ve fonksiyondan geçirilmesi ile veriden daha anlamlı bilgi çıkarımı yapılabildiği gösterilmektedir. Buna benzer bir sonuç, deneme yanılma yöntemi ile öznitelik fonksiyonları bulunmuş ve az sayıdaki veriden başarılı modelleme performansı [25] elde edilmiştir.




(a) Eğitime verisi.




(b) Doğrulama verisi.




(c) Eğitime tahmin sonuçları.



(d) Test tahmin sonuçları.



(e) Eğitime yakınlaştırmış sonuçlar.



(f) Test yakınlaştırmış sonuçları.

Şekil 13: Sigma-Pi sinir ağı (3 düğüm): öznitelik çıkarımı kullanarak modelleme ve kestirim sonuçları

4 Sonuçların Değerlendirilmesi ve Gelecek Çalışmalar

Tez çalışmanın amacı zaman serisi tahminlemede öznitelik çıkarımına yeni bakış açısı getirmek olup tahminleme performansını arttırmak ve hata oranını azaltarak gerçek hayatta verilerin kullanılabilirliğini arttırmaktır. Sembolik regresyon temelli öznitelik çıkarımı yöntemi, sinir ağı modellerine giren veriden daha anlamlı bilgi çıkarımı sağlamış ve sinir ağının modelleme performansının artmasını sağlamıştır. İkincil olarak, Sigma-Pi ve Pi-Sigma sinir ağlarının zaman serisi işlenmesinde kullanılması, daha az düğüm sayısı ve az parametre ile sonuç verecek bir model olmuştur. Önerilen öznitelik çıkarımı %8 – 15 arası iyileştirme sağlaması bazı uygulamalarda yeterli iken bazı uygulamalarda yetersiz kalacaktır. Elde edilen kısmi iyileştirme her tahminleme sonucunda kullanılması durumunda, üstel olarak artan bir iyileştirme sağlayacaktır.

Çalışmanın daha iyi sonuç vermesi için bazı iyileştirmelerin yapılması öngörülmüştür. Birincisi zaman serisinin kaç adet geçmiş değeri kullanılacağı, ikincisi hangilerinin kullanılacağı (input selection) ve en önemlisi kaç adet sembolik fonksiyon ve operatör ile öznitelik çıkarılacağı tasarlanmalıdır. Ayrıca LM eğitmenin sürekli lokal minimuma takılması ve giriş sayısı değiştikçe optimizasyon kodunun değişecek olmasından dolayı burada üç adet giriş ile sınırlandırılmıştır. Fakat sezgisel yöntemlerin kullanılması durumunda, lokal minimum ve başlangıç şartlarına bağlılık probleminden kaçınılacak ve istenilen sayıda giriş ile Jakobyen matrisini değiştirmeden kolayca parametre optimizasyonu sağlanacaktır. Ek olarak, enerji tüketim verisinde var olan anomalilerin işaretlendiği veri seti kullanarak veri sınıflandırma işlemi yapılması planlanmaktadır. Veri kaydı yapan cihazlara bu modeller entegre edilebilir hale getirilecek ve faturalandırma ve hata tahminlenmesinde kullanılacaktır.

Kaynaklar

- [1] C. C. Aggarwal et al. Neural networks and deep learning. *Springer*, 10:978–3, 2018.
- [2] K. Amber, R. Ahmad, M. Aslam, A. Kousar, M. Usman, and M. S. Khan. Intelligent techniques for forecasting electricity consumption of buildings. *Energy*, 157:886–893, 2018.
- [3] D. A. Augusto and H. J. Barbosa. Symbolic regression via genetic programming. In *Proceedings. Vol. 1. Sixth Brazilian Symposium on Neural Networks*, pages 173–178. IEEE, 2000.
- [4] A. Azadeh, R. Babazadeh, and S. Asadzadeh. Optimum estimation and forecasting of renewable energy consumption by artificial neural networks. *Renewable and Sustainable Energy Reviews*, 27:605–612, 2013.
- [5] A. Azadeh, S. F. Ghaderi, S. Tarverdian, and M. Saberi. Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption. *Applied mathematics and computation*, 186(2):1731–1741, 2007.
- [6] J. Bedi and D. Toshniwal. Empirical mode decomposition based deep learning for electricity demand forecasting. *IEEE access*, 6:49144–49156, 2018.
- [7] J. Bedi and D. Toshniwal. Deep learning framework to forecast electricity demand. *Applied energy*, 238:1312–1326, 2019.
- [8] S. Beyhan. Fuzzy emulated symbolic regression for modelling and control of markov jump systems with unknown transition rates. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 69(3):1352–1356, 2021.
- [9] L. Billard and E. Diday. Symbolic regression analysis. In *Classification, clustering, and data analysis*, pages 281–288. Springer, 2002.
- [10] G. E. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.

- [11] D.-K. Bui, T. N. Nguyen, T. D. Ngo, and H. Nguyen-Xuan. An artificial neural network (ann) expert system enhanced with the electromagnetism-based firefly algorithm (efa) for predicting the energy consumption in buildings. *Energy*, 190:116370, 2020.
- [12] N. Cc, K.-Y. Song, D. N. Saraf, and M. M. Gupta. Production forecasting of petroleum reservoir applying higher-order neural networks (honn) with limited reservoir data. *Int J Comput Appl*, 975:8887, 2013.
- [13] E. K. Chong and S. H. Zak. *An introduction to optimization*. John Wiley & Sons, 2004.
- [14] T. Chow and S. Cho. Development of a recurrent sigma-pi neural network rainfall forecasting system in hong kong. *Neural Computing & Applications*, 5(2):66–75, 1997.
- [15] B. Cooper. Stability analysis of higher-order neural networks for combinatorial optimization. *International Journal of Neural Systems*, 12(03n04):177–186, 2002.
- [16] E. M. de Oliveira and F. L. C. Oliveira. Forecasting mid-long term electric energy consumption through bagging arima and exponential smoothing methods. *Energy*, 144:776–788, 2018.
- [17] R. Dubčáková. Eureka: software review, 2011.
- [18] C. Fan, J. Wang, W. Gang, and S. Li. Assessment of deep recurrent neural network-based strategies for short-term building energy predictions. *Applied energy*, 236:700–710, 2019.
- [19] J. Fulcher, M. Zhang, and S. Xu. Application of higher-order neural networks to financial time-series prediction. In *Artificial neural networks in finance and manufacturing*, pages 80–108. IGI Global, 2006.
- [20] C. W. Fusting. *Temporal Feature Selection with Symbolic Regression*. The University of Vermont and State Agricultural College, 2017.

- [21] J. Ghosh and Y. Shin. Efficient higher-order neural networks for classification and function approximation. *International Journal of Neural Systems*, 3(04):323–350, 1992.
- [22] C. L. Giles and T. Maxwell. Learning, invariance, and generalization in high-order neural networks. *Applied optics*, 26(23):4972–4978, 1987.
- [23] M. M. Gupta, I. Bukovsky, N. Homma, A. M. Solo, and Z.-G. Hou. Fundamentals of higher order neural networks for modeling and simulation. In *Artificial Higher Order Neural Networks for Modeling and Simulation*, pages 103–133. IGI Global, 2013.
- [24] N. A. Husaini, R. Ghazali, N. M. Nawi, L. H. ISMAIL, M. M. Deris, and T. Herawan. Pi-sigma neural network for a one-step-ahead temperature forecasting. *International Journal of Computational Intelligence and Applications*, 13(04):1450023, 2014.
- [25] H. Isleroglu and S. Beyhan. Prediction of baking quality using machine learning based intelligent models. *Heat and Mass Transfer*, 56(7):2045–2055, 2020.
- [26] D. Karaboga, C. Ozturk, N. Karaboga, and B. Gorkemli. Artificial bee colony programming for symbolic regression. *Information Sciences*, 209:1–15, 2012.
- [27] M. Keijzer. Improving symbolic regression with interval arithmetic and linear scaling. In *European Conference on Genetic Programming*, pages 70–82. Springer, 2003.
- [28] M. Keijzer. Scaled symbolic regression. *Genetic Programming and Evolvable Machines*, 5(3):259–269, 2004.
- [29] M. K. Kim, Y.-S. Kim, and J. Srebric. Predictions of electricity consumption in a campus building using occupant rates and weather elements with sensitivity analysis: Artificial neural network vs. linear regression. *Sustainable Cities and Society*, 62:102385, 2020.
- [30] S. Kim and K. R. Horspool. Aircraft speed/altitude control using a sigma-pi neural network. In *AIAA Scitech 2020 Forum*, page 1235, 2020.

- [31] T.-Y. Kim and S.-B. Cho. Predicting residential energy consumption using cnn-lstm neural networks. *Energy*, 182:72–81, 2019.
- [32] B. E. Köktürk-Güzel and S. Beyhan. Symbolic regression based extreme learning machine models for system identification. *Neural Processing Letters*, 53(2):1565–1578, 2021.
- [33] M. F. Korns. Accuracy in symbolic regression. In *Genetic Programming Theory and Practice IX*, pages 129–151. Springer, 2011.
- [34] N. Kulishova. Emotion recognition using sigma-pi neural network. In *2016 IEEE First International Conference on Data Stream Mining & Processing (DSMP)*, pages 327–331. IEEE, 2016.
- [35] C. Li, Y. Tao, W. Ao, S. Yang, and Y. Bai. Improving forecasting accuracy of daily enterprise electricity consumption using a random forest based on ensemble empirical mode decomposition. *Energy*, 165:1220–1227, 2018.
- [36] J.-Y. Li and T. W. Chow. Functional approximation of higher-order neural networks. *Journal of Intelligent Systems*, 6(3-4):239–260, 1996.
- [37] K. Li, X. Xie, W. Xue, X. Dai, X. Chen, and X. Yang. A hybrid teaching-learning artificial neural network for building electrical energy consumption prediction. *Energy and Buildings*, 174:323–334, 2018.
- [38] T. Liu, Z. Tan, C. Xu, H. Chen, and Z. Li. Study on deep reinforcement learning techniques for building energy consumption forecasting. *Energy and Buildings*, 208:109675, 2020.
- [39] L. A. Lyutikova. Sigma-pi neural networks: error correction methods. *Procedia computer science*, 145:312–318, 2018.
- [40] T. McConaghy. Ffx: Fast, scalable, deterministic symbolic regression technology. In *Genetic Programming Theory and Practice IX*, pages 235–260. Springer, 2011.

- [41] D. C. Montgomery, C. L. Jennings, and M. Kulahci. *Introduction to time series analysis and forecasting*. John Wiley & Sons, 2015.
- [42] S. C. Nayak. Development and performance evaluation of adaptive hybrid higher order neural networks for exchange rate prediction. *International Journal of Intelligent Systems and Applications*, 9(8):71, 2017.
- [43] S. C. Nayak, B. B. Misra, and H. S. Behera. Fluctuation prediction of stock market index by adaptive evolutionary higher order neural networks. *International Journal of Swarm Intelligence*, 2(2-4):229–253, 2016.
- [44] Y. Nie and W. Deng. A hybrid genetic learning algorithm for pi-sigma neural network and the analysis of its convergence. In *2008 fourth international conference on natural computation*, volume 3, pages 19–23. IEEE, 2008.
- [45] J. Nocedal and S. J. Wright. *Numerical optimization*. Springer, 1999.
- [46] A.-D. Pham, N.-T. Ngo, T. T. H. Truong, N.-T. Huynh, and N.-S. Truong. Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability. *Journal of Cleaner Production*, 260:121082, 2020.
- [47] F. Prado, M. C. Minutolo, and W. Kristjanpoller. Forecasting based on an ensemble autoregressive moving average-adaptive neuro-fuzzy inference system–neural network-genetic algorithm framework. *Energy*, 197:117159, 2020.
- [48] A. Rahman, V. Srikumar, and A. D. Smith. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks. *Applied energy*, 212:372–385, 2018.
- [49] M. B. Reid and L. Spirkovska. Higher-order neural network software for distortion invariant object recognition. In *NASA, Washington, Technology 2001: The Second National Technology Transfer Conference and Exposition, Volume 2*, 1991.

- [50] J. Reynolds, Y. Rezgui, A. Kwan, and S. Piriou. A zone-level, building energy optimisation combining an artificial neural network, a genetic algorithm, and model predictive control. *Energy*, 151:729–739, 2018.
- [51] S. Roweis. Levenberg-marquardt optimization. *Notes, University Of Toronto*, 52, 1996.
- [52] P. Satrio, T. M. I. Mahlia, N. Giannetti, K. Saito, et al. Optimization of hvac system energy consumption in a building using artificial neural network and multi-objective genetic algorithm. *Sustainable Energy Technologies and Assessments*, 35:48–57, 2019.
- [53] M. Shao, X. Wang, Z. Bu, X. Chen, and Y. Wang. Prediction of energy consumption in hotel buildings via support vector machines. *Sustainable Cities and Society*, 57:102128, 2020.
- [54] Y. Shin and J. Ghosh. The pi-sigma network: An efficient higher-order neural network for pattern classification and function approximation. In *IJCNN-91-Seattle international joint conference on neural networks*, volume 1, pages 13–18. IEEE, 1991.
- [55] H. Swapna Rekha, J. Nayak, and H. Behera. Pi-sigma neural network: Survey of a decade progress. In *Computational Intelligence in Pattern Recognition*, pages 429–441. Springer, 2020.
- [56] M. K. Tiwari, K.-Y. Song, C. Chatterjee, and M. M. Gupta. River-flow forecasting using higher-order neural networks. *Journal of Hydrologic Engineering*, 17(5):655–666, 2012.
- [57] M. Torabi, S. Hashemi, M. R. Saybani, S. Shamshirband, and A. Mosavi. A hybrid clustering and classification technique for forecasting short-term energy consumption. *Environmental progress & sustainable energy*, 38(1):66–76, 2019.

- [58] G. K. Tso and K. K. Yau. Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. *Energy*, 32(9):1761–1768, 2007.
- [59] H. Vaddireddy, A. Rasheed, A. E. Staples, and O. San. Feature engineering and symbolic regression methods for detecting hidden physics from sparse sensor observation data. *Physics of Fluids*, 32(1):015113, 2020.
- [60] L. Wang, H. Hu, X.-Y. Ai, and H. Liu. Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm. *Energy*, 153:801–815, 2018.
- [61] Y. Wei, L. Xia, S. Pan, J. Wu, X. Zhang, M. Han, W. Zhang, J. Xie, and Q. Li. Prediction of occupancy level and energy consumption in office building using blind system identification and neural networks. *Applied energy*, 240:276–294, 2019.
- [62] K. Yan, W. Li, Z. Ji, M. Qi, and Y. Du. A hybrid lstm neural network for energy consumption forecasting of individual households. *Ieee Access*, 7:157633–157642, 2019.
- [63] T.-J. Yang, Y.-H. Chen, J. Emer, and V. Sze. A method to estimate the energy consumption of deep neural networks. In *2017 51st asilomar conference on signals, systems, and computers*, pages 1916–1920. IEEE, 2017.
- [64] Z. Ye and M. K. Kim. Predicting electricity consumption in a building using an optimized back-propagation and levenberg–marquardt back-propagation neural network: Case study of a shopping mall in china. *Sustainable Cities and Society*, 42:176–183, 2018.
- [65] S. Zagrebina, V. Mokhov, and V. Tsimbol. Electrical energy consumption prediction is based on the recurrent neural network. *Procedia Computer Science*, 150:340–346, 2019.
- [66] M. Zhang. *Artificial higher order neural networks for modeling and simulation*. IGI Global, 2012.