

**İŞLEMSEL ZEKANIN
ELEKTROMANYETİK PROBLEMLERE
UYGULANMASI**

Hüseyin GÖKSU

**DOKTORA TEZİ
FİZİK ANABİLİM DALI
ISPARTA – 2006**

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İŞLEMSEL ZEKANIN
ELEKTROMANYETİK PROBLEMLERE UYGULANMASI**

Hüseyin GÖKSU

**DOKTORA TEZİ
FİZİK ANABİLİM DALI
ISPARTA – 2006**

Fen Bilimleri Enstitüsü Müdürlüğüne

Bu çalışma jürimiz tarafından FİZİK ANABİLİM DALI 'nda DOKTORA TEZİ olarak kabul edilmiştir.

Başkan: Prof. Dr. Nazım UÇAR

Üye: Prof. Dr. Ali KÖKCE

Üye: Prof. Dr. Nuri ÖZEK

Üye: Prof. Dr. Atalay KÜÇÜKBURSA

Üye: Doç. Dr. İskender AKKURT

Üye: Doç. Dr. Fatih UCUN

Üye: Yrd. Doç. Dr. Ali MANZAK

ONAY

Bu tez 29 / 05 / 2006 tarihinde Enstitü Yönetim Kurulu 'nca belirlenen yukarıdaki jüri üyeleri tarafından kabul edilmiştir.

..../...../200..

S.D.Ü. FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Prof. Dr. Çiğdem SAVAŞKAN

İÇİNDEKİLER

	Sayfa
ÖZET	v
ABSTRACT	vii
TEŞEKKÜR	ix
SİMGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xvi
1. GİRİŞ	1
1.1. Problem Çözümü	1
1.1.1. Düz Problemler	2
1.1.2. Ters Problemler ve Eniyileme	3
1.3. Model Tabanlı Problemler	4
1.3.1. Model - Veri İlişkisi	4
1.3.2. Doğrusallık Koşulu	6
1.3.3. Yarı Doğrusal Problemler	8
1.4. Modele Dayalı Olmayan Problemler	9
1.5. Eniyileme Problemleri	9
1.5.1. Izgara Arama (GS)	10
1.5.2. Monte Carlo Metotları	11
1.6. Referans Sistemlerine Ait Altyapılar	12
1.7. İşlemsel Zeka	13
1.7.1. Mantık Sistemleri ve Yapay Zeka	14
1.7.2. Zeka ve Bilgisayarlar	15
1.8. Elektromanyetik Problemler	16
1.8.1. Birinci Problem: Elektromanyetik Kaynak Tanıma	17
1.8.2. İkinci Problem: FDTD Benzetimlerinde Veri Dışdeğerlemesi	19
1.8.3. Üçüncü Problem: Düşük Güç Tümdrevre Tasarımı	20
1.8.4. Dördüncü Problem: Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları	22
2. KAYNAK ÖZETLERİ	25
2.1. Elektromanyetik Kaynak Tanıma	25

2.2. FDTD Veri Dışdeğerlemesi	25
2.3. Düşük Güç Tasarımı	26
2.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları	27
3. MATERYAL VE METOD	28
3.1. Materyal	28
3.1.1. Elektromanyetik Kaynak Ölçümleri	28
3.1.1.1. Parametreler	31
3.1.2. FDTD EMC Simülasyonları ve Dışdeğerleme	33
3.1.3. Düşük Güç ve Sıcaklık Tasarımı	35
3.1.3.1. Tümdevre Güç Tüketimi	35
3.1.3.2. Eniyileme Parametreleri	37
3.1.3.3. Masraf fonksiyonu	37
3.1.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları	38
3.1.4.1. Formülizasyon	38
3.1.4.1.1. Enerji Eniyilemesi İçin Formülasyon	39
3.1.4.1.2 En yüksek Güç Eniyilemesi	40
3.2. Metotlar	41
3.2.1. Entropi İstatistiği	41
3.2.1.1. Entropi denklemi	42
3.2.1.2. Entropi Ayırıştırma Teorisi	43
3.2.1.3. Çok Boyuta Genişletilmesi	46
3.2.2. ARMA – Özbağlanımlı Kayan Ortalama Yaklaşımı (AutoRegressive Moving Average): Zaman Serileri İçin Regresyon Formülü	48
3.2.3. Matris Kalem Metodu (MPM)	49
3.2.3.1. Pencil Biçimi ve Pencil Parametresi	50
3.2.3.2. Kesintiye Uğramış Tekil Değer Ayırışımı (SVD) ve Kutup Sayısı	52
3.2.4. Asal Bileşen Analizi (PCA)	54
3.2.5. Kısa Vadeli Fourier Dönüşümü ve Dalga Paketçiği Dönüşümleri	56
3.2.5.1. Kesikli Fourier Dönüşümü	56
3.2.6. Dalgacık Paketi Dönüşümü Analizi	59

3.2.6.1. Dalgacık Paketi Analizinin Uygulanışı	59
3.2.6.2. Bir Boyutlu Sinyal İşlemede Dalgacık Paketi Dönüşümü	62
3.2.7. Yapay Sinir Ağları	63
3.2.7.1. MLP ve Geri yayılım (BP – Backpropagation) Algoritması	67
3.2.8. Olasılıksal Sinir Ağları (PNN: Probabilistic Neural Networks)	67
3.2.9. Benzetimlenmiş Soğutma (SA) Metotları	69
3.2.9.1. Metropolis Algoritması	71
3.2.9.2. Matematiksel Model ve Asimptotik Yaklaşım	73
3.2.9.3. Isı Banyosu (HB: Heat Bath) Algoritması	74
3.2.9.4. Reddedilen Hareketleri Olmayan SA	75
3.2.9.5. Hızlı Benzetimlenmiş Soğutma (FSA)	76
3.2.9.6. Çok Hızlı Benzetimlenmiş Tekrar Soğutma (VFSR) Algoritması	78
3.2.10. Elektromanyetik Simülasyonlar	82
3.2.10.1. Momentler Metodu	82
3.2.10.2. Sonlu Eleman Metodu	83
3.2.10.3. FDTD	83
3.2.10.4. Diğer Teknikler	83
3.2.10.4.1. Sonlu Farklı Zaman Boyutu Metodu (FDTD)	83
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	88
4.1. FDTD Benzetimlerinde Veri Dışdeğerlemesi	88
4.1.1. Yapay Sinyal Üzerinde Uygulama	88
4.1.2. Öğrenme ve Parametre İlk Değerleri	92
4.1.3. Kod Uyarlama Problemleri	95
4.1.3.1. Sinüs Dalgasına Uygulama	96
4.1.4. Gerçek Sinyal Üzerinde Dışdeğerleme	99
4.2. Elektromanyetik Kaynak Tanıma	100
4.2.1. STFT Metodu	100
4.2.2. Dalga Paketçiği Metodu	104
4.2.3. Olasılıklı Yapay Sinir Ağları Sınıflandırması	108

4.3. Düşük Güç Tasarımı	109
4.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları	110
4.4.1. İş Yüğü ve Uzunluğunun Etkisi	110
4.4.2. Çoklu Amaç Fonksiyonu Kullanmanın Etkisi	112
4.4.3. Isınma Soğuma Katsayılarının Etkisi	113
5. SONUÇ	116
5.1. FDTD Benzetimlerinde Veri Dışdeğerlemesi	116
5.1.1. Eğitim Problemleri	116
5.1.2. Kod Uyarlama Problemleri	117
5.2. Elektromanyetik Kaynak Tanıma	117
5.3. Düşük Güç Tasarımı	118
5.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları	119
6. KAYNAKLAR	121
ÖZGEÇMİŞ	127

ÖZET

(İşlemsel Zekanın Elektromanyetik Problemlere Uygulanması)

Uygulamalı elektromanyetik problemlere örneklem sunacak çeşitlilikte seçilen dört problem, işlemsel zeka ve klasik yöntemlerin birlikte kullanımıyla çözülmüştür. Birinci problem elektromanyetik kaynakların tanınmasıdır. Bu amaçla otomobillerin yaydıkları elektromanyetik alan yoluyla sınıflandırılması gerçekleştirilmiştir. Sinyallerin Kısa Vadeli Fourier Dönüşümü'nden (STFT) çıkarılan istatistiksel parametreler ve Dalgacık Paket Ayırışımı'ndan (WPD) elde edilen alt imgelerinin enerjilerinden oluşan nitelik vektörleri sınıflandırılmada karşılaştırılmıştır. Sınıflayıcı olarak Çok Katlı Perceptron (MLP) ve Olasılıklı Yapay Sinir Ağları (PNN) kullanılırken, boyutların yüksek olduğu durumlarda dikgenleştirme amacıyla Asal Bileşen Analizi'ne (PCA) başvurulmuştur. İkinci problem, Sonlu Farklı Zaman Boyutu (FDTD) benzetimlerinde dışdeğerleme yaklaşımıdır. Benzetim sürelerinin kısaltılması amacıyla MLP kullanarak yerel (kısa vadeli) öngörme yöntemi ile Matris Pencil Metodu (MPM) kullanarak evrensel (uzun vadeli) öngörme yöntemi karşılaştırılmıştır. Yapay belirlenimci sinyallerde kısa vadeli öngörü başarılı olurken gerçek sinyallerde gürültüden dolayı uzun vadeli öngörü daha kararlı sonuçlar vermiştir. Genel kayan pencere dışdeğerleyicilerinde farklı sinyaller için örnekleme frekansı ve pencere genişliğinin uyarlanabilir olması amacıyla entropi istatistiğine dayalı bir eniyileme yöntemi geliştirilmiştir. Üçüncü problem, tümleşik devrelerde güç tüketiminin azaltılması amacıyla en iyi kaynak ve eşik gerilimi seçimi ve aygıt boyutlandırmasıdır. Evrensel eniyileme yöntemi olarak Çok Hızlı Benzetimlenmiş Tekrar Soğutma (VFSR) kullanılırken çoklu hedef olarak güç tüketimi en düşüklendirken, pil yük sığasının en büyüklenmesi benimsenmiştir. Dördüncü problem, dinamik voltaj ölçeklenebilir (DVS) sistemlerde enerji, en yüksek güç ve sıcaklık eniyilemeleri arasındaki farkları incelemektedir. Verilen iş yükleri için eniyileme farklarında mikroçipin ısısal özelliklerinin etkisi de incelenmiştir. Monte Carlo benzetimleriyle yapılan incelemelerde ne enerji ve ne de en yüksek güç eniyilemesinin sıcaklığın düşürülmesi bakımından iyi olmadığı görülmüştür.

ANAHTAR KELİMELER: Dalgacık Dönüşümleri, Yapay Sinir Ağları, Elektromanyetik Alanlar, Matris Pencil Yöntemi, Tümdevre Tasarımı, Benzetimlenmiş Soğutma, Düşük Güç Tasarımı, Asal Bileşen Analizi, Elektromanyetik Benzetim, Önceden Tahmin

ABSTRACT

(Application of Computational Intelligence to Electromagnetic Problems)

Four different electromagnetic problems are solved using computational intelligence techniques and conventional methods. First problem is identification of electromagnetic sources. For this purpose, automobiles are classified using their electromagnetic emissions. Statistical parameters extracted from Short Term Fourier Transform (STFT) windows and energies of sub-images from Wavelet Decomposition (WPD) are compared in terms of classification rates. Multilayer Perceptron (MLP) and Probabilistic Neural Networks (PNN) are used as classifiers and Principle Component Analysis (PCA) is used for orthogonalization when dimensions are high. Second problem is extrapolation in Finite Difference Time Domain (FDTD) simulations. In order to shorten simulation times, a short term (local) MLP type predictor is compared to a Matrix Pencil Method (MPM) type long term (global) predictor. While short term prediction is better in artificial deterministic signals, long term prediction is more stable in noisy real signals. In order to make sampling frequency and window size adaptive for sliding window extrapolators, an optimization method based on entropy statistics is developed. Third problem addresses supply and threshold voltage selection with device sizing to reduce power consumption in integrated circuits. Very Fast Simulated Reannealing (VFSR) is used as a global optimization tool. Minimization of power consumption and maximization of battery charge capacitance are included in the multiobjective cost. Fourth problem addresses the differences between energy, peak power and temperature optimizations in dynamic voltage scalable (DVS) systems. The effect of thermal characteristics of chips is also studied. Monte Carlo simulations showed that neither energy nor maximum power optimization is good for temperature reduction.

KEYWORDS: Wavelet Transforms, Artificial Neural Networks, Electromagnetic Fields, Matrix Pencil Method, VLSI, Simulated Annealing, Low Power Design, Principal Component Analysis, Electromagnetic Simulations, Prediction

TEŞEKKÜR

Tez danışmanım, Sayın Prof. Dr. Ali Kökçe'ye, çalışma esnasında yardım ve desteği için; İkinci tez danışmanım Sayın Yrd. Doç. Dr. Ali Manzak'a, çalışmanın Düşük Güç Tasarımı kısmındaki yol göstericiliği için; Missouri Üniversitesi'nden Sayın Mary Finley Distinguished Profesörü Dr. Donald Wunsch'a Elektromanyetik Kaynak Tanınması ve Elektromanyetik Zaman Serisi Dışdeğerlemesi kısımlarındaki bilimsel danışmanlığı ve Missouri Üniversitesi Uygulamalı İşlemsel Zeka Laboratuvarı ile Elektromanyetik Uyumluluk Laboratuvarı'nı kullanımımıza tahsis ettiği için; ve aileme koşulsuz destekleri için en içten teşekkürlerimi sunarım.

SİMGELER DİZİNİ

VFSA	Çok hızlı benzetimlenmiş soğutma (Very Fast Simulated Annealing)
VFSR	Çok hızlı benzetimlenmiş tekrar soğutma (Very Fast Simulated Reannealing)
SA	Benzetimlenmiş soğutma (Simulated Annealing)
TSP	Gezici Satıcı Problemi
FA	Hızlı soğutma
WPD	Dalgacık Paket Ayırışımı (Wavelet Packet Decomposition)
MPM	Matris Pencil Metodu (Matrix Pencil Method)
MLP	Çok Katmanlı Perceptron (Multilayer Perceptron)
PCA	Asal Bileşen Analizi (Principal Component Analysis)
FDTD	Sonlu Fark Zaman Boyutu (Finite Difference Time Domain)
DS	Veri sayısı
t	Zaman
G	Hassasiyet matrisi
GS	Izgara arama
MC	Monte Carlo
GA	Genetik Algoritma
E	Enerji
K	Boltzman sabiti
T	Sıcaklık
Z	Bölüşüm fonksiyonu
HB	Isı banyosu
P	Olasılık
FSA	Hızlı benzetimlenmiş soğutma
S	Hassasiyet
V	Potansiyel
SAWR	Reddedilen hareketleri olmayan benzetimlenmiş soğutma
EMC	Elektromanyetik Uyumluluk
FFT	Hızlı Fourier Dönüşümü

V_{dd}	Sürücü Potansiyel
V_{th}	Eşik Potansiyeli
RF	Radyo Frekansı
d_{göz}	Gözlem Verisi
d	Veri
m	Model
MS	Modeldeki Parametre Sayısı
d_{yap}	Yapay Veri
Θ	Küçük Açık
Δm	Modeldeki sarsım
m₀	Referans modeli
PNN	Olasılıksal Sinir Ağları (Probabilistic Neural Networks)
AI	Yapay Zeka (Artificial Intelligence)
IEEE	Institute of Electrical and Electronics Engineers
EMC	Elektromanyetik Uyumluluk (Electromagnetic Compatibility)
FFT	Hızlı Fourier Dönüşümü (Fast Fourier Transform)
RF	Radyo Frekansı
EM	Elektromanyetik
STFT	Kısa Vadeli Fourier Dönüşümü (Short Term Fourier Transform)
DSP	Sayısal Sinyal İşleme (Digital Signal Processing)
ARMA	Özbağımlımlı Çınlama Kayan Ortalama (Autoregressive Moving Average)
FIR	Sonlu Dürtü Cevabı (Finite Impulse Response)
ILP	Tamsayı Doğrusal Programlama
PEC	Mükemmel Elektrik İletici
TLM	İletim Hattı Matrisi
GMT	Çoklu Kutup Tekniği
FVTD	Sonlu Hacim Zaman Boyutu
UMR	University of Missouri-Rolla
CMOS	Complementary Metal Oxide Semiconductor
H	Entropi
p	Olasılık

SVD	Tekil Değer Ayrışımı
QMF	Karesel Ayna Süzgeci
NN	Yapay Sinir Ağı (Neural Networks)
BP	Geri Yayılım (Back Propagation)
RBF	Işınsal Temel Fonksiyonu (Radial Basis Function)
RMS	Root Mean Square
P	Güç
T	Sıcaklık veya Zaman

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Genel Problem Modeli	2
Şekil 1.2. Bir Boyutlu tipik bir doğrusal olmayan hata/model eğrisi	10
Şekil 3.1. Farklı otomobillerden yayılım spektrumları	28
Şekil 3.2. (a) VC serisi Yugoslav fünye. (b) Zamanlayıcının ölçülen yayımı	29
Şekil 3.3. (a) 1 nolu araçtan yayılan 1 boyutlu sinyal ve 2 boyutlu spektrogramı (b) 1 boyutlu çevre gürültü sinyali ve 2 boyutlu spektrogramı. (c) 2 nolu araçtan yayılan 1 boyutlu sinyal ve 2 boyutlu spektrogramı	30
Şekil 3.4. FDTD ile benzetimi yapılan geometri	35
Şekil 3.5. Kısa vadeli dışdeğerleyici	49
Şekil 3.6. Fourier Dönüşümü	57
Şekil 3.7. Kısa Zamanlı Fourier Dönüşümü	57
Şekil 3.8. Dönüşümler	58
Şekil 3.9. Kesikli Dalgacık Analizi	58
Şekil 3.10. Dalgacık Ayrışımı	59
Şekil 3.11. Dalgacık Paketi Ayrışımı	59
Şekil 3.12. Dalgacık Süzgeç Fonksiyonlarının Çift Aile Kavramı	60
Şekil 3.13. d4 Dalgacık Fonksiyonu Kullanarak Örnek Sinyalin WP Tablosu	63
Şekil 3.14. Yapay Nöron Modeli	64
Şekil 3.15. İleribeslemeli Yapay Sinir Ağı Modeli	65
Şekil 3.16. Sigmoid Fonksiyonu	66
Şekil 3.17. Olasılıklı Yapay Sinir Ağı	68
Şekil 3.18. FDTD Uzay Örgüsünün Temel Elemanı	85
Şekil 3.19. FDTD Uzay Örgüsündeki Saçıcı	86
Şekil 4.1. Sinyalin %16'sından sonraki kısmının çıkartıldığında MPM dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal ise kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın	

	başladığı yeri gösterir	88
Şekil 4.2.	Sinyalin %16'sından sonraki kısmının çıkartıldığında MLP dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir	89
Şekil 4.3.	Sinyalin %32'sinden sonraki kısmının çıkartıldığında MPM dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal ise kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir	90
Şekil 4.4	Sinyalin %32'sinden sonraki kısmının çıkartıldığında MLP dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir	91
Şekil 4.5.	Dışdeğerleme yapılan sinyallerden bir örnek	94
Şekil 4.6.	Dışdeğerleme yapılan sinyalin değiştirilmiş versiyonu	94
Şekil 4.7.	Kayan pencereler arasındaki ortalama ortak bilgi ve pencere genişliğine bağlı grafiği	96
Şekil 4.8.	Kayan pencereler arasındaki ortalama ortak bilginin örnekleme hızına bağlı grafiği	96
Şekil 4.9.	Örneklenmiş saf sinüs dalgası	97
Şekil 4.10.	Üç kez fazla örneklenmiş aynı sinüs dalgası	97
Şekil 4.11.	Kayan pencereler arasındaki ortalama ortak bilgi ve örnekleme hızı	98
Şekil 4.12.	Özgün ve kesilmiş dalga formları	99
Şekil 4.13.	Özgün ve oluşturulmuş sinyallerin frekans boyutunda karşılaştırılması	100
Şekil 4.14.	Otomobil EMC laboratuvarındaki çevre gürültüsünün kısa-vade FFT çizimi	101
Şekil 4.15.	Otomobil rolantide çalışırkenki alanın Kısa-vade FFT çizimi	102
Şekil 4.16.	Otomobil rolantide çalışırkenki kısa-vade FFT çizimi (ateşleme işareti yokken)	102
Şekil 4.17.	Araç 1 için WP ağacı ve alt imgeleri	105

Şekil 4.18.	Ortam alanı için WP ağacı ve alt imgeleri	106
Şekil 4.19.	Araç 2 için WP ağacı ve alt imgeleri	107
Şekil 4.23.	Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,5\}$ ve $c=\{1,2\}$) Yatay eksen normal toplam esnekliği göstermektedir.	110
Şekil 4.24.	Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=\{1,2\}$). Yatay eksen normal toplam esnekliği göstermektedir	110
Şekil 4.25.	Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=(1,2)$). Yatay eksen normal toplam esnekliği göstermektedir	111
Şekil 4.26.	$P_{\max}$ masraf fonksiyonu iken $T_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=(1,2)$) Yatay eksen normal toplam esnekliği göstermektedir.	111
Şekil 4.27.	$T_{\max}$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ 'ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.	112
Şekil 4.28.	$(T_{\max}+T_{\text{son}})$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ 'ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.	113
Şekil 4.29.	$(T_{\max}+T_{\text{son}})$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ 'ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.	113
Şekil 4.30.	$P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/10$)	114
Şekil 4.31.	$P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/25$)	114
Şekil 4.32.	$P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/50$)	115
Şekil 4.33.	$P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/100$)	115
Şekil 4.34.	$P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/1000$)	115

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 1.1 Örnek problemler ve sınıflandırma	3
Çizelge 3.1. Benzetimlenmiş Soğutma (Simulated Annealing) Algoritmalarının Listesi	71
Çizelge 3.2. Metropolis Algoritması	72
Çizelge 3.3. Isı Banyosu Algoritması	75
Çizelge 3.4. VFSA Algoritması	81
Çizelge 4.1. Tahmin hatalarının karşılaştırılması (% RMS)	90
Çizelge 4.2. Tahminlerin karşılaştırılması	93
Çizelge 4.3. STFT dönüşümünden çıkarılan istatistiksel değişkenler kullanılarak yapılan sınıflandırma başarıları	103
Çizelge 4.4. STFT dönüşümünden çıkarılan istatistiksel değişkenler kullanılarak iki kademeli sınıflandırma sonuçları	104
Çizelge 4.5. WP alt imge enerjileri kullanılarak yapılan sınıflandırma başarısı	108
Çizelge 4.6. PNN Kullanılarak yapılan sınıflandırma sonuçları	108
Çizelge 4.7. % olarak VFSA sonuçları	109

1. GİRİŞ

Uygulamalı fizik ve mühendislikte karşılaşılan problemlerin sistematik bir biçimde çözülebilmeleri ve farklı problem şekilleri arasında benzerlikler kurarak yöntem alışverişini sağlayabilmek için doğru ve olabildiğince çok problem yapısını kapsayan genel bir problem şablonu bulmak gerekmektedir. İşlemsel zeka ve yapay zeka birçok bilim dalında problem çözümüne ışık tutabilen yöntemlerden oluştuğu için bu konuda bize yardımcı olacaktır. Bu yaklaşım işlemsel zekanın diğer bilimsel metotlar arasındaki yerini bulmamız konusunda da yol gösterecektir.

Tezin uygulama alanı olarak seçilen elektromanyetik bilim dalı uygulamalı fizikteki tanımı kapsamında kullanılmıştır. Elektronik mühendisliği biliminde elektromanyetik, sinyal işleme ve devreler anabilim dallarına yayılan bu problemler fizikte uygulamalı elektromanyetik altında toplanabilmektedir. Böylece bu alan diğer bilim dallarında karşılaşılan problemlere geniş bir örneklem olabilecek bir zenginliğe sahip olmaktadır. İşlemsel zekanın problem çözümünde uygulamalarını inceleyen bu tezin uygulama alanı olarak elektromanyetiği seçmesinin en önemli sebeplerinden birisi geniş uygulamaya sahip olmasıdır. Seçilen elektromanyetik problemlerin tanımlarına geçmeden önce problem çözümüne doğru bakış için geliştirilen ana fikrimizi ortaya koymak uygun olacaktır.

1.1. Problem Çözümü

Uygulamada karşılaşılan problemlerin


- a) Düz problemler
- b) Ters problemler ve eniyileme

olarak ikiye ayrılabilceği yaklaşımından hareket edeceğiz. Eniyileme problemlerini de kapsayan ters problem çözümlerini düz problem çözümünü tanımladıktan sonra incelemek daha kolay olacaktır.

1.1.1. Düz Problemler

Problem çözümlerinin önemli bir kısmını kapsayan düz problemler bilinen bir değerler grubundan yola çıkarak bilinmeyen diğer bir değerler grubunun bulunması şeklinde ifade edilebilir. İleride görüleceği üzere bu sınıftan farklılık gösteren ters problemler bu sınıf temel alınarak daha kolay bir şekilde incelenebilecektir.

Matematikte bilinen değerlerden bilinmeyen değerlerin bulunması, bir sistemi temsil edebilecek farklı referans sistemleri arasındaki dönüşümlerin veya haritaların keşfedilmesi ve dolayısıyla dönüşüm yapılmak istenilen bu referans sistemlerinin seçilmesi ve keşfedilmiş referans sistemi dönüşümleri içerisinde değişebilen kısımların istenilen doğrultuda değiştirilmesi şeklinde ele alınabilir.



Şekil 1.1. Genel Problem Modeli

Yukarıdaki tanıma göre sınıflama, örüntü eşleştirme, sensör veya bilgi füzyonu, fonksiyon yaklaşıklama, zaman serisi modelleme, öngörü gibi problemler referans sistemi dönüşümü şeklinde görülebilir. Şekil 1.1.'de bu yaklaşımın genel şablonu gösterilmiş ve Çizelge 1.1.'de bu yaklaşıma örnekler verilmiştir.

Çizelge 1.1 Örnek problemler ve sınıflandırma

Düz Problem	Referans Sistemi I	Referans Sistemi II	Dönüşüm
Spektrum Anl.	Zaman	Frekans kas.	Fourier dönüşümü
Sensör Füzyonu	Sensörler	Dikgen referans	Farklı Sistemler
Kontrol	Sensörler	Kontrol çıktıları	Farklı Sistemler
Sınıflandırma	Veri	Sınıflar	Farklı Sistemler
Öngörme	Eski veriler	Yeni veri	Farklı Sistemler
Dalgacık Anl.	Zaman	Dalgacık kats.	Dalgacık dönüşümü
Fonksiyon Yak.	Fonksiyon	Yaklaşık ifade	Farklı Sistemler
Örüntü Eşl.	Örüntü	Şablon	Farklı Sistemler
Zaman Ser. M.	Zaman Serisi	Model parametreleri	Farklı Sistemler
FDTD	Konfigürasyon	Dürtü cevabı	Zaman Benzetimi

1.1.2. Ters Problemler ve Eniyileme

Ters problemler düz problemlerin tam tersine Referans sistemi II'den I'e olan bir dönüşüm gerektirmektedir. Fakat bu tanım düz problemlerdeki dönüşümün tersinin alınabildiği durumları kapsamamaktadır. Çünkü referans sistemi I ve II arasındaki dönüşüm tam tersine dönüştürülebilme özelliği taşıyorsa bu durumda bu problem de bir düz problem olarak görülebilir çünkü sadece I ve II no'lu Referans sistemleri yer değiştirmiştir.

Gerçekten ters problem özelliği taşıyan problemlerde I ve II no'lu referans sistemleri arasındaki dönüşümün doğrudan tersini almak mümkün değildir. Gerçek ters problemlerde I uzayından II uzayına dönüşüm bilinmekte fakat tersi bilinmemektedir, dolayısıyla istenen II nolu uzaydan I nolu uzaya olan dönüşüm ancak II nolu uzaydaki istenen sonuçlara karşılık gelen değerlerin düz problemdeki dönüşüm aracılığıyla aranmasıyla gerçekleştirilebilir.

Eniyileme problemleri de buna benzer bir özellik göstermektedir. Eniyileme genellikle II nolu uzaydaki en düşük değerlere karşılık gelen I nolu uzay değerlerinin

aranmasına karşılık gelir. Bu durum eniyilemenin kolay olduğu analitik çözümleri dışlamaktadır. Ters problem çözümü ve eniyileme birbirine oldukça benzemektedir. Ayrıca çoğu ters problemin de istenilen değerler ile gerçek değerler arasındaki hata fonksiyonunun en düşüklüğüne edilmesi şeklinde bir eniyileme problemine dönüştürülebilir. (Göksu, 2002; Göksu vd., 2005-b).

Ters ve düz problemlerin arasındaki ilişkiyi izleyebilmek için hem ters hem de düz problemleri modele dayalı olan ve olmayan olarak ikiye ayırmak doğru olacaktır. Modele dayalı olmayanlar, modele dayalı problemlerin dışında kalan tüm alanı kapsadığı için özel bir tanıma ihtiyacı yoktur. Dolayısıyla modele dayalı problemlerin tanımlanması diğerinin de otomatikman tanımlanması anlamına gelmektedir.

Düz ve ters problemler arasındaki farkları ve eniyileme ile ilişkilerini daha iyi görebilmek için model tabanlı problemlere kısaca göz atmakta yarar var.

1.3. Model Tabanlı Problemler

Tanımını yaptığımız genel problem çözümü şablonunda model tabanlı problemlerdeki ölçüm verileri birinci referans sisteminde tanımlanan bir vektör iken, o sisteme ait öğrenilmek istenen model parametreleri sistemi ifade etmeye çalışan ikinci referans sistemindeki bir vektör olacaktır. Dolayısıyla problem çözümü bu referans sistemleri arasındaki dönüşümlerin keşfedilmesine çalışmak şeklini alacaktır. Model-veri ilişkisi bu durumu anlamamıza yardımcı olacaktır.

1.3.1. Model - Veri İlişkisi

Model tabanlı gerçek problemleri ele alacak olursak, ilk olarak elimizde ölçüm veya gözlem yoluyla elde ettiğimiz $\mathbf{d}_{göz}$ verileri mevcuttur. Gerçek dünya problemlerinde elde edebileceğimiz gözlem ve dolayısıyla veri sayısı sonlu olduğu için biz bu veriyi,

$$\mathbf{d} = [d_1, d_2, \dots, d_{DS}]^T \quad (1.1)$$

şeklinde bir sütun vektörle ifade edebiliriz. Burada DS, veri sayısını, T ise matrisin devriğini ifade etmektedir.

Ters problem çözümünde bu ve benzeri gözlem verilerinden yola çıkarak doğrudan gözleyemediğimiz veya ölçemediğimiz başka bazı değerlere ulaşmaya çalışırız. Veya bu veriyi kullanarak modellemek istediğimiz bir fiziksel yapı vardır. Bu modeli $\mathbf{m}$ ile ifade edeceğiz. Gözlem Verisinin sahip olduğu yapıya benzer olarak modeli de bir sütun vektör olarak ifade edebiliriz:

$$\mathbf{m} = [m_1, m_2, \dots, m_{MS}]^T \quad (1.2)$$

MS modeldeki parametre sayısını ifade etmektedir.

Gerçek dünya problemlerin model tabanlı çözümü için model ile veri arasında yine daha önceki gözlemlere dayanarak veriler arasındaki korelasyonlara bakarak analitik ilişkiler keşfedilmiştir. Bulunan analitik ilişkiler arasında yapılan matematiksel işlemler sonucu yine başka analitik ilişkiler elde edilebilmiş ve böylece doğa bilimlerinde evrenin dinamiklerini ifade eden bir ilişkiler ağı ortaya çıkmıştır. Her bir ilişkiyi ifade eden analitik ifadeler bir düz modelleme operatörü g ile ifade edilebilir. Dolayısıyla çözülmeye çalışılan problem,

$$\mathbf{d}_{göz} = g(\mathbf{m}) \quad (1.3)$$

ile ifade edilir.

Görüldüğü üzere model parametreleri bilindiği takdirde daha önceden bilinen g operatörü etki ettirilerek yapay gözlem verileri elde edilebilir. Buna $\mathbf{d}_{yap}$ yani yapay veri ismini vereceğiz. Fakat sadece verilerden yola çıkarak doğrudan metotlarla modele ulaşmak yalnızca g 'nin doğrusal olduğu durumlarda mümkündür.

1.3.2. Doğrusallık Koşulu

Evrende çözülmeye çalışılan gerçek matematiksel problemlerin hemen hepsi doğrusal olmayan cinstendir. Bu yüzden çoğu zaman ilişkiler doğrusallaştırılarak çözülmeye çalışılır. Yani analitik çözüm için doğrusallık şarttır. Bu durumun mümkün olması iki koşuldan birine bağlıdır.

1) Bunlardan birincisi bazı problemlerde olduğu gibi özel şartların sağlandığı durumlarda ilişkiler yaklaşık olarak doğrusal bir şekle dönüştürülür. Örneğin bir sarkaç problemini ifade eden,

$$d^2\Theta / dt^2 = - (g / l) \sin \Theta \quad (1.4)$$

doğrusal olmayan denklemini çözülebilmek için, Θ 'nın küçük açı değerleri için denklem,

$$d^2\Theta / dt^2 = - (g / l) \Theta \quad (1.5)$$

şeklinde doğrusallaştırılır ve ancak bu şekilde çözüm sağlanır.

2) Analitik çözümlerin doğrusal olmayan sistemler için kullanılmasının mümkün olduğu ikinci durum ise model parametrelerinde oluşturulacak sarsım ile veride yapılacak sarsım arasında yine yaklaşık olarak doğrusal ilişkiler elde edilebildiği durumlardır.

Bu durumlarda $\mathbf{d}_{göz}$ gözlemsel verisinin, $\mathbf{m}_0$ referans modeline $\Delta\mathbf{m}$ sarsımı uygulanarak oluşturulan yeni bir modele g operatörünün etki etmesiyle elde edildiğini varsayınız. Yani:

$$\mathbf{d}_{göz} = g (\mathbf{m}_0 + \Delta\mathbf{m}) \quad (1.6)$$

ve

$$\mathbf{d}_{\text{yap}} = g(\mathbf{m}_0) \quad (1.7)$$

Daha sonra bir önceki eşitliğin $\mathbf{m}_0$ referans modeli etrafında Taylor serisi açılımını yaparsak şunu elde ederiz:

$$g(m_0 + \Delta m) = g(m_0) + \left. \frac{\partial g(m_0)}{\partial m} \right|_{m=m_0} \Delta m$$

+ iki ve daha yüksek dereceli terimler. (1.8)

Yüksek dereceli terimleri çok küçük olacaklarını bildiğimiz için ihmal edersek denklem sistemimiz:

$$d_{g\partial z} = d_{\text{yap}} + \left. \frac{\partial g(m_0)}{\partial m} \right|_{m=m_0} \Delta m \quad (1.9)$$

veya,

$$\Delta \mathbf{d} = \mathbf{G}_0 \Delta \mathbf{m} \quad (1.10)$$

şeklinde değişir.

$\Delta \mathbf{d} = \mathbf{d}_{\text{göz}} - \mathbf{d}_{\text{yap}}$ ve $\mathbf{G}_0$ hassasiyet matrisidir veya bir başka deyişle yapay verilerin model parametrelerine göre kısmi türevlerinden oluşan matristir. Şimdi artık verideki sarsım ile model parametrelerindeki sarsım arasında doğrusal bir ilişkiye sahip olduk.

Bunun ters çözümü şu şekilde ifade edilir:

$$\mathbf{m} = \mathbf{G}^{-1} \mathbf{d}, \quad (1.11)$$

$\mathbf{G}^{-1}$ düz problem operatörünün yani $\mathbf{G}$ 'nin ters operatörüdür.

Bu durum eldeki problemin çözümünün olup olmaması konusunda “çözümün varlığı, çözümün tekliği ve çözümün kararlılığı” problemlerini göz önünde bulundurmamızı gerektirir (Koch, 1990; Tarantola, 1987).

Bu aşamadan sonra En Küçük Kareler Yöntemi ve En yüksek olasılıklı metotları kullanılır. Bunların çözümü sırasında stabilite, teklik ve tekil değer ayrışımı, sonucu kısıtlama metotları ve belirsizlik tahminleri gibi konular işin içine girmektedir. Bu tezin konusuyla doğrudan alakalı olmadığı için burada bu açıklamalarla yetinilmiştir. Daha detaylı bilgi kaynaklardan elde edilebilir (Sen ve Stoffa, 1995).

1.3.3. Yarı Doğrusal Problemler

$\mathbf{d} = \mathbf{g}(\mathbf{m})$ sisteminin ters çözümü düz problemin doğrusal olduğu durumlarda ve verideki sarsımların model parametrelerindeki sarsımlarla doğrusal ilişki gösterdiği zayıf doğrusal olmayanlık durumlarında; doğrusal denklemler kümesine dönüştürülebilir. Böyle durumlarda ters çözümün en küçük kareler veya tekil değer ayrışımı metotları ile bir adımlık bir işlem olduğundan ve model tahminlerinin ve belirsizliklerinin kolaylıkla hesaplanabileceğinden kısaca söz edildi. Doğrusallık varsayımı geçerli olmadığı durumlarda bu metotlar işe yaramaz. Bundan biraz daha karmaşık bir durum ise yarı doğrusallık durumudur ki bu durumda hata yüzeyinde en düşük hataya karşılık gelen durağan noktaya; bir başlangıç modeli etrafında yerel doğrusallaştırma yaparak ve iterasyon yoluyla modeli yenileyerek ve eldeki veri ile karşılaştırarak ulaşılabileceği varsayılır. Bu durum yarı doğrusal sistemler için geçerli olup her iterasyonda doğrusal ortalamalar alınarak en düşük noktasına biraz daha yaklaşılr ve adımlar boyunca hata gittikçe düşer.

$$\Delta \mathbf{d} = \mathbf{G}_0 \Delta \mathbf{m} \quad (1.12)$$

denklemini bu amaçla şu şekilde kullanılır: $\Delta \mathbf{d}$ sapma vektörü, $\mathbf{G}_0$ verinin model parametrelerine olan kısmi türevlerini içeren matris ve $\Delta \mathbf{m}$ model yenileme vektörüdür. Bu vektör yeni bir model elde etmek için referans modeline eklenir.

Daha sonra $\Delta \mathbf{d}$ hesaplanır ve bu işlem bir hareket gözlenmeyinceye kadar tekrar edilir. Yani aşağıdaki denklem iteratif olarak uygulanır:

$$\mathbf{m}_{i+1} = \mathbf{m}_i + \mathbf{G}_0^{-1} |_{\mathbf{m}=\mathbf{m}_i} [\mathbf{d} - \mathbf{g}(\mathbf{m}_i)] , \quad (1.13)$$

burada $\mathbf{d}$ gözlenen veri, $\mathbf{g}(\mathbf{m}_i)$, model $\mathbf{m}_i$ için sentetik veri üreten operatördür.

Gerçek uygulamalarda karşılaşılan doğrusallık sorunları Izgara Arama metotları ve farklı düzeyde akıllılık özelliği gösteren farklı MC metotları kullanarak aşılabilmektedir.

1.4. Modele Dayalı Olmayan Problemler


Modele dayalı olmayan problemlerde genel problem çözümünde tanımlanan dönüşüm kısmı için herhangi bir analitik model mevcut değildir. Örneğin tez çalışmasında incelenen problemlerden birisi olan elektromanyetik kaynak tanıma problemi bu cinstendir. Otomobil gibi karmaşık elektromanyetik kaynak ışınlamalarının otomobil sınıflarına haritalanması konusunda herhangi bir teorik model mevcut değildir. Burada uygulanabilecek çözüm ise farklı sinyal işleme tekniklerini kullanarak parametreler arasındaki dönüşümü keşfetmeye çalışmaktır. Çalışmada sırasıyla STFT ve WP metotları bu amaçla uygulanmıştır.

1.5. Optimizasyon Problemleri

Eniyileme problemleri, model parametreleri referans sisteminden en iyi değeri istenen başka bir parametre grubunun oluşturduğu referans sistemine yapılan haritalama çerçevesinde en iyi olması istenen parametrenin evrensel en düşük noktasının aranmasından ibarettir.

Bu arama haritanın doğrusal veya yarı doğrusal olduğu durumlarda bir önceki bölümlerde açıklandığı şekilde iteratif metotlarla bulunabilir. Bu koşulların sağlanmadığı durumlarda ise en düşük noktasının aranması başlangıç değerine bağlı

olduğu için (Şekil 1.2.) daha farklı yöntemleri denemek gerekir. Bunlar da genel olarak Monte Carlo Metotları olarak bilinmektedir.



Şekil 1.2. Bir Boyutlu tipik bir doğrusal olmayan hata/model eğrisi

Şimdi Monte Carlo (MC) Metotlarını inceleyelim. Fakat önce kısaca arama metotlarına baz alınan en basit ve kapsamlı arama metodu olan Izgara Arama (GS) metoduna kısaca deyinelim:

1.5.1. Izgara Arama (GS: Grid Search)

GS metodu, önceden belirlenmiş model doğrultusunda model uzayının tümünü bir ızgara yardımıyla küçük parçalara ayırarak tarama esasına dayanır. Yani başka bir deyişle çözüm için belirlenen model parametreleri, her değer için denenir ve böylece model uzayında denenen değerler için en iyi parametreler seçilerek problem çözülmüş olur.

Genellikle arama uzayları çok büyük olduğu için bu metot çok verimli değildir, bilgisayar kaynaklarını kullanım açısından da çok pahalıdır. MC metotları ise olasılık ve istatistik yöntemlerinden faydalananarak bu verimliliği artırmaya çalışır.

1.5.2. Monte Carlo (MC) Metotları

MC metotları modellerin düzgün bir dağılımdan rastgele seçilmesi ve veriyle kıyaslanmasına dayanan rastgele arama metotlarıdır. MC metodunu kullanarak ters problem çözümünde her model parametresinin daha önce belirlenen bir arama aralığında değişmesine müsaade edilir. Her m_i model parametresi için şu aralık tanımlanır:

$$m_i^{\min} \leq m_i \leq m_i^{\max} . \quad (1.14)$$

$U[0,1]$ düzgün dağılımından rastgele bir sayı seçilir ve model parametresine uygulanır. Örneğin, rastgele sayının rs olduğunu varsayalım, bu durumda yeni model parametre değeri şu şekilde verilebilir:

$$m_i^{\text{yeni}} = m_i^{\min} + (rs) (m_i^{\max} - m_i^{\min}) \quad (1.15)$$

Model vektörünün belli sayıda model parametresinde rastgele sarsım yapılarak yeni bir rastgele model vektörü üretilebilir. Daha sonra yeni model için yapay veri üretilerek gözlem verisiyle karşılaştırılır. Model, yapay verinin gözlem ile ne kadar uyduğuna dair belirlenmiş bir kritere göre belirlenimci olarak ret veya kabul edilir. Bu üretme-ret/kabul işlemi belli bir durma kriteri oluşuncaya kadar sürdürülür. Genelde kullanılan durma kriteri belli sayıdaki kabul edilen model sayısıdır.

Görüldüğü gibi çalışma prensibi açısından MC metodu doğrusal olmayan ters problemler için kullanılabilir. Çünkü doğası gereği arama sırasında yerel en düşük noktalara takılma problemi yoktur. Fakat düzgün bir dağılımdan çektiği rastgele sayıları kullanarak tüm uzayı ağırlıksız olarak taradığı için bilgisayar kullanımı olarak oldukça pahalıdır ve istatistiksel olarak evrensel en iyi noktanın bulunmasının garantilenmesi çok zordur. Bu kısıtlamanın giderilmesi için önerilen bir metot önceden bilinen bilgilerin bir ön olasılık yoğunluk fonksiyonu tanımlanmasında kullanılması ve böylece arama uzayının kısıtlanmasıdır.

Saf MC metotlarının getirdiği yoğun bilgisayar yükünün hafifletilmesi ve böylece zaman boyutunda verimli hale gelmesi için Yönlendirilmiş MC Metotları geliştirilmiştir. Bunlardan ikisi Genetik Algoritmalar ve Simusyonlu Soğutma (SA: Simulated Annealing) algoritmalarıdır. Bu tez çalışmasının birden fazla yerinde birçok açıdan daha verimli olduğu kanıtlanan SA metotlarından birisi olan Çok hızlı Benzetimlenmiş Tekrar Soğutma (VFSR: Very Fast Simulated Reannealing) algoritması kullanılmıştır. Bu iki algoritmayı kıyaslayan Ingber vd. (1992) VFSR algoritmasının Genetik Algoritmaya göre çok daha hızlı ve verimli olduğunu göstermiştir.

Yönlendirilmiş MC algoritmaları yine rastgele yürüme metodu kullanmakla birlikte düz MC algoritmalarından farklı olarak aramayı yönlendirmek için geçiş olasılığı kuralları kullanırlar ve böyle olduğu için düz MC metotlarından çok daha iyi oldukları birçok uygulama ile kanıtlanmıştır.

1.6. Referans Sistemlerine Ait Altyapılar

Referans sistemlerini ve aradaki dönüşümleri tanımlayan ve kurallarını koyan altyapılar sırasıyla düz mantık (veya klasik veya kırılğan mantık), bulanık mantık ve kuantum mantıklarını temel alabilmektedir. Örneğin kuantum mantığı kapsamında çözülmek istenen bir problemin referans sistemlerindeki vektörlerin Hilbert uzayında ifade edilmesi ve haritaların kuantum mekaniğinden alınan kuantum mantığının kural ve yöntemleriyle belirlenmesi gerekmektedir.

Bu tanımdan yola çıkarak her problemin her kapsamda ifade edilemeyeceğini söyleyebiliriz. Kapsamların çıkarıldığı sistemlerin yeni uygulanmak istenen sistemlerle izomorfizm göstermesi gerekmektedir. Mesela mikroskopik uzaydan alınan kuantum mantığının makroskopik uzaya uygulanabilmesi için makroskopik uzaydaki sistemle kuantum sistemleri arasında izomorfizmin var olduğunun gösterilmesi gerekmektedir (Göksu, H., 2005-c; Göksu, 2005-d).

Şimdi tanımını yaptığımız problem çözme şablonunda konumuz olan işlemsel zekanın yerinin tespit edilmesinin zamanı geldi.

1.7. İşlemsel Zeka

Tabiattaki canlı ve cansız süreçler incelendiği zaman bilimde kullandığımız problem çözümüne benzer davranışlar gösterdiği görülmektedir. Örneğin kristallerin oluşumu sırasında atomların enerji dönüşümleri arasındaki seçimlerini modelleyen benzetimlenmiş soğutma (SA) algoritmaları karmaşık problemlerin çözümünde başarıyla kullanılmaktadır (Göksu, 2002). Bir başka örnek olan canlılardaki sinir sisteminin yapısını modelleyerek çalışan yapay sinir ağları öğrenebilen ve adapte olabilen sistemler oluşturmakta başarıyla kullanılabilir. Karıncaların davranışını modelleyen karınca kolonisi algoritmaları ve kuşların sürü halinde uçuşlarını modelleyen parçacık sürü eniyileme metotları ve canlıların genotip ve/veya fenotiplerindeki kooperatif değişimleri modelleyen evrimsel hesaplama metotları yine karmaşık bilimsel problemlerin çözümünde kullanılmaktadır.

Doğada gözlenen bu problem çözme davranışının modellenmesi yoluyla elde edilen akıllı algoritmalar işlemsel zekanın parçaları sayılmaktadır. Dolayısıyla işlemsel zekanın doğadan ödünç alarak karmaşık ve değişken şartlarda zeki davranışlar gösterebilen uyarlanabilir mekanizmalar modellemeye ait çalışmaları kapsadığı söylenebilir. Bu mekanizmalar öğrenme ve yeni durumlara adapte olma, genelleme, soyutlama, keşif ve eşleştirme kabiliyeti gösteren yapay zeka (AI) modellerini kapsamaktadır. İşlemsel zeka metotları mantık, tümdengelimli muhakeme, uzman sistemler, durum tabanlı muhakeme ve sembolik makine öğrenen sistemler ile birleşerek Yapay Zeka (AI) alanının bir parçasını oluşturmaktadırlar.

Bu kadar geniş ve multidisipliner bir konu olan işlemsel zeka ve yapay zekanın mantık sistemleri ile arasındaki ilişkinin incelenmesi sınırlarının belirlenmesi açısından faydalı olacaktır.

1.7.1. Mantık Sistemleri ve Yapay Zeka

Literatürde bulanık mantığı ve bundan türetilen bulanık sistemleri işlemsel zekanın ve dolayısıyla yapay zekanın bir parçası olarak gösterenler vardır. Bunun sebebi bulanık sistemlerin keşfedilmesinin organizmaların çevreleriyle olan ilişkilerinin incelenmesi yoluyla olmasıdır. Bir başka sebep ise bulanık mantık kapsamında bu mantıktan türetilen diğer işlemsel zeka tekniklerinin bulunmasıdır, örneğin bulanık sinir ağları (fuzzy neural systems).

Fakat önceki bölümde bahsedildiği üzere bulanık mantık, klasik mantığın daha genel bir hali olan bir mantık sistemidir. Eğer bulanık mantık yapay zekaya dahil edilirse atom altı parçacıkların davranışlarını modelleyen kuantum sistemlerinin de yapay zekanın içerisine dahil edilmemesi için hiçbir sebep yoktur. Çünkü birçok problemde kuantum algoritmaları klasik algoritmalarından daha hızlı ve verimli olarak sonuca ulaşabilmektedir.

Bu durumda mikroskopik düzeyde geçerli olan kuantum mantığının makroskopik düzeye genellenmesinden ibaret olan ve kapsam bakımından onun bir alt kümesi olan klasik mantığın da doğadaki süreçleri modelleyerek oluştuğu hesaba katılırsa, klasik mantığın ve ondan türetilen klasik matematik biliminin de yapay zekaya kapsamına eklenip geriye neredeyse hiçbir şey kalmayacak şekilde herşey yapay zeka kapsamı altına dahil edilecektir.

Fakat burada dikkat çekilmesi gereken bir konu tüm bu süreçlerin doğadaki olayları modelleyerek insan beyni tarafından yapıldığıdır. Örneğin her ne kadar karınca kolonilerinin davranışları bir problem çözme tekniği halinde insanlar tarafından modellenebilse de karıncaların davranışlarını problem çözme kastıyla yaptıklarını düşünmek zordur.

O halde doğanın modellenmesiyle oluşan ve yapay zeka tanımını oluşturan *zeka* tanımının irdelenmesi ve bilgisayarlarla ilişkilendirilmesi gerekir.

1.7.2. Zeka ve Bilgisayarlar

Zekaya tanım bulmaya yönelik çabalar hala önemini korumaktadır. Sözlükler zekayı idrak kabiliyeti, deneyimleri anlama ve faydalanma, zekayı yorumlayabilme, düşünme ve muhakeme kapasitesine (özellikle yüksek derece) sahip olma olarak tanımlamaktadır. Zekanın farklı yönlerini ortaya koyan diğer anahtar kelimeler ise yaratıcılık, ustalık, şuur, duygu ve sezgidir.

Bilgisayarlar zeka gösterebilir mi? Bu soru günümüzde zekanın tanımından daha çok tartışmaya sebep olmaktadır. 1900'lerin ortalarında Alan Turing (Turing, 1950) bu soru üzerinde çok çalışmış bilim adamlarından birisidir. İnsan beyin süreçlerini taklit eden makinaların yapılabileceğine ve beynin yaptığı şeyler arasında iyi tasarlanmış bir bilgisayarın yapamayacağı birşeyin olmadığına inanan Turing'in sözleri elli sene sonra hala tam olarak gerçekleşmiş değildir. Biyolojik sinir sistemlerini modellemede başarı sağlanmasına rağmen insan zekasının önemli parçaları olan sezgi, şuur ve duyguların modellenmesi gibi karmaşık problemlere henüz bir çözüm bulunamamıştır.

Tüm bu kapsamda bilgisayarların tanımlandığı şekilde zeka gösterip gösteremeyeceğini tartışan kişiler bilgisayarların da her ne kadar insan tasarısı olsalar da doğanın bir parçası olduklarını gözardı etmemeleri gerekir. Özellikle kuantum bilgisayarlardaki gelişmelerle birlikte daha da doğayla, yani atomlarla ve atomik sistemlerle bütünleşen makinaların oluşacağı gözardı edilmemelidir.

Bunlara ek olarak artık kök hücre metotlarıyla laboratuvarlarda sinir hücreleri de dahil olmak üzere istenilen her türlü hücre üretilmekte ve yaşatılabilmektedir. Dolayısıyla yakın bir gelecekte biyolojik bilgisayarların üretilmeyeceğini söylemek zordur. Yakın geçmişte kullanılmaya başlanan biyosensörler belki de bu çabalar için bir ilk adımdır.

Konumuz olan yapay zekaya geri dönecek olursak, Turing (1950) Turing testi ismini verdiği bilgisayar zekasının test edilmesine dair bir yöntem yayınlamıştır. Test bir

kişiyi ve de bir bilgisayara klavye yardımıyla sorular sorularak yapılır. Turing'e göre sorguya çeken kişi bilgisayarı diğer kişiden ayırt edemezse bilgisayarın zeki olduğu anlaşılabacaktır. Turing 2000 yılında 1E9 bit hafızaya sahip bir bilgisayarın 5 dakikalık Turing testini %70 olasılıkla geçebileceğine inanıyordu. İnancının gerçekleştiği söylenebilir mi? Bu sorunun cevabı başka bir tartışmaya meydan vermemek için açık bırakmak uygun görüldü.

Bu konuyu daha yeni bir yapay zeka tanımı olan IEEE yapay sinir ağları meclisinin 1996'daki tanımına değinerek bitirmek uygun olacak: "Yapay zeka, insanların daha iyi yaptığı işlerin bilgisayarlara nasıl yaptırılabilmesine yönelik çalışmalardır."

Bu tez çalışmasında kullanılan AI yöntemleri yapay sinir ağları alt dalına ait olan ileri beslemeli Çok Katmanlı Perceptron (MLP: Multilayer Perceptron) sinir ağları, olasılıksal sinir ağları (PNN) ve çok hızlı benzetimlenmiş tekrar soğutma (VFSR) algoritmalarıdır. Çözülen problemlerde benimsenen referans sistemleri arasındaki dönüşüm yaklaşımı tüm problemlere daha geniş açıdan bakabilme imkanını vermiştir. Referans sistemlerinin verimliliğini incelemek ve başka bir deyişle daha verimli referans sistemleri oluşturmak için ve başka bir açıdan bakılınca verimsiz referans sistemlerinden daha verimli referans sistemlerine geçişte harita olarak kullanılmak üzere asal bileşen analizi (PCA) ve entropi istatistiği yöntemleri kullanılmıştır. Bunun yanında sistemlerin daha kolay yorumlanabilmesi için fourier dönüşümleri ve dalgacık paketi dönüşümleri dönüşüm tekniği olarak kullanılmıştır. Bazı yerlerde peşpeşe uygulanan dönüşümler arasında istatistiksel parametre çıkarımı da kullanılan referans sistemi dönüşümü yöntemleri arasındadır.

Artık çözülen elektromanyetik problemlerin tanımlanması ve benimsediğimiz referans sistemleri dönüşümü yaklaşımında alacakları şeklin belirlenmesi gerekir.

1.8. Elektromanyetik Problemler

Bu çalışmada çözüm için seçilen dört elektromanyetik problemten ikisi yukarıda tanımı yapılan düz problem kapsamına girecek problemlerdir. Bunlardan birisi model tabanlı diğeri ise model tabanlı olmayan problemlerdir. Kalan iki problem ise

eniyileme problemleridir. Bunlardan birincisinde düz problem olarak model tabanlı tümdevre modellemesi alınırken ikincisinde ise düz problem olarak sıcaklığın MC benzetimi ile modellenmesi alınmıştır. Şimdi problemlere göz atalım.

1.8.1. Birinci Problem: Elektromanyetik Kaynak Tanıma

Elektromanyetik kaynaklar arasında otomobiller oldukça karmaşık yayım kaynakları oldukları için elektromanyetik kaynak tanıma probleminde modeli olmayan düz bir problem olarak bu uygulama seçilmiştir. Tipik olarak otomobillerin diğer birçok makinada olduğu gibi bilinçli veya bilinçsiz onlarca elektromanyetik yayım kaynağı vardır. Mikroişlemci devreleri, güç devreleri, haberleşme devreleri, elektronik ateşleme, sensörler, motorlar ve aktuatörler hepsi etkili elektromanyetik karışım kaynakları olmaya aday aygıtlardır. Bu sinyaller uygun bir antene kuple olarak istenen veya istenmeyen yayımlara dönüşebilirler (Ruddle vd. 2003; Noble 1992).

Yıllar boyunca elektromanyetik uyumluluk (EMC) mühendisleri farklı elektromanyetik yayım kaynaklarının tespiti ve karakterizasyonu için çeşitli alet ve teknikler geliştirmişlerdir. Bu teknikler zaman boyutu dalga şekli analizi, kısa vadeli FFT, sıfır aralıklı ölçümler ve AM/FM demodülasyonu ve diğer yöntemleri (Göksu vd., 2004) içermektedir. Bu yöntemlerin kullanımıyla edinilen tecrübeleriyle EMC mühendisleri farklı kaynakların elektromanyetik imzalarını farketmeyi öğrendiler.

Bu teknikler aynı zamanda elektronik sistemlerin otomatik tanınması için de kullanılabilir. Mesela, farklı firmalar tarafından üretilen veya farklı bileşenler taşıyan otomobiller genellikle farklı elektromanyetik yayımlara sahip olacaktır. EM yayım verilerini yukarıda bahsedilen yöntemleri kullanarak işlemek üzere, farkları ortaya koyacak biçimde kaydetmek mümkündür. Bu farklar bir otomobilin varlığını tespit etmekte veya belli bir otomobil tipini farketmekte kullanılabilir.

Gerçekçi bir devre tasarımında ışıyan tüm yayımları yok etmek mümkün değildir. Yüksek hızlı sayısal devrelerde yayımı standartlarda istenilen limitlerinin altına düşürmek bile büyük bir problem olabilir. Eğer bu yayımlar doğru bir şekilde

karakterize edilirse, bu bilgi elektronik veya radyo kontrollü mühimmatın tespiti, tanınması, konum ve durum tespitinde kullanılabilir. Benzer problemler EMC ve radyo mühendisleri tarafından yıllarca araştırılmıştır. Birçok EMC mühendisi sadece elektromanyetik imzasına bakarak elektronik cihazlar tarafından yerine getirilen işlevleri veya problemlili yayımları tespit edebilmektedir. Elektronik ürünlerdeki elektromanyetik yayımları, diğer istemli ve istemsiz RF üreten kaynakların yakınındayken tanımak, konum tespiti ve karakterize etme amacıyla yöntemler geliştirmişlerdir. Elektromanyetik radyasyon kaynaklarının çok geniş alanlardaki konumunun tespiti, kaynakların doğru tanınmasından sonra anten alan teknikleri kullanarak kolayca yapılabilir.

Dolayısıyla gizlenmiş elektronik ve radyo kontrollü mühimmatı elektronik yayımlarına bakarak tespit etmek mümkündür. Elektromanyetik kaynakların tanınmasının uygulanabileceği bir diğer uygulama insani amaçlarla mayın temizlemedir. Elektronik zamanlama sistemlerine sahip yeraltı mayınlarının yaptıkları EM yayımlardan yola çıkarak tanınması bu yöntem temel alınarak mümkün olacaktır. Kullanılan metotlar EMC ve radyo mühendislerinin elektronik ürünlerin analiz ve testinde ve elektromanyetik kaynakların yer tespitinde kullandıkları metotları ve benzer uygulamalarda kullanılan sinyal işleme ve tanıma metotlarını kapsamaktadır. Düşük güçle (insanları incitmeden) araçların durdurulması ise başka bir potansiyel uygulama alanıdır. Bunun ilk adımı aracın tanınması ve daha sonra da anında sadece o aracı durdurabilecek sinyali üretmektir.

Anlatılanlar çerçevesinde elektronik kaynak tanıma probleminin çözümü için Kısa Vadeli Fourier (STFT) ve Dalgacık Paketi Dönüşümleri (WP) yardımıyla sinyal anlaşılır hale getirilerek MLP yapay sinir ağları ve olasılıksal yapay sinir ağları ile sınıflandırılmıştır. Girdi uzayının çok yüksek boyutlu olduğu durumlarda Asal Bileşen Analizi (PCA) kullanılarak bu boyut düşürülmüştür. Farklı gün ve zamanlarda üç farklı otomobilin yaydığı ışıınımdan elde edilen üç grup sinyal otomobilin yokluğunda alınan gürültü sinyalleri ile toplam dört sınıf oluşturmuştur. Arabaların varlığındaki sinyallerde periyodik olarak rastlanan kıvılcımın sınıflandırmadaki etkisi incelenmiştir. Yöntemin gömülü mühimmata genellenebilir

olduğunu göstermek için Yugoslav kökenli bir yer altı mayınının elektronik ateşleme tertibatının yaptığı ışınlamayı yansımasız odada kaydedilerek incelenmiştir.

1.8.2. İkinci Problem: FDTD Benzetimlerinde Veri Dışdeğerlemesi

Elektronik sistemlerin Elektromanyetik Uyumluluk (EMC: Electromagnetic Compatibility) karakteristiklerinin benzetiminde oldukça çok kullanılan FDTD simülasyonları (Taflove, A., 1989) çınlamaya sahip yapılar için işlemsel süre bakımından çok pahalı hale gelebilmektedir. Bir yapının benzetimi haftaları bulan bilgisayar işlem süreleri gerektirebilmektedir. Bu problemin çözülerek benzetimin süresini kısaltmak için belli sayıda zaman adımından sonra benzetimi durdurup geri kalan sinyalin bir dışdeğerleyici tarafından öngörülmesi bu çalışmanın amacıdır.

İlk aşamada üstdüşümlenmiş sönümlenen sinüzoidlerden oluşan yapay bir zaman serisi üzerinde MLP yapay sinir ağlarının kısa vadeli öngörüsü ile doğrusal bir özealiz yöntemine dayanan Matris Pencil Metodu (MPM: Matrix Pencil Method) öngörü başarıları yönünden karşılaştırılmıştır. Daha sonra gerçek bir FDTD sinyalinde Matris Pencil Metodu (MPM)'nun uzun vadeli dışdeğerlemesi incelenmiştir.

Frekans analizi bakış açısından tüm öngörü girişimleri, öngörülen sinyalin frekans bant içeriğini tekrar oluşturmak için kullanılan kesilmiş sinyalin bant genişliği ile sınırlı kalacaktır. Dolayısıyla benzetimin erken durdurularak tahmin yoluna gidilmesi işlemsel zamanı kısaltırken frekans içeriğinde kayba neden olabilir. Fakat kesilen sinyalin frekans içeriğinin pratikte yeterli olabileceğini ve bu içeriğin zamansal değişiminin kestirilerek daha sonraki sinyalin öngörülebileceğini varsaymaktayız.

Kesintiye uğramış gürültülü sinyallere ait karakteristik parametrelerin çıkarılmasına dair literatürde bazı çalışmalar yapılmıştır. Bunların içerisinde bir grup çalışma Prony metodundan çıkarılan metotlardır ve bunların kökeni birkaç yüzyıl öncesine dayanmaktadır. Bu metodun temeli kesilmiş orjinal sinyale uyan belirlenimci üstel bir model aramaya dayanmaktadır. Model sönümlenen sinüzoidlerden oluşmakta ve bunların herbiri bir frekans ve sönümlenme faktörüyle belirlenmektedir. Bu

parametreleri çıkarmak için farklı yollar uygulanabilir fakat diğerleriyle kıyaslanınca Matris Pencil metodu gürültüye karşı en kararlı olanıdır (Hua, Y. vd., 1990). Bu metot sönümlenme faktörlerini ve frekansları bir pencil matrisinin çözümlerine karşılık gelen özdeğer ve kutuplardan çıkarmaktadır.

Metot Y. Hua ve T. K. Sarkar (Hua, Y. vd., 1988) tarafından ortaya konmuştur. İlk olarak sinyale ait veri örnekleri iki adet kare olmayan Hankel matrislerini dolduracak şekilde seçilmekte ve daha sonra bunlara dayanarak bir pencil matrisi oluşturularak tekil değer problemi yoluyla çözülmektedir. Kutup değerleri seçildikten sonra bunlara karşılık gelen kalıntılar (residue) en küçük kareler yaklaşımıyla hesaplanır ve özgün sinyal yeniden oluşturulur. Dolayısıyla sinyalin kutupları genelleştirilmiş bir özdeğer problemini çözerek belirlenir.

Model tabanlı düz problemlere örnek olarak alınan bu problemin test edilmesi için kayan pencere yöntemine dayalı MLP dışdeğerlemesinin yapay sinyal üzerinde MPM yöntemine göre başarılı olmasına karşın gürültülü gerçek sinyallerde kayan pencerenin kümülatif olarak yerel hataların üstüste ekleneceğinden dolayı tercih edilemeyeceği görülmüştür. Gerçek bir FDTD benzetiminden elde edilen sinyal üzerinde MPM dışdeğerleme denemeleri yapılmıştır. Metotta esasında uyarlanabilir olmayan kutup sayısı ve pencil parametresinin dışdeğerleme başarısındaki gradiyente bağlı basit bir eniyileme ile uyarlanabilir hale getirilebileceği gösterilmiştir. Ayrıca kayan pencere metodunun kullanılabileceği durumlarda pencere genişliğinin ve sinyal örnekleme frekansının eniyilemesi için bilgi teorisindeki entropi istatistiğine dayalı bir yöntemle başvurulmuştur.

1.8.3. Üçüncü Problem: Düşük Güç Tümdevre Tasarımı

Eniyileme tipi problemlere bir örnek olarak düşük güç tasarımı ele alınmıştır. Tümleşik devrelerde güç harcamasının azaltılması elektronik endüstrisinde son derece önemli konulardan birisi haline gelmiştir.

Besleme gerilimini azaltmak güç harcamasını düşürmek için başvurulan yöntemlerden birisidir. Güç dinamik güç ve kaçak güç olmak üzere ikiye ayrılırsa besleme geriliminin dinamik güç ile arasındaki ilişki karesel iken kaçak güçle arasındaki ilişki neredeyse doğrusaldır. Günümüz teknolojisinde dinamik güç halen toplam güç tüketiminde baskın rol oynamaktadır fakat bu yakın gelecekte değişecektir. Otomatik tasarım yazılımları daha önceden belirlenmiş besleme ve eşik potansiyellerine sahip dijital devreler üretmektedir. Fakat bu değerler güç tüketimi ve pil sığası bakımından genellikle en iyi değildir. Güç kısıtlaması olan uygulamalara yönelik tasarımlar için yeni güç eniyileme yazılımları gerekir.

Güç eniyileme metotları kullanılınca güç genellikle gecikme ve kaplanan alanla değiş tokuş edilebilir ve devrenin hızı kritik yol tarafından belirlenir. Tasarımcılar kritik yol gecikmesini boyutu değiştirerek eniyilerler. Devredeki tüm yollar dengeli olmadığı için kritik olmayan yollar üzerinde gevşeklik bulunmaktadır. Bu gevşeklik güç tüketimini eniyilemek için kullanılabilir. Anahtarlama faaliyeti de uygulama yazılımıyla değiştiği için belirleyici bir faktördür. Optimal performans için devrenin ortalama anahtarlama faaliyetinin de belirlenmesi gerekir.

Besleme potansiyeli dinamik güce karesel ve kaçak güce doğrusal bağlı olduğu için onu azaltmak güç tasarrufu için en etkili yol olmasına rağmen besleme potansiyelini düşürmek devre gecikmesini artırır ve işlem hızını azaltır. Eşik potansiyelini düşürmek ise devre hızını artırır ve devrenin gereken frenkansta çalışmasına yardımcı olur. Öteki yandan eşik potansiyelini düşürmek kaçak akımı üstel olarak artırır. Dolayısıyla besleme potansiyeli ve eşik potansiyeli arasında gecikme sınırlamasının sağlandığı ve güç ve pil sığasının en iyi olduğu nokta bulunabilir.

Kapı boyutlandırması da bir başka eniyileme parametresi olarak eklendiği zaman devrenin eniyilenmesi daha da karmaşılaşır. Besleme potansiyelini azaltmak, düşük eşik potansiyelli transistörler kullanmak veya transistör genişliğini azaltmak güç tüketimini azaltır fakat buna karşılık gecikmede artış olur.

Kritik yol üstündeki transistörler için yüksek besleme potansiyeli, düşük eşik potansiyeli ve geniş kanal seçilmesi ve zamanlama sınırlamalarını sağlamak; kritik olmayan yollardaki transistörler içinse düşük besleme potansiyeli, yüksek eşik potansiyeli ve küçük kanal genişliği kullanarak güç harcamasını düşürmek iyi bilinen bir güç eniyileme metodudur. Fakat ekstra serbestliğin nasıl kullanılacağı güç eniyilenmesi yönünden tasarım problemlerinden birisidir ve buna dair geçmişte çalışmalar yapılmıştır.

Bu çalışma şu andaki teknoloji için otomatik bir tasarım algoritması olması amacıyla pil sığasının ve güç kullanımının kısıtlayıcı faktör olduğu durumlarda en iyi potansiyel, eşik voltajı ve aygıt boyutunu bulmayı hedeflemektedir. Bu hedefi yakalamak için VFSR algoritması evrensel eniyileme aracı olarak kullanılmıştır. Eniyileme hedef fonksiyonu güç kullanımını ve pil sığasını aynı anda içerecek şekilde belirlenmiştir. Literatürde bilinen beş farklı devre kullanılarak güç ve pil sığasındaki kazançlar test edilmiştir.

1.8.4. Dördüncü Problem: Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları

Çoklu amaç eniyileme problemlerine bir örnek olarak seçilen bu problem dinamik voltaj ölçeklemesinde sıcaklık, enerji ve en yüksek güç eniyilenmesinin farklarını incelemektedir. Günümüzde enerji eniyilemesi ve en yüksek güç eniyilemesi mikroçip tasarımı bakımından önemli performans ölçüleridir. enerji (ortalama güç) eniyilemesi pille çalışan mobil cihazlar için önemli iken en yüksek güç tüketiminin eniyilenmesi ise yüksek sıcaklığın silikon kusurlarına sebep olduğu ve sistem masrafını (soğutma ve paketlenme) yükselttiği yüksek güç gerektiren sistemlerde önemli olmaktadır (Rabaey vd, 1996). Dinamik voltaj ölçekleme düşük güce ulaşmak için uygun olduğu için ticari birçok işlemcide uygulanmaktadır.

DVS (dinamik voltaj ölçeklenebilir) sistemlerde enerji, en yüksek güç ve sıcaklık eniyilenmeleri arasındaki farkların incelendiği problemde sistemimizin girdileri iş geliş zamanları, iş yürütme zamanları ve işlemsel yüküdür. Amacımız işlemcinin

herbir işi yerine getirirkenki işletim potansiyelinin enerji, en yüksek güç veya sıcaklık en düşük olacak şekilde belirlenmesi ve üç eniyileme arasındaki farkların belirlenmesidir.

Dinamik voltaj ölçeklenebilir işlemciler gerçek zamanlı iş gücüne (işlemsel güç) göre enerji, en yüksek güç veya sıcaklık eniyilemesi için voltaj ve frekansını adapte edebilmektedir. Mobil uygulamalarda işgücü değişimleri kayda değerdir (Flautner vd., 2001; Flautner vd., 2002). İş yürütme zamanları ise DSP (sayısal sinyal işleme) veya genel amaçlı mikroişlemci sistemleri için oldukça değişim gösterebilmektedir. Tek bir video içerisinde video pencereleri dört veya daha fazla kat değişiklik gösterebilmektedir (Bavier, 1998; Pouvelse, 2003). Bazı işler yürütülmek için daha uzun süreye gereksinim duymakta ve her saat devrinde daha fazla güç gerektiren anahtarlama olmaktadır. Anahtarlama faaliyetindeki değişimlerin nedeni girdi akışı (girdi anahtarlama vektörleri, girdi korelasyonu vs.) olabilmektedir. 16 bitlik bir çarpım devresinde beş kat anahtarlama faaliyeti değişimi rapor edilmiştir (Marculescu vd., 1995). Bu durum yürütme sırasında farklı işlevsel birimlerin aktif olmasını gerektirdiği için yapılan işin doğasına da bağlıdır. Farklı işlevsel birimler bir döngüde farklı güç harcamasıyla sonuçlanabilmektedir.

İş büyüklükleri aynı olsa bile güç harcamaları farklılık gösterebilmektedir. Çünkü işlerin yürütülmesi sırasında anahtarlama sığıları farklılık göstermektedir. Bir iş yürütüldüğü zaman farklı işlevsel birimler aktif olabilmekte ve her işlevsel birim farklı anahtarlama sığıasına sahip olabilmektedir. İşlem sırasında aynı işlevsel birim kullanılsa bile işyükünün girdi vektörleri farklı olabilir. Bu ise farklı anahtarlama faaliyetinden dolayı farklı anahtarlama sığıasına neden olmaktadır. Her iki durumda da esnek işler için dahi (katı mühlet yokken) enerji eniyilemesi en yüksek güç eniyilemesine göre farklılık göstermektedir.

İşlerin güç profilinin önceden bilindiğini varsayıyoruz. İşlevsel birimlerin anahtarlama faaliyet oranlarının en yüksek 2 olduğu gibi tutucu bir varsayım yapmaktayız.

Sıcaklık eniyilemesi dışbükey bir eniyileme problemidir ve Elipsoid Algoritması kullanılarak polinomiye zamanda çözülebilir. Şimdiye kadar bu konuda yapılan çalışmalar katı mühlet sınırlamasına sahip ve önceliğe izin veren işleri gözönüne almışlar ve anahtarlama faaliyetinin ve anahtarlama sığasının etkisini ihmal etmişlerdir. Mühlet sınırı olmaz ve anahtarlama faaliyetleri ihmal edilirse tüm işler aynı voltajda yürütüldüğü zaman enerji, güç ve sıcaklık en düşük olacaktır. Mühlet sınırlamasının veya anahtarlama faaliyetinin dahil edilmesi enerji, en yüksek güç ve sıcaklık en iyi değerlerinin farklı olması ile sonuçlanacaktır.

Bu çalışmada bazı işlerin mikroçip üzerindeki bir hafızada depolanabileceği hesaba katarak işlerin katı mühletleri olamayacağı varsayılmıştır. Fakat anahtarlama sığa değişimlerinden dolayı yürütme zamanları aynı olsa bile işlerin güç tüketimi farklı olabilmektedir.

Çalışma sıcaklığın en düşüklendiği voltaj ölçeklemesine odaklanmaktan çok sıcaklık eniyilemesinin enerji veya en yüksek güç eniyilemesinden farklı olduğunu ortaya koymaktadır. Farklı amaç fonksiyonlarının kullanıldığı durumlardaki mümkün olan hatalar (örneğin amaç fonksiyonunun güç olduğu durumda sıcaklıktaki düşüş) ortaya konulmaktadır. Sıcaklık eniyilemesi için verimli zamanlama ilerideki bir araştırmaya bırakıldı. Sıcaklık Fourier kanunu temel alınarak Monte Carlo Benzetimi yoluyla belirlenmiştir. Kayan pencerelerde herbir pencerenin son sıcaklığını bir sonraki pencere ilk sıcaklık olarak devralmıştır. Böylelikle kümülatif olarak değişen sıcaklığın uzun sürelerdeki değişimi üç farklı eniyileme hedef fonksiyonu için gözlenmiştir. Bu yöntem kullanılarak geliştirilen benzetimler üzerinde yapılan eniyilemede hedef fonksiyonu olarak her pencere için en yüksek sıcaklık ve son sıcaklığın toplamının sadece en yüksek sıcaklığın alındığı duruma göre farkı incelenmiştir. Ayrıca çiplerin ısınma ve soğuma katsayılarının eniyilemeler üzerindeki etkisi de incelenmiştir.

2. KAYNAK ÖZETLERİ

2.1. Elektromanyetik Kaynak Tanıma

Daha önce elektronik aygıtların elektromanyetik yayımlarına dayanarak tespit edilmesine dayanan çalışmalar vardır (Dudczyk vd., 2004; D'Amore vd., 1998; Aunchaleevarapan vd., 2000; Shieh vd., 2002). Tüm bu çalışmalarda ışınlam yapan kaynaklar oldukça basittir. Arabalardan yayılan ışıma ise oldukça karmaşık olabilmektedir çünkü bir araba birçok elektronik bileşene sahiptir ve ışıma tüm bu bileşen ve cihazların ve araba geometrisinin bir fonksiyonu olarak değişim gösterecektir.

Arabaların elektromanyetik tanınması konusunda daha önce yapılmış herhangi bir çalışma yoktur. Yapılan tek çalışma bu tez çalışmasının bir parçası olarak iki konferansta sunulmuştur (Göksu v.d., 2004; Göksu, 2005-e).

2.2. FDTD Veri Dışdeğerlemesi

FDTD türü sinyallerde süre kısaltımı için zaman boyutu sinyallerinde dışdeğerleyici yardımıyla süresinin kısaltılması konusunda literatürde bulunan tek çalışma FIR cinsi bir sinir ağının doğrusal ARMA dışdeğerleyicisiyle karşılaştırması çalışmasıdır (Wu, C., 1996). Literatürdeki ikinci çalışma ise bu tez çalışmasının bir parçası olarak MLP ve MPM dışdeğerleyicilerini karşılaştıran ve yapay sinir ağı eğitim konularını irdeleyen iki yayın vardır (Göksu ve Wunsch, 2003-c; Göksu vd., 2003-a).

Çalışmada kullanılan MLP ileribeslemeli bir yapay sinir ağıdır. Bu tip yapay sinir ağları sistem tanımlama ve zaman serisi tahmini açısından oldukça başarılıdır (Narendra v.d., 1990).

Kesintiye uğramış gürültülü bir sinyale ait karakteristik parametrelerin çıkarılmasına dair de literatürde çalışmalar yapılmıştır. Bunların içerisinde bir grup çalışma Prony metodundan çıkarılan metotlardır ve bunların orijini birkaç yüzyıl öncesine

dayanmaktadır. Bu süreç kesilmiş özgün sinyale uyan belirlenimci üstel bir model aramaya yöneliktir. Model sönümlenen sinüzoidlerden oluşur ve bunların herbiri bir frekans ve sönümlenme faktörüyle belirlenir. Bu parametreleri çıkarmak için farklı yollar uygulanabilir fakat diğerleriyle kıyaslanınca Matris Pencil metodu gürültüye karşı en kararlı olanıdır (Hua, Y. vd., 1990)

Örnekleme hızının adaptasyonunda ortak bilgiyi ve uygun pencere genişliğinin belirlenmesinde yanlış en yakın komşuluk metodunu öneren literatürde bir çalışma vardır (Ababarnel, H. D. I., 1993). Bu tez çalışmasında ise bir değişiklik yapılarak örnekleme hızına ek olarak pencere genişliğinin belirlenmesinde de ortalama ortak bilginin kullanılması önerilmiştir ve çalışmanın bu kısmı bir konferans bildirisi olarak yayınlanmıştır (Göksu ve Wunsch, 2003-b).

2.3. Düşük Güç Tasarımı

Düşük güç tasarımında daha önce Nguyen D. (2003) ve Pant P. v.d. (2001) eşik potansiyeli belirleme ve ebatlandırma çalışmaları yapmışlardır. Nyugen'in çalışmasında kombinasyonel devrelerde doğrusal programlama kullanılırken Pant'in çalışmasında güç eniyilemesi için ikili arama kullanılmıştır.

Hung (2004) birden çok V_{dd} , birden çok V_{th} , kapı ebatlandırma ve kuvvet istifi yöntemlerini anda bir genetik algoritma yardımıyla uygulamıştır. Stojanovic (2002) ise çalışmasında kapı ebatlandırma ve besleme potansiyeli eniyilemesi yapmıştır.

Çift besleme, çift eşik ve aygıt ebatlandırmanın etkinliği Augsburger (2002) tarafından gösterilmiştir. Dolayısıyla tezin bu kısmı V_{dd} , V_{th} ve ebatlandırarak güç ve pil boşalma süresini aynı anda eniyilemek açısından ilktir. Bu konudaki tek yayın bu tez çalışması sırasında yayınlanmıştır (Manzak ve Göksu, 2005).

2.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları

Son yıllarda dinamik voltaj işlemcilerde voltaj zamanlaması yaygın olarak incelenmiştir. İşler hakkında önceden tam bilgi sahibi olunduğu durumlarda enerji eniyilemesi için voltaj zamanlaması çevrim dışı yapılabilir (Flautner vd., 2001; Flautner vd., 2002; Marculescu vd., 1995). Gelecekteki işler hakkında bilgi mevcut olmadığı veya işgücündeki değişikliklerin kayda değer olduğu durumlarda voltaj zamanlama dinamik olarak yani yürütme süresinde yapılmalıdır (Marculescu vd., 1995; Bavier vd., 1998; Pouwelse vd., 2003; Gutnik vd., 1997; Yao vd., 1995; Ishihara vd., 1998; Hong vd., 1998; Quan vd., 2001; Manzak vd., 2001; Pouwelse vd., 2001; Weiser vd., 1994). Gelen iş parametreleri hakkındaki tahminler ne kadar iyiye enerji kazancı da o ölçüde daha iyi olmaktadır.

İşler arasında bağımlılığın olmadığı durumlarda çevrim dışı zamanlama (IBM PowerPC) de ele alınmış ve tamsayı doğrusal programlama (ILP) kullanılarak çözülmüştür. Zorluğu $O(n \log^2 n)$ olan çevrimiçi bir algoritma n öncelikli iş için (Intel Xscale) de önerilmiştir. Algoritma kritik işleri en yüksek hızda zamanlamakta ve daha sonra geri kalan işler için bir alt problem oluşturmakta ve bunu yinelemeli olarak çözmektedir. Öncelikli olmayan iş zamanlaması için çevrim dışı keşisel bir yol (Flautner vd. 2001)'de ortaya konmuştur. Daha yeni olarak işler için zamanlama parametrelerinin önceden bilindiği durumlarda voltaj zamanlaması için $O(n^3)$ karmaşıklığında bir algoritma (Flautner vd., 2002) tarafından önerilmiştir. Algoritma kritik aralıkları belirleyerek ve bunlara karşılık gelen hızları hesaplayarak bir voltaj zamanlaması oluşturmaktadır.


Düşük güç için voltaj ölçeklemesi üzerine bir çok araştırma bulunmasına rağmen düşük sıcaklık için voltaj ölçeklemesi yeni bir konudur. Geçmişte düşük güç tasarımının sıcaklığa etkisi ihmal edilmiş veya güç endüştüklendiğinde sıcaklığın da düşeceği varsayılmıştır. Araştırmaların bir kısmı sıcaklık düşüşü için en yüksek güç üzerine odaklanmıştır. (Bansal, 2004) dinamik voltaj zamanlamasında güç eniyilemesinin sıcaklık eniyilemesinden farklı olacağını ortaya koymuştur.

3. MATERYAL VE METOT

3.1. Materyal

3.1.1. Elektromanyetik Kaynak Ölçümleri

Otomobillerin yayımları frekans bantlarının belirlenmesi amacıyla spektrum analizörüne bağlanmış bikonik anten yardımıyla ölçülmüştür. Şekil 3.1 Missouri Üniversitesi Otomobil EMC Laboratuvarındaki iki farklı arabanın yaydığı elektromanyetik yayım ile çevre gürültüsünü karşılaştırmaktadır. Ölçüm için seçilen çözünürlük bant genişliği 100kHz'dir. Şekil yayım spektrumunun arabadan arabaya farklılık gösterdiğini ortaya koymaktadır.




Şekil 3.1. Farklı otomobillerden yayılım spektrumları

Sınıflandırma amacıyla yayımlar General Motors Cadillac binek otomobil, Ford Windstar minivan ve Toyota Tundra pikap olmak üzere üç farklı araçtan bikonik antenin dijital osiloskopa bağlanması yoluyla ölçülmüştür. Zaman boyutundaki sinyaller 500E+06 örnek/saniye örnekleme frekansı ile 100mikrosaniye'lik pencereler şeklinde farklı gün ve zamanlarda ölçülmüş ve kaydedilmiştir. Ölçümlerin alındığı laboratuvar ekranlanmadığı için çevre gürültüsü oldukça fazladır. Bu da deneyi gerçeğe oldukça yakın kılmaktadır. Araba yayımında periyodik olarak rastlanan kıvılcımı içeren ve içermeyen sinyaller ve otomobilin olmadığı çevre gürültüsü sinyalleri farklı gruplarda farklı günler boyunca sınıflandırma amacıyla kaydedilmiştir. Daha sonra sırasıyla STFT ve WP metotları kullanılarak sinyaller dönüştürüldükten sonra parametrisasyon işlemine tabi tutularak yapay sinir ağıları yardımıyla sınıflandırılmışlardır. Otomobil yayımlarında periyodik fakat ender olarak görülen kıvılcımın alınan pencerelerde olup olmasının etkisi incelenmiştir.



(a)




(b)


Şekil 3.2. (a) YC serisi Yugoslav fünye (b) Zamanlayıcının ölçülen yayımı dBm.

Yaklaşımımızın gömülü mühimmatın tespitine de genişletilebilirliğini göstermek için bir elektronik patlayıcı zamanlayıcısından yayılan elektromanyetik yayımlar da incelendi. Elektronik zamanlayıcı (Şekil 3.5.(a)) Balkanlarda mayın taramaları sırasında aktif bir mühimmattan çıkarılmış YC serisi bir Yugoslav fünyesidir (YCE-T). Zamanlayıcı, düşük frekanslı ticari sayısal elektronik parçalardan yapılmıştır. Sofistike olmamasına rağmen cihazı belirleyebilecek ölçülebilir ve düşük frekanslı yayımlar bekleniyordu. Zamanlayıcıdan yayılan yayımlar UMR yarı yansız


odasında Rohde and Schwarz FSEB spektrum analizör ve yakın-alan manyetik probuyla ölçülmüştür. Ölçülen yayımlar Şekil 3.5.(b)'de görülebilir. Yayımlar zamanlama saat sinyalinin ve baskı devrenin bir fonksiyonudur. Bu sinyalin özelliklerini kullanarak özel süzgeçler yapılabilir ve bir anten dizisi yardımıyla cihazın yeri çok rahat belirlenebilir. Sayısal sinyaller hızlandıkça ve devreler daha karmaşıklaştıkça bu sinyalleri bulmak ve yerini belirlemek daha da kolaylaşmaktadır. Cihaz tarafından radyo haberleşme devrelerinin kullanılıyor olması da bulma ve yerini tespit etme kabiliyetini artırmaktadır.



(a)



(b)



(c)

Şekil 3.3. (a) 1 nolu araçtan yayılan 1 boyutlu sinyal ve 2 boyutlu spektrogramı (b) 2 nolu araçtan yayılan 1 boyutlu sinyal ve 2 boyutlu spektrogramı (c) 1 boyutlu çevre gürültü sinyali ve 2 boyutlu spektrogramı.

Otomobillerden ölçülen yayımların STFT ve WP dönüşümlerinden sonra dönüştürüldükleri parametreler aşağıdaki bölümde anlatılmaktadır. STFT ve WP metotlarının ayrıntıları Metot bölümünün alt başlıkları olarak bulunabilir.

3.1.1.1. Parametreler

Yayımların STFT ile elde edilen spektrogramları sınıflandırma için kullanılacak olan yapay sinir ağına girilemeyecek kadar büyük boyuta sahiptir. Dolayısıyla bu sayıyı düşürebilmek için STFT sonuçlarından beş grup parametre çıkarılmıştır. Herbir parametre farklı özellikleri yansıtmaktadır. Parametreler DC ve 250MHz'e kadar alınan 30 adet 8.33 MHz'lik bantlar için olmak üzere $5 \times 31 = 155$ parametreden oluşmaktadır.

1. Bir frekans bandındaki en yüksek spektral genlik bölü ortalama genlik. Bu parametre darbelerle saf tona sahip sinyaller arasındaki farkı bildirir ve darbenin genişliği hakkında biraz bilgi verir. Uzun süreli saf bir ton için bu

değer 1'e yakındır. Kısa süreli darbe içinse daha büyük değerdedir. Geniş bantlı bir darbe ise birden çok frekans bandında yüksek değerler verecektir.

2. Bir frekans bandındaki ortalama genlik bölü tüm frekans bantları boyunca ortalama genlik. Bu parametre bir frekans bandındaki bağıl faaliyeti belirler. Uzun süreli saf ton sinyallere veya birçok kısa süreli darbeye sahip bantlarda yüksek değer verir. Kısa süreli bir darbe veya gürültü için bu değer düşüktür.
3. Bir frekans bandındaki genliğin standart sapması. Uzun süreli saf ton sinyaller bu parametrede düşük değere sahiptir. Birçok kısa süreli darbeler büyük değer verecektir. Benzer şekilde güçlü geniş bantlı bir darbe birçok frekans bandında büyük değere sahip olacaktır. Bu parametre yüksek genlikli rastgele gürültüde de yüksek değer verebilir.
4. Bir frekans bandındaki en yüksek spektral genliğin 3dB yakınındaki nokta sayısı. Bu parametre keskin ve hızlı darbeleri diğer sinyallerden ayırt eder. Hızlı bir darbe için genelde düşük değere sahiptir, saf tona sahip sinyaller veya rastgele gürültü için daha büyük değere sahiptir. Yavaş bir darbe içinse ortada bir değer alır.
5. Bir frekans bandındaki darbe sayısı. Bu parametre arabadaki kıvılcımı diğer darbelerden ayırmak için kullanılabilir. Bir darbenin, genliğin en yüksek genliğe 3dB yaklaşmasından ortalama genliğin altına düşmesine kadar tanımlanır. Uzun süreli saf ton bir sinyal düşük değer verecektir. Tek güçlü bir darbe 1 değeri verecektir. Periyodik sayısal faaliyet ortada bir değer verirken rastgele gürültü tek başına yüksek bir değer verecektir.

Yukarıdaki STFT dönüşümünden sonra elde edilen beş parametreye ek olarak WP Ayırışımıyla elde edilen alt imgelerin enerjileri de ayrı bir parametre seti oluşturmaktadır. Üç seviyeye kadar yapılan Ayırıştırmada 15 alt imge ve dolayısıyla da 15 enerji bileşeni elde edilmektedir.

Yapay sinir ağlarıyla yapılan sınıflandırma denemelerinden önce girdi vektörünün boyutunun büyük olduğu durumlarda boyut küçültmek için PCA yöntemine başvurulmuştur. PCA sonunda elde edilen nitelik vektörlerinde veri setinde toplam

değişime %2'den fazla katkı sağlayan bileşenler korunmuş diğerleri atılmıştır. PCA hakkında detaylı bilgi Metot kısmında ayrılmış ilgili bölüme bakılabilir.

3.1.2. FDTD EMC Simülasyonları ve Dışdeğerleme

FDTD bir elektromanyetik sistemin dürtü cevabının zaman boyutunda simüle edildiği çok kullanılan bir simülasyon metodudur. Örneğin cihaz kasalarının ekranlama özellikleri dürtü cevaplarıyla simüle edilebilir. Kusursuz bir dürtü frekans boyutunda düz beyaz gürültüye eşdeğerdir ve kasanın ekranlama etkisi farklı frekanslara uyguladığı zayıflatmanın derecesine bağlıdır. Dolayısıyla metot, kasanın içinde bir dürtü oluşturmak ve dışarıda zayıflamış sinyali ölçmekle eşdeğerdir.

Eğer test edilmek istenen sistemin geometrisi tamamen bilinirse dürtünün sistemin her yerine yayılışı FDTD yöntemiyle simüle edilebilir. Bu metotta kesikleştirilmiş Maxwell denklemleri yardımıyla içiçe iki ızgara üzerinde elektrik ve manyetik alanlar birbiri ardına hesaplanarak tüm geometri boyunca sönümleme belli bir eşiğin altına ininceye dek yayılır. Test altındaki sistem büyüdükçe simülasyon işlemsel süre bakımından gittikçe güç yetmez hale gelir. Mesela bir kasanın ekranlama özelliğinin benzetimi haftalar boyu sürebilir.

Bu tür simülasyonların işlemsel masrafının azaltılması daha fazla simülasyona imkan tanıyarak daha yaratıcı ve daha iyi tasarımlara imkan tanıyabilir. Çoğu zaman boyutu simülasyonlarının aynı prensiple çalıştığı hesaba katılırsa yukarıda bahsedilen türden bir iyileştirme tüm grubun iyileştirilmesi etkisi yapacaktır.


FDTD ve diğer elektromanyetik benzetimler hakkında detaylı bilgiyi Metot kısmındaki alt başlıklara bırakıp problemimize dönelim. FDTD'nin sinyallerine uygulanacak bir dışdeğerleyicinin önce üstdüğümlenmiş sönümlenen sinüzoidlerden oluşan yapay bir sinyalde test edilerek başlanmasını uygun gördük. Çünkü anlaşılacağı üzere gerçek FDTD sinyalleri bu tür sönümlenen sinüzoidleri andıracaktır.

Bu tür yapay sinyaller üzerinde önce ARMA yaklaşımıyla çalışan kısa vadeli bir dışdeğerleyici olan MLP ile uzun vadeli bir dışdeğerleyici olan MPM metotlarının öngörü başarısı karşılaştırıldı. ARMA, MLP ve MPM ile ilgili bilgiler Metot bölümünde ilgili alt bölümlerde bulunabilir.

MLP cinsi dışdeğerleyici kayan pencere şeklinde yerel öngörüler yoluyla çalıştığı için pencere büyüklüğünün belirlenmesi ve bunun farklı örneklenmiş sinyallerde standart olabilmesi için örnekleme hızıyla bağıntılı hale getirilmesi için ortalama ortak bilgi (average mutual information) kullanılarak eniyileme yapıldı. Ortalama ortak bilginin pencere büyüklüğü ve örnekleme frekansı eksenleri arasında çizilen yüzey üzerindeki ilk en düşük noktanın en iyi değer olarak alınabileceği öngörüldü. Ortalama ortak bilgi ve diğer entropi istatistiği konuları hakkında detaylı bilgi Metot bölümünün ilgili alt bölümlerinde bulunabilir.

İlk defa denenen entropi istatistiğine dayanan ve dışdeğerleyicinin farklı sinyallere uyarlanabilir olabilmesi için yapılan bu eniyileme metodu, doğruluğunun test edilmesi açısından saf sinüs dalgası üzerinde Nyquist frekansının test edilmesi açısından uygulandı.

Sönümlenen üstdüşümlenmiş sinüzoidlerden oluşturulan yapay sinyalde her ne kadar MLP daha başarılı olsa da gürültü içeren gerçek FDTD sinyallerinde kayan pencerelerde oluşan hatanın üstüste eklenmesiyle büyüyeceği gerçeği ile paralel olarak gerçek FDTD sinyallerinde dışdeğerlemede doğrudan uzun vadeli MPM'in başarılı olduğu görülmüştür. Dolayısıyla bu yöntemin de uyarlanabilir olabilmesi için pencil parametresi ve kutup sayısı değişkenleri dışdeğerleme başarısı masraf fonksiyonu olarak alınarak basit bir arama metoduyla eniyilendi. Şekil 3.4 de gerçek FDTD sinyalinin elde edilmesi için benzetimlenen test altındaki kutu şeklindeki geometrinin gerçek resmi görülmektedir.



Şekil 3.4 FDTD ile benzetimi yapılan geometri

3.1.3. Düşük Güç Tasarımı

3.1.3.1. Tümdevre Güç Tüketimi

CMOS sayısal devrelerdeki toplam güç tüketimi şu denklemle ifade edilebilir:

$$P = P_{dyn} + P_{leakage} + P_{sc} , \quad (3.4)$$

Birinci terim parazitik sığanın saat frekansında yüklenip boşalmasından kaynaklanan dinamik güç tüketimidir. İkinci terim ise eşik altı kayıp akımdan kaynaklanan kayıp güç tüketimidir. Sonuncu terim kısa devre akımından kaynaklanan kısa devre güç kaybıdır. Kısa devre akımı mantıksal anahtarlama sırasında nmos ve pmos transistörlerin kısa devre konumda olduğu ve güç potansiyelinden toprağa doğrudan yol bulunduğu zaman kısa süre için akar. Dolayısıyla kısa devre gücü toplam güç tüketiminin %10'unu oluşturmaktadır ve bu çalışmada ihmal edilmektedir.

Günümüz teknolojisinde dinamik güç tüketimi baskındır ve şu şekilde ifade edilebilir:

$$P_{\text{dyn}} = \alpha C_L V_{\text{dd}}^2 f \quad (3.5)$$

Burada C_L yük sığası, α anahtarlama faaliyeti, V_{dd} besleme potansiyeli ve f saat frekansdır. Yük sığası parazitik sığaların bir kombinasyonudur ve besleme gücünün bir fonksiyonudur. αC_L çarpımı anahtarlanmış sığaya karşılık gelir. Tüm çipin dinamik gücünü hesaplamak için 1 saniyedeki toplam anahtarlanmış sığa V_{dd}^2 ile çarpılır. Her bloğun anahtarlama faaliyeti değişiktir ve girdiye bağlıdır. Anahtarlama faaliyetini kestirmek için istatistiksel metotlar geniş ölçüde kullanılmıştır.

Kayıp güç tüketimi büyük ölçüde eşik altı kayıp akıma bağlıdır ve bu akım işleme teknolojisiyle değişmektedir:

$$I_{\text{leak}} = k\mu C_{\text{ox}} \frac{W}{L} V_T^2 e^{\frac{V_{\text{gs}} - V_{\text{th}}}{nV_T}} (1 - e^{-\frac{V_{\text{ds}}}{V_T}}) \quad (3.6)$$

μ mobilite, C_{ox} birim alandaki kapı oksit sığası, W kanal genişliği, L kanal uzunluğu, V_T termal voltaj, V_{th} eşik potansiyeli, n eşik altı sallanma katsayısı ve k teknolojiye dayalı bir sabittir. Burada V_{th} ve sıcaklık kayıp akıma üstel olarak bağlıyken W doğrusal olarak bağlıdır.

Devre gecikmesi besleme ve eşik potansiyelline aşağıdaki denklemle bağlıdır:

$$T = k' C_L \frac{V_{\text{dd}}}{(V_{\text{dd}} - V_t)^\alpha} \quad (3.7)$$

Gücü endüştüklemek pil ömrünün enyükselendiği anlamına gelmez. Peukert denklemi (Linden, 1995) pil sığasıyla boşalma akımı I arasındaki bağıntıyı şöyle verir:

$$C = T_d I^\alpha \quad (3.8)$$

burada T_d boşalma süresi ve α ise tipik olarak [1.2, 1.4] aralığında olan Peukert sabitidir.

3.1.3.2. Eniyileme Parametreleri

Eniyileme metodumuzda P toplam güç ve T_d pil boşalma süresi olmak üzere P/T_d 'yi endüştüklemeye çalışmaktayız. V_{dd} , V_{th} ve kapı büyüklüğünün optimum kombinasyonunu bulmaya çalışıyoruz. Parametrelerin etkinliği genellikle dinamik kayıp akım oranına ve devre topolojisine bağlıdır. Ekstra serbestlik bulunduğu zaman gücü düşürmek için kapı büyüklüğü küçültülebilir. Herbir kapı büyüklüğü küçüldükçe sürücü kapıların yük sığası da düşer ve kapı genişliklerinin daha da küçültülmesi mümkün olur.

Besleme potansiyelini düşürmek dinamik gücü oldukça azaltır çünkü besleme potansiyeli ile güç arasında karesel bir ilişki söz konusudur. Kayıp akım yine doğrusal olarak düşer. Yüksek V_{th} 'ye sahip cihazlar kullanmak kayıp akımı üstel olarak azaltır. Her iki metot beraberinde gecikmede bir artış getirir. Tüm çip için dinamik ve kayıp güçler arasındaki oran hangi metodun daha etkili olduğunu belirler.

Algoritmamız gücü minimize etmek ve pil boşalma süresini enyüksellemek için en iyi V_{dd} , V_{th} ve kapı ebatı kombinasyonunu bulmaya çalışmaktadır. Bu işlemler yüksek karmaşıklık gerektirdiği için VFSSR algoritması kullanılmıştır. VFSSR hakkında detaylı bilgi için Metot bölümünün ilgili alt bölümlerine bakılabilir.

3.1.3.3. Masraf Fonksiyonu

Stratejimiz her kritik olmayan yol için toplam P/T_d değerinin eniyilenmesi yoluyla üç katlı güç azaltımı sağlamaktadır. P/T_d kritik olmayan yol üzerindeki her elemanın W_n , V_{th} ve T değerlerine bağlı olarak değişmektedir. Dolayısıyla N devredeki toplam eleman sayısı olmak üzere bizim eniyilememiz $3N$ boyutlu uzayda en küçük noktayı aramaya karşılık gelmektedir.

Masraf fonksiyonunun hesaplanması aşağıdaki prosedürden oluşur:

- Devre üzerindeki kritik yolu bul
- Toplam gecikmeyi hesapla
- Tüm diğer yollar için:
 - o T_i , W_{ni} ve V_{thi} 'yi yoldaki her i devre elemanını kapsayacak şekilde serbest parametreler olarak tanımla
 - o ΣT_i =mobilité koşulunu gözet
 - o V_{ddi} 'yi sınır denkleminde hesapla
 - o V_{ddi} sınır değerlerini uygula
- Tüm devre için kümülatif masrafı P/T_d hesapla

3.1.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En Yüksek Güç Eniyileme Farkları

Dinamik voltaj örnekleme enerji için yapıldığında en yüksek güç'ün ve sıcaklığın en iyi değerden ne kadar uzaklaştığı, en yüksek güç için eniyileme yapıldığında ise enerji ve sıcaklığın en iyi değerden ne kadar uzaklaştığı bu bölümde incelenmiştir.

3.1.4.1. Formülizasyon

n işten oluşan bir set ($iş_1, iş_2, \dots, iş_n$) ve T_{toplam} toplam işlem süresi için amacımız işleri T_{toplam} zamanında 1) enerji tüketimi en az ve 2) en yüksek güç tüketimi en az olacak şekilde zamanlamak.

İşlerin zamanlanması her bir işin yürütülmesi sırasında işlemcinin besleme voltajının belirlenmesine eşdeğerdir.

CMOS kapısının yayılım gecikmesi şu formülle ifade edilebilir:

$$T \approx V_{dd} / (V_{dd} - V_t)^2 \quad (3.10)$$

V_t eşik voltajıdır. Benzer bir formül kritik yol gecikmesini hesaplamak için kullanılabilir:

$$\tau_{crit} = k V_{dd} / (V_{dd} - V_t)^2 \quad (3.11)$$

Burada k kritik yoldaki toplam yük sığasına ve cihaz parametrelerine bağlıdır.

Herbir iş verilen T_{toplam} zamanında bir kez var olur. T_i iş i 'nin yürütülme zamanı ise ve n iş sayısı ise, T_{toplam}

$$T_{toplam} > \sum T_i = \sum s_i \tau_i = k \sum s_i V_i / (V_i - V_t)^2 \quad (3.12)$$

Burada τ_i iş i 'nin bir kontrol döngüsündeki yürütme zamanı, s_i iş i 'nin yürütülmesi için gereken kontrol döngülerinin sayısı ve V_i iş i yürütülürken besleme potansiyelidir.

3.1.4.1.1. Enerji Eniyilemesi İçin Formülasyon

İş i 'nin enerjisi şu şekilde verilebilir

$$E_i = C_{swi} V_i^2 s_i \quad (3.12)$$

C_{swi} : iş i için ortalama anahtarlama sığasıdır. C_{swi} yürütülen programın tipine bağlıdır ve simülasyon veya olasılıksal ve istatistiksel teknikler kullanılarak bulunabilir.

Anahtarlama sığası $C_{swi} = \alpha_i C_{Li}$ şeklinde yazılabilir, burada α_i toplam sığa C_{Li} için anahtarlama faaliyetidir. İş aynı işlevsel birim kullanılarak yürütülürse girdi vektöründeki değişimler α_i 'nin farklı olmasına yol açar. Benzer şekilde işler farklı işlevsel birimler kullanılarak yürütülürse işlevsel bloklar farklı α_i 'ye sahip olacaktır. Toplam enerji tüketimi böylece şu şekildedir:

$$E_{total} = \sum s_i C_{swi} V_i^2 \quad (3.13)$$

Hedefimiz $T_{\text{toplaml}} = \text{sabit zaman sınırlaması altında } E_{\text{toplaml}}$ 'ı endüştüklemektir. Lagrange çarpan metodu kullanarak E_{toplaml} aşğıdaki şart sağlandığında en düşük olduğı gösterilebilir

$$C_{\text{swl}} V_1 (V_1 - V_t)^3 / (V_1 + V_t) = \dots = C_{\text{swn}} V_n (V_n - V_t)^3 / (V_n + V_t) \quad (3.14)$$

3.1.4.1.2 En yüksek Güç Eniyilemesi

İş i'nin harcadığı güç

$$P_i = C_{\text{swi}} V_i^2 f_i \quad (3.15)$$

tür. Burada $f_i (=1/\tau_i)$ iş i için saat frekansdır. Herbir iş için saat frekansı $f_i = 1/\tau_i \approx (V_i - V_t)^2 / V_i$ ile belirlendiğı için iş i için güç tüketimi,

$$P_i = k C_{\text{swi}} V_i (V_i - V_t)^2. \quad (3.16)$$

P_{peak} iş setleri için en yüksek güç tüketimi olduğunu varsayalım. P_{peak} en yüksek güç tüketimidir.

$$P_{\text{peak}} = \max \{P_i\} \quad (3.17)$$

Bu durumda amacımız P_{peak} en düşük olacak şekilde iş voltajlarının belirlenmesidir. P_{peak} 'in en düşük olduğı durum $P_1 = P_2 = \dots = P_n$ durumudur. Bu da şunu gerektirir:

$$C_{\text{swl}} V_1 (V_1 - V_t)^2 = \dots = C_{\text{swn}} V_n (V_n - V_t)^2 \quad (3.18)$$

α_i herbir iş için farklıdır. Bu farklılıklar enerji, en yüksek güç ve sıcaklık eniyilemelerindeki farklılığın sebebidir.

İşlerin anahtarlama sığaları aynı olduğu zaman enerji, zamandaki esneklik tamamen kullanıldığı ve işlerin voltajları aynı olduğu zaman en düşüktür. Bu aynı zamanda en yüksek gücün de en düşük olduğu durumdur. Malesef işlerin anahtarlama sığaları farklıdır ve dolayısıyla en düşük enerji, en düşük en yüksek-güç ve en düşük sıcaklık çözümleri farklıdır.

Sıcaklık Fourier yasasında göre modellenir:

$$T' = aP - b(T - T_0) \quad (3.19)$$

T' sıcaklığın değişim hızı, P anlık güç, T mikroçipin anlık sıcaklığı ve T_0 çevre sıcaklığıdır. a ve b mikroçipin ısınma ve soğuma hızını tanımlayan sıcaklık hassasiyetleridir.

Dinamik voltaj ölçeklemesi için i için gücün sabit olduğunu varsaymaktayız. Bu durumda sıcaklık formülü şu şekli alır:

$$T' = a C_{swi} V_i^2 f_i - b (T - T_0) \quad (3.20)$$

3.2. Metotlar

3.2.1. Entropi İstatistiği

FDTD Benzetimlerinde dışdeğerleme probleminde pencere boyutunun ve örnekleme frekansının eniyilemesinde kullanılan entropi istatistiğine göz atmak gerekmektedir. Entropinin kökeni Ludwig Boltzmann'a (1877) dayanmaktadır ve bilgi teorisinde Claude Shannon (1948) tarafından olasılıksal bir yorum kazanmıştır. Henri Theil bilgi teorisinin ekonomiye uygulamalarını geliştirmiştir ve bunları iki eserde toplamıştır: Economics and Information Theory (1967) ve Statistical Decomposition Analysis (1972).

3.2.1.1. Entropi denklemi

Entropi denklemi bir olasılık dağılımındaki beklenen bilgi içeriğini veya belirsizliği ifade eder. E_i bir olayı ve p_i E_i 'nin olma olasılığını ifade etsin ve n adet olay $E_1, \dots, E_n$ ve olasılıkları $p_1, \dots, p_n$ toplamı 1 olsun. Daha az olasılığa sahip olaylar daha fazla bilgi taşıdığı için (en az beklendikleri için) bilginin ölçüsü $h(p_i)$ 'nin azalan bir fonksiyonu olacaktır. Shannon (1948) $h(p_i)$ fonksiyonunu ifade etmek için logaritmik bir fonksiyon kullandı:

$$h(p_i) = \log_2 \left(\frac{1}{p_i} \right) \quad (3.21)$$

p_i 0'dan 1'e kadar değişirken bu fonksiyon sonsuzdan 0'a doğru değişir. Bu fonksiyon bir olayın olma olasılığı azaldıkça bu olayın olduğunu belirten bir mesajın taşıdığı bilginin de artacağını simgeler. Burada bilgi logaritmanın tabanı olarak 2 kullanıldığı için bitlerle temsil edilirken doğal logaritma kullanılarak 'nit'lerle de temsil edilebilir.

n tane bilgi değeri olan $h(p_i)$ 'den yola çıkarak bir olasılık dağılımındaki beklenen bilgi içeriği, yani entropi, bilgi değerleri olan $h(p_i)$ 'yi karşılık gelen olasılıklarıyla ağırlıklandırarak:

$$H = \sum_{i=1}^n p_i \log_2 \left(\frac{1}{p_i} \right) \quad (3.22)$$

şeklinde ifade edilebilir. Burada H bit olarak entropi'yi göstermektedir.

Gelenek olarak (Theil 1972) şu tanım yapılır:

$$\text{eğer } p_i = 0 \quad \text{ise} \quad p_i \log_2 \left(\frac{1}{p_i} \right) = 0 \quad (3.23)$$

Bu tanım eşitliğin solundaki terimin p_i sıfıra yaklaşırkenki limit değeridir. (Theil 1972: 5).

Entropi değeri olan H negatif olamaz. Mümkün olan en küçük entropi değeri olan sıfır, tek bir olayın birim olasılığa sahip olduğu durumdur:

$$H_{\min} = 1 \cdot \log_2 \left(\frac{1}{1} \right) = 0 \quad (3.24)$$

Tüm durumlar eşit olasılığa sahip olduğu zaman ($p_i = \frac{1}{n}$), entropi değeri en yüksektir:

$$H_{\max} = \sum_{i=1}^n \frac{1}{n} \log_2(n) = n \frac{1}{n} \log_2(n) = \log_2(n) \quad (3.25)$$

(ispatı Theil 1972’de verilmektedir). Dolayısıyla en yüksek entropi n ’ye bağlı olarak artar.

Entropi belirsizliğin bir ölçüsü olarak da yorumlanabilir. Bir bilginin açıklanmasından önceki belirsizlik ne kadar fazlaysa mesajın taşıdığı bilginin ortalama o kadar daha fazla bilgi taşıdığı söylenebilir. Theil (1972) bu bağlamdaki entropiyi gerçek değerli rastgele değişkenlerdeki varyans’a benzetmektedir. Aradaki en önemli fark entropinin nicel yerine nitel değerlere uygulanır olması ve dolayısıyla mümkün olayların olasılıklarına bağlı olmasıdır.

Bir mesaj iletildiği zaman önceki olasılıklar olan p_i sonraki olasılıklar olan q_i ‘e dönüştüğü zaman (Theil 1972) bilgi için aşağıdaki ifadeyi ortaya koymuştur:

$$I(q \mid p) = \sum_{i=1}^n q_i \log_2 \left(\frac{q_i}{p_i} \right) \quad (3.26)$$

bu ifade önceki olasılıklar sonraki olasılıklara eşit olduğunda sıfırdır (bilgi yok) ve diğer durumlarda pozitifdir.

3.2.1.2. Entropi Ayrıştırma teorisi

Entropi istatistiğinin en güçlü ve çekici özelliği kümeleme ve ayrıştırma problemlerinin ele alınış biçimindendir. (Theil 1972; Zajdenweber 1972). Bu ise entropi formülünün toplanabilirliğinden ileri gelmektedir.

E_i nin bir olayı temsil ettiğini ve böylece n tane olayın $E_1, \dots, E_n$ varlığını $p_1, \dots, p_n$ olasılıklarıyla varsayalım. Tüm olayların daha az sayıda olay kümeleri şeklinde $S_1, \dots, S_G$ her olay tek bir kümeye S_g düşecek şekilde $g=1, \dots, G$ kümelenebildiğini varsayalım. S_g altındaki olayın olma olasılığı şu toplamla bulunur:

$$P_g = \sum_{i \in S_g} p_i \quad (3.27)$$

Olay kümeleri seviyesinde entropi:

$$H_0 = \sum_{g=1}^G P_g \log_2 \left(\frac{1}{P_g} \right) \quad (3.28)$$

H_0 gruplar arası entropidir. Entropi Ayrıştırma teoremi kümeler seviyesindeki gruplar arası entropi H_0 ile olaylar seviyesindeki aşağıda verilen entropi H arasındaki bağıntıyı verir. Entropi H şu şekilde yazılır:

$$H = \sum_{i=1}^n p_i \log_2 \left(\frac{1}{p_i} \right) = \sum_{g=1}^G \sum_{i \in S_g} p_i \log_2 \left(\frac{1}{p_i} \right)$$

$$\begin{aligned}
&= \sum_{g=1}^G P_g \sum_{i \in S_g} \frac{p_i}{P_g} \left(\log_2 \left(\frac{1}{P_g} \right) + \log_2 \left(\frac{P_g}{p_i} \right) \right) \\
&= \sum_{g=1}^G P_g \left(\sum_{i \in S_g} \frac{p_i}{P_g} \right) \log_2 \left(\frac{1}{P_g} \right) + \sum_{g=1}^G P_g \left(\sum_{i \in S_g} \frac{p_i}{P_g} \log_2 \left(\frac{P_g}{p_i} \right) \right) \\
&= \sum_{g=1}^G P_g \log_2 \left(\frac{1}{P_g} \right) + \sum_{g=1}^G P_g \left(\sum_{i \in S_g} \frac{p_i}{P_g} \log_2 \left(\frac{1}{p_i / P_g} \right) \right)
\end{aligned}$$

Son satırın sağındaki birinci terim H_0 dır. Dolayısıyla:

$$H = H_0 + \sum_{g=1}^G P_g H_g \quad (3.29)$$

ve:

$$H_g = \sum_{i \in S_g} \frac{p_i}{P_g} \log_2 \left(\frac{1}{p_i / P_g} \right) \quad g = 1, \dots, G \quad (3.30)$$

Olasılık p_i/P_g , $i \in S_g$ E_i nin S_g altındaki olaylardan bir tanesinin olduğu bilindiği durumdaki şartlı olasılığıdır. Dolayısıyla H_g , S_g kümesindeki entropi ve (9) deki $\sum P_g H_g$ terimi *ortalama grup içi entropidir*. Entropi bu durumda gruplar arası entropi ve grup içi ortalama entropinin toplamıdır. Bu bağıntının iki özelliği hemen takip eder (Theil 1972):

- (i) $H \geq H_0$ dir çünkü hem P_g hem de H_g negatif değildir. Bu gruplamadan sonra öncekinden daha fazla entropi (belirsizlik) olamaz.

- (ii) $H = H_0$ şartı sadece $\sum P_g H_g = 0$ ve $\sum P_g H_g = 0$ şartları yerine gelince olabilir. Bu da sadece herbir S_g kümesi için $H_g = 0$ olduğu zaman mümkündür. Bu demektir ki entropi gruplararası entropiye sadece gruplamanın sıfırdan farklı olasılığa sahip en fazla bir olayın var olacağı şekilde yapılması durumunda eşittir.

Bilgisel terimlerle Ayrıştırma teoremi şöyle yorumlanabilir. Birinci mesajda olay kümelerinden birinin oluştuğunun iletildiğini varsayalım. Beklenen bilgi içeriği H_0 dır. Bunu takip eden mesajın bu kümeye ait olaylardan bir tanesinin oluştuğunu bildirdiğini düşünelim. Bunun beklenen bilgi içeriği H_g dır. Toplam bilgi içeriği $H_0 + \sum P_g H_g$ olur.

3.2.1.3. Çok Boyuta Genişletilmesi

Bir çift olayı ele alalım (X_i, Y_j) ve her iki olayın birlikte oluştuğu olasılığı. İki marjinal katkının olasılıkları:

$$p_{i.} = \sum_{j=1}^n p_{ij} \quad (i = 1, \dots, m) \quad (3.31)$$

$$p_{.j} = \sum_{i=1}^m p_{ij} \quad (j = 1, \dots, n) \quad (3.32)$$

Marjinal entropi değerleri:

$$H(X) = \sum_{i=1}^m p_{i.} \log_2 \left(\frac{1}{p_{i.}} \right) \quad (3.33)$$

$$H(Y) = \sum_{j=1}^n p_{.j} \log_2 \left(\frac{1}{p_{.j}} \right) \quad (3.34)$$

Ve iki boyutlu entropi:

$$H(X, Y) = \sum_{i=1}^m \sum_{j=1}^n p_{ij} \log_2 \left(\frac{1}{p_{ij}} \right) \quad (3.35)$$

Şartlı entropi Y_j olayının oluştuğunu bildiğimiz zaman kalan bir boyuttaki (mesela, X) belirsizliği ölçer. Bu ise şu şekilde ifade edilir (Theil 1972):

$$H_{Y_j}(X) = \sum_{i=1}^m \frac{p_{ij}}{p_{.j}} \log_2 \left(\frac{p_{.j}}{p_{ij}} \right) \quad (3.36)$$

$$H_{X_i}(Y) = \sum_{j=1}^n \frac{p_{ij}}{p_{i.}} \log_2 \left(\frac{p_{i.}}{p_{ij}} \right) \quad (3.37)$$

Ortalama şartlı entropi ise şartlı entropilerin ağırlıklı ortalaması olarak türetilir:

$$H_Y(X) = \sum_{j=1}^n p_{.j} H_{Y_j}(X) = \sum_{i=1}^m \sum_{j=1}^n p_{ij} \log_2 \left(\frac{p_{.j}}{p_{ij}} \right) \quad (3.38)$$

$$H_X(Y) = \sum_{i=1}^m p_{i.} H_{X_i}(Y) = \sum_{i=1}^m \sum_{j=1}^n p_{ij} \log_2 \left(\frac{p_{i.}}{p_{ij}} \right) \quad (3.39)$$

Ortalama şartlı entropinin hiçbir zaman şartsız entropiyi geçmeyeceği $H_X(Y) \leq H(Y)$ ve $H_Y(X) \leq H(X)$ şeklinde gösterilebilir ve ortalama şartlı entropi ve şartsız entropi sadece iki olayın stokastik olarak bağımsız olması durumunda eşit olabilir (Theil 1972).

Beklenen ortak bilgi iki boyut arasındaki bağımlılığın bir ölçüsüdür; yani ne ölçüye kadar olayların belli kombinasyonlar şeklinde birlikte oluşmaya müsait olmasıyla alakalıdır. Bu kapsamda entropi varyansa benzemesi gibi ortak beklenen ortak bilgi de çarpma momenti korelasyon katsayısına benzetilebilir. Ortak bilgi şu şekilde verilebilir:

$$J(X, Y) = \sum_{i=1}^m \sum_{j=1}^n p_{ij} \log_2 \left(\frac{p_{ij}}{p_{i.} \cdot p_{.j}} \right) \quad (3.40)$$


Bazen $M(X, Y)$ veya $T(X, Y)$ şeklinde de ifade edilir. $J(X, Y) \geq 0$ ve $J(X, Y) = H(Y) - H_X(Y)$ ve $J(X, Y) = H(X) - H_Y(X)$ olduğu gösterilebilir (Theil 1972: 125-131). Buna ek olarak çok boyutlu entropinin marjinal entropilerin toplamından ortak bilginin çıkarılmasıyla elde edilebileceği türetilir (Theil 1972):

$$H(X, Y) = H(X) + H(Y) - J(X, Y) \quad (3.41)$$

Bunu şu şekilde yorumlamak mümkündür: Ortak bilgi olmadığı zaman marjinal dağılımlar bağımsızdır ve entropileri toplanarak toplam entropiyi verir. Ortak bilgi pozitifse marjinal dağılımlar bazı kombinasyonların diğer kombinasyonlara göre daha fazla görüldüğü için bağımlıdır ve marjinal entropilerin toplamı toplam entropiden ortak bilgi miktarı kadar daha fazladır.

3.2.2. ARMA – Özbağlanımlı Kayan Ortalama Yaklaşımı (AutoRegressive Moving Average): Zaman Serileri İçin Regresyon Formülü

Yapay veri üzerinde kısa vadeli dışdeğerleyici olarak kullanılan MLP ARMA yaklaşımını kullanmaktadır.



Şekil 3.5. Kısa vadeli dışdeğerleyici

Genellikle $X = \langle x_1, x_2, \dots, x_n \rangle$ zaman serisi için

→ $x_{n+1} = \zeta + \phi_n x_n + \phi_{n-1} x_{n-1} + \dots + \phi_1 x_1 + \varepsilon_{n+1}$ formülünü kullanarak x_{n+1} i tahmin edilir.

ϕ_i – otoregresyon parametresidir. Daha önceki ortalamadan sapmaların ağırlıklı toplamı olarak düşünülebilir.

ε_{n+1} – $n+1$ anındaki rastgele hatadır.

→ Bunun yerine hareket eden ortalamaları: $x_{n+1} = a_{n+1} + \theta_n a_n + \theta_{n-1} a_{n-1} + \dots + \theta_{n-q} a_{n-q}$ kullanarak x_{n+1} değeri tahmin edilir.

a_i – birbirini izleyen değerler kümesinden hareket eden ortalama; ağırlıklı ortalama önce görünen değerlere dayandırılır.

θ_i – yukarıdaki ϕ_i değerine eşdeğerdir.

Otoregresyon hedefi –sapmaların ortalama karesi görünen değerlere dayanarak endüshüklenir.

3.2.3. Matris Pencil Metodu (MPM: Matrix Pencil Method)

Yapay veri üzerinde MLP ile karşılaştırılan ve gerçek veri üzerinde de başarıyla denenen Matris Pencil metodunun altında yatan varsayım sinyalin sönmölenen sinüzoidler şeklinde yeniden oluşturulabileceğidir. Genellikle sistemin cevabı

analitik kapalı formlar yerine simülasyonlar ya da ölçümler yoluyla elde edilir. Dolayısıyla sinyal dalga formu örneklenir ve şu şekilde ifade edilir:

$$y[k] = \sum_{i=1}^M R_i z_i^k \quad (3.42)$$

burada T_s genellikle z_i 'de gömülüdür ve örnekleme periyodunu gösterir, R_i 'ler genellikle karmaşık çiftler şeklinde kalıntıları temsil eder ve z_i 'ler Z-Dönüşümü boyutunda karmaşık üstelleri temsil ederler. Dalga formları zaman boyutunda gerçek oldukları için karmaşık üsteller eşlenik çiftlerdir. Fakat bu değerler bazı durumlarda gerçek değer alabilirler. Yukarıdaki denklemde verilen eşittir ifadesine dikkat etmek gerekir. Denklemin sol tarafındaki örneklenen değer özgün sinyal ve rastgele gürültünün toplamıdır. Bu uygulamada gürültü sayısal hatadır ve simülasyon algoritmasının sonlu hassasiyetinden kaynaklanmaktadır. Denklemin sağ tarafı ise özgün sinyalin sönmüş sinüzoidler şeklindeki yaklaşıklığıdır. Bu yaklaşımın doğruluğu kullanılan terim sayısına bağlıdır yani kutup sayısı ve kesim hatası M sayısının bir fonksiyonudur. Buna ilave olarak bu parametre MPM'in çekirdek operasyonu olan SVD'de çok önemli rol oynamaktadır. Örneklerin seçimi işlemin karmaşıklığını etkilemektedir. FDTD'den gelen dalga formları genellikle aşırı örneklenmiştir çünkü zaman boyutu simülasyon algoritmalarındaki zaman aralığı Δt gereksinimleri Nyquist teoreminde belirtilen örnekleme kuralından çok daha sıkıdır. Dolayısıyla bir yoketme faktörü uygulandığı takdirde aynı zamanda evrişen bir sinyal daha az örnekle ifade edilebilir (Luo, X., 1998). Dolayısıyla SVD'de kullanılan matrisler küçülür ve işlem çok daha hızlanır.

3.2.3.1. Pencil Biçimi ve Pencil Parametresi

Problem çözümü genelleştirilmiş bir özdeğer problemi şeklinde formülize edilmiştir ve N ölçülen örnekten iki tane Hankel matrisi oluşturulmuştur. İlk olarak $(N-L) \times (L+1)$ Matris olan Y örneklenmiş diziden oluşturulur:

$$[Y] = \begin{pmatrix} y[0] & y[1] & \dots & y[L] \\ y[1] & y[2] & \dots & y[L+1] \\ \dots & \dots & \dots & \dots \\ y[N-L-1] & y[N-L] & \dots & y[N] \end{pmatrix}_{(N-L) \times (L+1)}$$

Bir sonraki adım $[Y]$ matrisinin sırasıyla son veya ilk sütununu silerek oluşturulan iki tane daha matris tanımlanmasıdır. Son olarak Pencil problemi şu şekilde formüle edilir:

$$[Y_2] - \lambda[Y_1] = \begin{pmatrix} y[1] & y[2] & \dots & y[L] \\ y[2] & y[3] & \dots & y[L+1] \\ \dots & \dots & \dots & \dots \\ y[N-L] & y[N-L+1] & \dots & y[N] \end{pmatrix}_{(N-L) \times L} - \lambda \begin{pmatrix} y[0] & y[1] & \dots & y[L-1] \\ y[1] & y[2] & \dots & y[L] \\ \dots & \dots & \dots & \dots \\ y[N-L-1] & y[N-L] & \dots & y[N-1] \end{pmatrix}_{(N-L) \times L}$$

$[Y_1]$ ve $[Y_2]$ deki her eleman birinci denklemdeki gibi ifade edilebilirse bu denklem şu şekilde yeniden yazılabilir:

$$[Y_2] - \lambda[Y_1] = \{[Z_2][R_0][Z_0][Z_1]\} - \lambda\{[Z_2][R_0][Z_1]\} = [Z_2][R_0]\{[Z_0] - \lambda[I]\}[Z_1]$$

burada

$$[Z_0] = \text{diag}[z_1, z_2, \dots, z_M] \quad , \quad Z_2 = \begin{pmatrix} 1 & z_1 & \dots & z_1^{(N-L-1)} \\ 1 & z_2 & \dots & z_2^{(N-L-1)} \\ \dots & \dots & \dots & \dots \\ 1 & z_M & \dots & z_M^{(N-L-1)} \end{pmatrix}_{(N-L) \times M}$$

ve

$$Z_1 = \begin{pmatrix} 1 & 1 & \dots & 1 \\ z_1 & z_2 & \dots & z_M \\ \dots & \dots & \dots & \dots \\ z_1^{(L-1)} & z_2^{(L-1)} & \dots & z_M^{(L-1)} \end{pmatrix}_{M \times L}, [R_0] = \text{diag}[R_1, R_2, \dots, R_M]$$

ve $I(M) \times (M)$ birim matristir.

Gösterilmiştir ki üçüncü denklemdeki $[Y_2] - \lambda[Y_1]$ 'nin özdeğerleri birinci denklemin kutuplarına karşılık gelmektedir (Hua, Y. vd, 1988) ve herbir kutbun gerçekte ve sanal değerleri sırasıyla sönümlenme faktörüne ve sönümlenen sinüzoidin frekansına karşılık gelmektedir. Kalıntılar da belirlendikten sonra birinci denklemdeki değerler herbir zaman adımında sinyali temsil etmek için $t=kT_s$ kullanılabilir. Sinyal birinci denklemdeki gibi temsil edilebilirse üçüncü eşitliğin $[Y_2] - \lambda[Y_1]$ Pencil'inin matrisleri sıra bakımından kısıtlıdır ve Hankel yapısı gösterir (Lu, B. vd., 1998). Pencil matrisinin en yüksek sırası M 'dir. Fakat λ kutupların z_i herhangi birine eşit olduğu zaman Pencil Matris sıra bakımından düşer ve i 'nci z_i üçüncü eşitlikteki $[Y_2] - \lambda[Y_1]$ problemindeki özdeğere karşılık gelir. (Hua, Y. vd, 1988).

Problemin formülasyonunda L parametresi konulmuştur. Bu Pencil parametresidir ve üçüncü denklemdeki $[Y_2]$ ve $[Y_1]$ matrislerinin bir boyutunu belirler. L parametresi en azından M den büyük ve $N-M$ den küçük olacak şekilde sınırlandırılmıştır fakat bu parametrenin daha sınırlı bir bölgede yani $N/3 < L < N/2$ bölgesinde seçilmesi uygundur (Sarkar T.K. v.d., 1995). Bu değerler metodun gürültüye karşı daha duyarsız olmasına yarar.

3.2.3.2. Kesintiye Uğramış Tekil Değer Ayırımı (SVD) ve Kutup Sayısı

Pencil problemi belirlenince çözümü Y_1 matrisinin tersini alarak ve $\{[Y_1]^H[Y_2]\}$ matrisinin özdeğerlerini bulmakla elde edilir. Fakat hasta durumlu bir matris olduğu için özellikle sinyale gürültü eklenmişse geleneksel algoritmalar kararlı değildir (Lu, B. vd., 1998). Bu problemi çözmek için $[Y_1]$ ve $[Y_2]$ matrisleri üzerinde SVD metodu uygulanabilir. Daha sonra en büyük özdeğerler bulunup özgün matrislerin

kesilmiş versiyonları elde edilebilir (Luo, X., 1998). Bu prosedür Pencil matrisinin sırası M 'i kısıtlar fakat Hankel yapısı kaybolur ve sinyal gürültü oranı düşükse metodun performansı düşer.

ve $[Y_2]$ matrisleri üzerinde SVD metodu uygulamak yerine T.K. Sarkar ve O. Pereira ayrıştırma özgün matris $[Y]$ üzerine uygulanırsa $[Y]$ 'nin sağ özdeğerlerine dayalı olarak yeni bir Pencil matrisi belirlenebileceğini ve bu yeni matrisin özdeğerlerinin $[Y_2] - \lambda[Y_1]$ özdeğerlerine eşit olduğunu göstermişlerdir (Sarkar vd., 1995). $[Y]$ matrisi şu şekilde ayrıştırılabilir:

$$[Y]_{(N-L) \times (L+1)} = [U]_{(N-L) \times (N-L)} [\Sigma]_{(N-L) \times (L+1)} [V]^H_{(L+1) \times (L+1)}$$

H eşlenik devriği ifade eder ve $[U]$ ve $[V]$ matrisleri sol ve sağ özdeğerleri ve $[\Sigma]$ ise $[Y^H Y]$ matrisinin özdeğerlerinin pozitif karakökleriyle doldurulmuş kare olmayan bir diagonal matrisi ifade etmektedir.

Teoride $[\Sigma]$ matrisinin sadece M sıfırdan farklı elemanı olması gerekir. Fakat eklenen gürültüden dolayı matris $L+1$ sıfırdan farklı diagonal elemana sahip olabilir ve bunlardan M tanesi yeni kesilmiş $[Y_T]$ matrisini yeniden oluşturmada kullanılmalıdır. Bu sayı önceden kestirilemeyeceği için $[\Sigma]$ matrisini inceleyen ve sadece kritere uyan elemanları seçen bir prosedür uygulanır. Yeni $[Y_T]$ matrisi o halde:

$$[Y_T]_{(N-L) \times (L+1)} = [U]_{(N-L) \times (M)} [\Sigma]_{(M) \times (M)} [V]^H_{(M) \times (L+1)}$$

olur. $M+1$ den $L+1$ e kadar özdeğerler ve özvektörler tüm üç matristen ($[\Sigma]$, $[V]$, $[U]$) atılır ve $[Y_T]$ yeni matrisi oluşturulur. Üçüncü denklemde tanımlanan $[Y_1]$ ve $[Y_2]$ 'nin şu şekilde yeniden yazılabildiği gösterilmiştir (Sarkar T.K. v.d., 1995):

$$\begin{aligned} [Y_{1T}]_{(N-L) \times (L)} &= [U]_{(N-L) \times (M)} [\Sigma]_{(M) \times (M)} [V_1]^H_{(M) \times (L)} \\ [Y_{2T}]_{(N-L) \times (L-1)} &= [U]_{(N-L) \times (M)} [\Sigma]_{(M) \times (M)} [V_2]^H_{(M) \times (L)} \end{aligned} \quad (3.43)$$

burada $[V_1]$ ve $[V_2]$ sağ özvektör matrisi olan $[V]$ 'nin sırasıyla son ve ilk sütununu silerek oluşturulur. Dolayısıyla üçüncü denklemde ifade edilen özgün problem sadece sağ özdeğerlerin kullanıldığı şu probleme denk olur:

$$[Y_2] - \lambda[Y_1] = [V_2]^H - \lambda[V_1]^H \quad (3.44)$$

SVD'deki en önemli konu M 'nin seçilmesidir. Bu parametrenin en yüksek değeri L 'dir ve daha iyi sinyal rekonstrüksiyonuna yol açar. Daha fazla sönümlenen sinüzoid kullanmanın rekonstrüksiyon doğruluğunu artırdığı anlamına gelir. Fakat matris daha çok hasta duruma gelir çünkü sayısal kararsızlığa sebep olan en küçük özdeğerler bile dikkate alınmaya başlar. M 'nin küçük seçimi kararsızlığı önleyebilir fakat rekonstrüksiyon doğruluğu kötüleşir.

Özgün matris Y ile kesilmiş versiyonu Y_T arasındaki ortalama kare hata iki terime ayrılabilir (Sullivan, B.J. v.d., 1984):

$$E_t = |E_T| - |E_n| \quad (3.45)$$

Sayısal kararsızlıkla ilgili olan birinci terim M ile artar. Rekonstrüksiyon kesinliğiyle ilgili olan ikinci terim ise M ile ters orantılıdır. Dolayısıyla sayısal kararlılık ve rekonstrüksiyon kesinliği arasındaki değiş tokuşa karşılık gelen en iyi bir M değeri vardır (Giuseppe, 2004).

3.2.4. Asal Bileşen Analizi (PCA)

Araba yayımlarının MLP yardımıyla sınıflandırılmasını hedef alan problemde veri boyutunu düşürmek için başvurulmuş Asal bileşen analizi gürültülü ve bozulmuş veri setlerini yeniden ifade etmek için en anlamlı referans sistemini hesap etmeye çalışan bir yöntemdir. PCA veri üzerinde SVD'ye (singular value decomposition) benzer bir etki yaparak bileşenleri tespit etmeye çalışır.

SVD'nin nasıl çalıştığına bir göz atalım. X herbiri m boyutlu vektörlerden oluşan n deneyden oluşan $m \times n$ Matris olsun. X 'in SVD'si şu şekildedir:

$$X = USV^T \quad (3.46)$$

Bu denklemde U $m \times n$ bir matristir. Bu matrisin sütunları $\{u_k\}$ sol tekil vektörler olarak adlandırılır ve deneyler için birimlik taban oluştururlar. V^T $n \times n$ bir matristir ve satırları $\{v_k\}$ sağ tekil vektörlerdir ve ölçüm vektörleri için birimlik tabandır. $S = \text{diag}(s_1, \dots, s_n)$ ise $n \times n$ diagonal bir matristir ve değerleri $\{s_k\}$ tekil değerlerdir. Kare simetrik bir X matrisi için SVD diagonalizasyonla veya özdeğer probleminin çözümüne eşdeğerdir.

SVD'yi hesaplamak için önce $X^T X$ diagonalize edilerek V^T ve S hesaplanır:

$$X^T X = VS^2V^T \quad (3.47)$$

Daha sonra U hesaplanır:

$$U = XVS^{-1} \quad (3.48)$$

X matrisinin derecesi olan r , n 'den küçük olduğu için bazı tekil değerler $s_k = 0$ olacaktır ($k = r+1, \dots, n$ için). Dolayısıyla U 'yu hesaplamak için önceki çarpımda V 'nin sadece ilk r sütunu önemlidir. Geriye kalan $n - r$ vektörler Gram-Schmidt orthogonalizasyonu ile belirlenebilir.

PCA SVD ile şu şekilde alakalıdır: tekil değerler verinin kovaryans matrisinden hesaplanır. Eğer X 'in herbir sütununu merkezlersek (her sütundan kendi ortalaması çıkarılır ve sıfır ortalamaya dönüşür) $X^T X$ deneylerin kovaryans matrisiyle orantılı olur. Dolayısıyla $X^T X$ nin diagonalizasyonu deneylerin asal bileşenlerini (özvektörlerini) içeren V^T yi verir ve $X^T X$ nin özdeğerler olan s_k^2 asal bileşenlerin varyanslarıyla orantılıdır.

3.2.5. Kısa Vadeli Fourier Dönüşümü ve Dalga Paketçiği Dönüşümleri

Otomobil yayım verileri hem STFT hem de WP metotları ile dönüştürülmüşler ve sınıflandırılmadaki başarıları karşılaştırılmıştır.

3.2.5.1. Kesikli Fourier Dönüşümü

Fourier analizi bir fonksiyon veya sinyali frekans harmoniklerine ayrıştırmaktan ibarettir. Fourier dönüşümü operatörü bir piyano gibi çalışmaktadır. Bir piyanonun yanında yüksek bir ses çıkarıldığı zaman bazı tellerin titreştiğini görürsünüz. Bunlar sesi oluşturan frekanslara karşılık gelmektedir. Piyanoların akortu bu şekilde yapılmaktadır. Kullanılan akort çatalı yüksek bir ses çıkarır ve bu ses piyanodaki sadece tek bir teli titretmelidir. Fourier dönüşümü hangi tellerin titreşmesi gerektiğini ve belli bir fonksiyon için ne kadar titreşmesi gerektiğini söylemektedir.


Fourier analizi tekniklerinin sayısız uygulaması vardır. Fourier analizi bir süre için görüntü sıkıştırmakta kullanılmıştır. JPEG görüntü sıkıştırmaları standardının altında Fourier analizi yatmaktadır. (Kasım 2000 yılında yürürlüğe giren JPEG2000 standardında dalgacıklar kullanılmaya başlanmıştır.) Bu sıkıştırma tekniğinin altında yatan anlayış, yüksek frekans bileşenlerinin fazla bilgi taşımadığıdır. Dolayısıyla bu bileşenleri düşürerek resimlerin elektronik büyüklüğü küçültülebilir. Bu yöntemde görüntü kalitesinden ödün verilmektedir fakat genellikle çok yüksek bir sıkıştırma oranı elde edilmektedir.

Fourier analizi teorisi radyo, televizyon ve X ışını cihazları gibi birçok alette kullanılmaktadır.

Fourier dönüşümü frekans ve zaman arasındaki dönüşümü sağlar:


$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (3.49)$$

Bu dönüşümde her iki boyutta birden yerelleşmek mümkün değildir:



Şekil 3.6. Fourier Dönüşümü:

Yani frekans boyutuna dönüştüğünde elde edilen genlik bilgisidir. Bununla baş etmek üzere STFT metodu geliştirilmiştir. Bu bir çeşit kayan pencere metodudur ve bir dereceye kadar zaman bilgisi verir fakat elde edilen frekans çözünürlüğü pencere büyüklüğüyle sınırlıdır.




Şekil 3.7. Kısa Zamanlı Fourier Dönüşümü (STFT)

Dalgacık Dönüşümü konum boyutuna ölçeği ekleyerek farklı örneklemelere fırsat tanır. Fourier analizindeki dikgen baz olarak alınan sinüzoidlere karşın dalgacık bazları daha yerelleşmiş dalgacık paketlerini temsil etmektedir. Ölçek ise bir dalga bazının katlarını alarak gittikçe büyötmek anlamına gelir.

Düşük Ölçek $a \Rightarrow$ Sıkışmış Dalgacık $\Rightarrow$ Çabuk değişen detaylar $\Rightarrow$ Yüksek Frekans ω .

Yüksek Ölçek $a \Rightarrow$ Esnemiş Dalgacık $\Rightarrow$ Yavaş değişen, kaba özellikler $\Rightarrow$ Düşük Frek ω .




Şekil 3.8. Dönüşümler

Dönüşüm Fourier analizini andırmakla birlikte daha farklıdır:


$$C(skala, konum) = \int_{-\infty}^{\infty} f(t) \psi(ölçek, konum, t) dt \quad (3.50)$$

Kesikli Dalgacık analizi sinyalin düşük ve yüksek frekanslı bileşenlerini iki adet süzgeç yardımıyla ayırarak çalışır.




Şekil 3.9. Kesikli Dalgacık Analizi

Bu analiz düşük frekans dalları gittikçe derinleştirilerek bir ağaç yapısı şeklinde istenilen veya sinyal çözünürlüğünün izin verdiği sürece derinleştirilir.



Şekil 3.10. Dalgacık Ayırışımı

Dalgacık paketi ayrışımı ise ağaç yapısını hem düşük hem de yüksek frekanslarda derinleştirerek ayrıştırmak anlamına gelir.




Şekil 3.11. Dalgacık Paketi Ayırışımı

Dalgacık paketi Ayırışımında ağaç yapısının herhangi bir bölümünde herhangi bir derinliğe kadar inilebilir. Yani örneğin $S=A_1+AD_2+ADD_3+DDD_3$ gibi farklı Ayırıştırmalar yapılabilir ve bu yapı evrensel enerjiyi muhafaza eder.

3.2.6. Dalgacık Paketi Dönüşümü Analizi

3.2.6.1. Dalgacık Paketi Analizinin Uygulanışı

Dalgacık dönüşümü, sinyali uzaysal frekansa göre ayrıştırır (Wickerhauser M V, 1994). Bu ise sinyali karesel ayna süzgeci (QMF) olarak anılan ve bant altı kodlamaya göre çalışan bir çift diyadik dikgen süzgeç ile süzerek gerçekleştirilir. (Rioul O ve Vetterli M 1991). Bu sinyali düşük ve yüksek geçiren iki süzgeç ile kaba ve ince çoklu-çözünürlük bileşenlerine ayıran bir Çoklu-çözünürlük işlemidir (Wickerhauser M V 1994; Wornell G W 1993). Şekil 3.12 dalgacık süzgeç fonksiyonlarının çift aile kavramını göstermektedir. Haar (d2) dalgacığın için, düşük geçiren süzgeç, genellikle baba dalgacık olarak adlandırılan ϕ ölçek fonksiyonuyken ve integrali bire eşitken, anne dalgacık olan ψ nin integrali sifıra eşittir. Yüksek dereceli dalgacıklara ait diğer süzgeç özellikleri şekil açıklamasında verilmiştir. Sıfır etrafında titreşen dalgacık fonksiyonlarının doğrusal kombinasyonları dolayısıyla 1 boyutlu sinyalleri temsil etmek ve yaklaşım için kullanılabilir. Dalgacıklar özellikle keskin sıçramalar yapan ve dolayısıyla Fourier serisi yaklaşım metotlarıyla çözümlenmesi zor sinyallerin incelenmesinde işe yarar. Şekil 3.12’de dört dikgen dalgacık süzgeç fonksiyonu yalnızca osilasyon derecesi ve düzenlilik bakımından farklılık göstermektedir. Haar dalgacığın (d2) bir kare dalgadır ve simetriktir fakat sürekli olmadığı için zayıf pozisyon frekans yerelleşmesine sahiptir (Daubechies I, 1992).



Şekil 3.12. Dalgacık Süzgeç Fonksiyonlarının Çift Aile Kavramı

QMF süzgeçlerinden birisinin ölçeklenmesi ve ötelemesi ile birbirinden çok farklı dalgacık paketi fonksiyonları $W_b(i)$ üretilir. Herbir fonksiyon titreşme veya dalgacık paketinin yaptığı sıfır geçişlerinin sayısına eşit olan b frekansına sahiptir. Haar tabanı için, dalgacık sıfır içerisinde titreşmez ($b=0$) dolayısıyla $\phi(i) \equiv W_0(i)$ dir fakat anne dalgacığının bir tane sıfır geçişi vardır ($b=1$) ve $\psi(i) \equiv W_1(i)$ dir. WPA sinyalin ölçeklenmiş ve kaydırılmış W_b den aşağıdaki şekilde üretilmiş dalgacık paketi fonksiyonları $W_{m,b,n}$ ile yaklaşıklanması yoluyla çalışır:

$$W_{m,b,n}(i) = 2^{-m/2} W_b(2^{-m}i - n) \quad (3.51)$$

Herbir dalgacık paketini $W_{m,b,n}$ karakterize eden notasyon 2^m ölçeğini ve $2^m n$ konumunu yansıtır. Çözünürlük seviyesi m ile değişirken kayma n ile değişir. Dolayısıyla bir $f(i)$ sinyali dikgen dalgacık paketi fonksiyonları $W_{m,b,n}(i)$ nın toplamı olarak şu şekilde yaklaşılanabilir:

$$f(i) \approx \sum_m \sum_b \sum_n w_{m,b,n} W_{m,b,n}(i) \quad (3.52)$$

Dalgacık paketi katsayıları C_n^m bu integralden elde edilebilir:

$$C_n^m \equiv w_{m,b,n} \approx \int W_{m,b,n}(i) f(i) di \quad (3.53)$$


Bu denkleme göre sinyali optimal olarak karakterize etmek için birçok dalgacık paketi fonksiyonu kombinasyonu mümkündür. Bu fraktal sinyallerin analizinde kullanılan ve dalgacık fonksiyonlarının sabit kesikli çözünürlük seviyelerinde bulunduğu daha genel dalgacık dönüşümü ile ters düşmektedir.

3.2.6.2. Bir Boyutlu Sinyal İşlemede Dalgacık Paketi Dönüşümü

WPA'nın hedefi sinyalin frekans boyutunun logaritmik olarak bölündüğü oktav pencereleri olarak anılan enerji seviyelerine binary ağaç (Coifman R R ve Wickerhauser M V, 1993) Ayrışımını sağlamaktır (Kaiser G, 1994). Ayrışımında herbir ölçek temsilindeki dalgacık katsayı büyüklüğünü endüşüklerken baskın sinyal özelliklerini korur. Dalgacık paketi katsayıları herbir kesikli nitelik için ölçek frekans ve pozisyon açısından enerji büyüklüğü hakkında bilgi taşıdığı için nitelik ve tekillik tespitinde oldukça kararlı bir yöntem sunar. Kayda değer olan nokta fraktal fonksiyonlarının tekillik spektrumunun dalgacık analizi yoluyla belirlenmesi ölçekleme davranışının termodinamik enerji fonksiyonları cinsinden mikroskopik

istatistiksel bir ifadesini ortaya koymasdır (Arnéodo A Bacry E ve Muzy J F, 1995). Sinyali herbir iterasyonda sadece herbir ikinci noktayı tutarak konvolve etmek (aşağı örnekleme) en iyi dalgacık paketi tabanını sonul yapar (Wickerhauser M V 1994; Farge M vd, 1992). Bir sonraki seviyeye olan her dönüşüm bir enerji korunumu sürecidir ve toplam enerji nitelik oynamalarını haritalayan bireysel enerjilerin toplamıdır. Girdi sinyali yukarı örnekleme ve katsayı kombinasyonlarının toplanması yoluyla yeniden oluşturulabilir.

Bilinen osilasyon indeksli bir anne ve baba dalgacık fonksiyonları kümesi (bir QMF) seçerek, bir girdi sinyali dalgacık paketi tablosu oluşturacak şekilde ayrıştırılabilir. Şekil 3.13, d4 dalgacık fonksiyonu kullanarak örnek bir sinyalin dalgacık paketi tablosunu göstermektedir.



Şekil 3.13. d4 Dalgacık Fonksiyonu Kullanarak Örnek Sinyalin WP Tablosu


3.2.7. Yapay Sinir Ağları

Hem otomobil yayımlarının sınıflandırılmasında hem de yapay simülasyon verilerindeki dışdeğerleme için kullanılan yapay sinir ağlarını incelemek için önce yapay sinir ağlarının modellediği gerçek sinir ağlarına göz atmak gerekir.

Beyin karmaşık, doğrusal olmayan ve paralel bir bilgisayardır. Örüntü tanıma, algılama ve motor kontrol gibi işleri herhangi bir bilgisayardan daha hızlı yapabilmektedir. Bu başarı silikon kapıların nanosaniye düzeylerinde ve sinir sistemlerinde milisaniyeler düzeyinde işlemesine rağmen. Bu özelliklere ek olarak öğrenme, ezberleme ve bunun yanı sıra genelleştirme kabiliyetleri biyolojik sinir sistemlerinin algoritmik olarak modellenmesi için bir sebep olmuştur. Bu algoritmik modellere yapay sinir ağları (NN) denmektedir.


İnsan korteksinde 10-500 milyar civarında nöronun 60 trilyon sinapsa sahip olduğu tahmin edilmektedir. Nöronlar yaklaşık herbiri 500 sinir ağından oluşan 1000 ana modülden oluşmaktadır. Peki bu büyüklükteki bir sistemin gerçekten modellenmesi mümkün müdür? En azından şu anda değil. Şimdiye kadarki sinir ağı modellemesindeki başarılar belli işlere ait problemleri çözen küçük yapay sinir ağlarından oluşmaktadır. Modern bilgisayar güç ve hafızası ile orta büyüklükteki problemler tek hedefli NN ile çözülebilmektedir. Fakat beyin farklı bölgelerine dağıtarak aynı anda birden çok problemi çözebilmektedir. Gerçek beyne yaklaşabilmek için daha çok zaman gerekmektedir.

Biyolojik sinir sistemlerinin temel yapı taşları nöron ismi verilen sinir hücreleridir. Şekilde genel yapısı görülmektedir. Nöronlar birbirine çok miktarda bağlantı ile bağlıdırlar. Bağlar bir nöronun aksonundan diğer nöronun dendritinedir. Bu bağlantıya sinaps denir. Sinyaller dendritlerden hücreden geçerek aksona iletilir ve buradan tüm bağlı dendritlere sinyal yayılır. Sinyal hücrenin aksonuna sadece hücre ateş ettiği zaman iletilir. Nöron sinyali güçlendirip veya zayıflatılabilir. Tipik bir yapay nöron yapısı şekilde verilmektedir.



Şekil 3.14. Yapay Nöron Modeli

Yapay sinir ağı ise nöronların katmanlar şeklinde bir araya gelmesiyle oluşur. Bir yapay sinir ağı girdi katmanı, gizli katmanlar ve çıktı katmanından oluşur. Bir katman tamamen veya kısmen bir sonraki katmana bağlanır. Daha önceki katmanlara geri besleme bağlantıları da mümkündür. Basit bir sinir ağı yapısı şekilde verilmektedir.



Şekil 3.15. İleribeslemeli Yapay Sinir Ağı Modeli

Bazı örnek yapay sinir ağı modellerine değinelim:

- Tek katmanlı NN'ler, örneğin Hopfield ağıları
- Çok katmanlı ileri beslemeli NN'ler, örneğin standart geriyayılım, işlevsel bağlantı ve çarpım birim ağıları
- Zamansal NN'ler, örneğin Elman ve Jordan basit yinelenen ağılar
- Kendi organize olan NN'ler, örneğin Kohonen kendi organize olan nitelik haritaları ve öğrenen vektör kuantizer
- İleri beslemeli ve kendi organize olan NN'lerin birleşimi, örneğin ışınsal baz fonksiyonu ağıları.


Bu NN çeşitleri hastalıkların tanısı, konuşma tanıma, veri madenciliği, müzik besteleme (Göksu vd., 2005-a), görüntü işleme, önceden tahmin, robot kontrolü (Aktaş ve Göksu, 2005), kredi tasdiği, sınıflandırma, örüntü tanıma, oyun stratejileri planlama, sıkıştırma ve benzeri bir çok geniş uygulama alanı bulmuştur.

Aktivasyon fonksiyonu doğrusal, adım, sigmoid, hiperbolik tanjant ve gaussian fonksiyonlarından herhangi birisi olabilir. Bunlardan sigmoid fonksiyonu şekilde görülmektedir.

Bu fonksiyonun matematiksel ifadesi şöyledir:

$$f(net - \theta) = \frac{1}{1 + e^{-\lambda(net - \theta)}} \quad (3.54)$$

Burada net, düğüm toplam girdisi ve θ ise gürültü değeridir.



Şekil 3.16. Sigmoid Fonksiyonu


3.2.7.1. MLP ve Geri yayılım (BP – Backpropagation) Algoritması

Geri besleme algoritması yardımcı öğrenmede en çok kullanılan metottur. MLP gizli katmanlardaki nöronlara ağırlıklı bağlantılarla bağlanmış bir giriş katmanından ve bu gizli katmanların yine bağlı olduğu çıktı katmanından oluşur (Şekil 3.15). Girdi düğüm sayısı çıktı ile eşleştirilmek istenen özelliklerin sayısına karşılık gelmektedir. MLP bilinen girdi ve çıktılar kullanılarak eğitilir. Girdiler için ağına verdiği çıktı bilinen çıktılarla karşılaştırılır ve hatalar ağıda geriye doğru iletilerek düğümler arasındaki bağlantılar değiştirilerek gerçek ve beklenen çıktılar arasındaki hata düşürülür. Ağırlık değişiminin hız ve yönü öğrenme hızı ve momentum parametreleri aracılığıyla belirlenir. Tüm eğitim veri seti ağına birçok kez sunulur ve ağırlıkların kademeli değişimiyle hatanın düşmesi sağlanır. Eğitilmiş ağı veri ile istenen çıktılar arasındaki ilişkinin bir modeli haline gelir. Dolayısıyla bu model yeni girdi setlerine karşılık gelen çıktılar tahmininde kullanılabilir ve bu ağı test edilmesi demektir.

3.2.8. Olasılıksal Sinir Ağları (PNN: Probabilistic Neural Networks)

Olasılıksal Sinir Ağları (PNN) genellikle geribeslemeli ağlar gibi diğer yapay sinir ağı modellerine göre daha hızlı öğrenirler (Rumelhardt vd., 1986) ve sınıflandırma problemleri başta olmak üzere farklı uygulamalarda başarıyla kullanılmışlardır. PNN'ler ışınsal temel fonksiyonlu (RBF: Radial Basis Function) ağlarının bir çeşididir (Wasserman, 1993).

Ağ örnekler olarak adlanabilecek T eğitim setinden öğrenir. Herbir örnek i bir y_i girdi vektörüne ve bir çıktı sınıfına sınıfı sahiptir. Test aşamasında ağa bunlardan farklı x girdi vektörleri sunulur ve ağ çıktı olarak bu vektörün ait olabileceği en yakın sınıfı verir. Olasılık sinir ağları Şekil 3.17'de verilen düzene sahiptir.



Şekil 3.17. Olasılıklı Yapay Sinir Ağı

Birinci yani en soldaki katman uygulamadaki herbir girdi için bir düğüme sahiptir. Ağdaki tüm bağlantılar ağırlık olarak 1 değerine sahiptir dolayısıyla girdi vektörü doğrudan olarak gizli düğümlerin herbirine aktarılır.

Eğitim setindeki herbir örnek için bir tane gizli düğüm vardır. Herbir gizli düğüm h_i kendine ait bir y_i merkez noktasına sahiptir bu da i örneğindeki girdi vektörüdür. Her bir gizli düğüm ayrıca bir yayılma faktörü σ_i ye sahiptir. Bu faktör düğümün algı alanının genişliğini verir. Bu parametrenin değerini belirlemenin çeşitli metotları vardır. Bizim yaklaşımımız σ_i 'yi herbir örnek i 'nin en yakın komşuluğuna olan

uzaklığın f ile çarpılması ile bulduk. f ise 0.5 ile başlatılarak doğrusal bir arama metoduyla ince ayarı yapılarak belirlendi. Her 5 adımda bir sınıflandırma için en yüksek ortalama başarıyı veren f değeri seçildi.

Gizli düğümler x girdi vektörünü alıp g Gauss fonksiyonu ile verilen bir aktivasyon çıktısı verir. Eğer x ve y_i eşitse bu çıktı 1 değerini verirken aradaki uzaklık arttıkça ihmal edilebilir bir değere düşer:

$$g(x, y_i, \sigma_i) = \exp[-D^2(x, y_i) / 2 \sigma_i^2] \quad (3.55)$$

Uzaklık fonksiyonu olan D iki vektörün ne kadar uzaklıkta olduğunu gösterir. Bu uzaklığın belirlenmesinde en yaygın metot olan Öklid uzaklığını kullandık.

Herbir h_i gizli düğüm sadece bir tane sınıf düğümüne bağlanır. Eğer i örneğinin çıktı sınıfı j ise h_i sadece c_j sınıf düğümüne bağlanır. Her c_j sınıf düğümü kendisine bağlı olan gizli düğümlerin aktivasyonlarının toplamını hesaplar, bu düğümler o sınıfa mensup gizli düğümlerdir. Sınıf düğümleri daha sonra bu toplamaları karar düğümüne aktarır. Karar düğümü ise en yüksek toplam aktivasyonu veren sınıfı çıktı olarak verir kabul eder.

Bu ağıın en büyük avantajı tekrarlamalı eğitime ihtiyaç duymaması ve dolayısıyla çok hızlı öğrenmesidir. Fakat öteki taraftan herbir eğitim örneği için ayrı bir gizli düğüme sahiptir ve dolayısıyla hafıza ve zaman bakımından daha fazla işlemsel yer harcar. Seri bir işlemcide herbir sınıflama $O(n)$ karmaşıklığında zaman alır. Paralel bir sistemde $O(\log n)$ kadar zaman alır.

3.2.9. Benzetimlenmiş Soğutma (SA) Metotları

Benzetimlenmiş Soğutma metotları eniyileme türü olan ve düşük güç ve düşük sıcaklık problemlerinin çözümü için kullanılmıştır. Türkçeye “Benzetimlenmiş Soğutma” olarak çevrilen SA (Simulated Annealing) metodu, büyük sayıda bağımsız değişkene sahip fonksiyonların evrensel en iyi yani en düşük veya en yüksek

değerinin bulunmasını gerektiren birçok eniyileme probleminde başarıyla uygulanmış bir metottur. Eniyilenmesi istenen fonksiyon genellikle Masraf Fonksiyonu olarak adlandırılır. Ters problem çözümlerinde ise genellikle Hata fonksiyonu bu fonksiyon yerine konarak eniyileme işlemi uygulanır.

SA metodunun temel prensipleri, sıvı veya katı örneklerindeki çok sayıda atomun davranışlarını analiz eden İstatistiksel Mekanik'teki bazı problemlerden alınmıştır. Metot, eniyileme problemlerindeki parametrelerle (model parametreleri) idealleştirilmiş fiziksel bir sistemdeki parçacıklar arasında benzerlikler kurmaktadır.

Fiziksel bir soğutma işleminde ısı banyosuna maruz bırakılan bir katı önce ısıtılarak sıcaklığı artırılır ve böylece içerisindeki tüm parçacıklar sıvı halinde rastgele dağılıma sahip hale gelir. Bu işlemi, yavaş soğutma izler. Bu aşamada parçacıklar kendiliklerinden en düşük enerji seviyesine ulaşacak şekilde organize olurlar ve bu aşamada kristalizasyon meydana gelir.

Eniyileme işlemi de bu fiziksel sistemin soğuyarak en düşük enerjiye ulaşması şeklindeki değişimini taklit eder. Stokastik süreçlerde parçacıkların her konfigürasyonuna “durum” denir. Her sıcaklık derecesinde katı örnek termal dengeye gelmesi için beklenir. Bu şekilde E_i enerjisine sahip her i durumunun olasılığı aşağıdaki gibi Gibbs veya Boltzmann olasılık yoğunluğu fonksiyonuyla ifade edilir:

$$P(E_i) = \frac{\exp\left(-\frac{E_i}{KT}\right)}{\sum_{j \in S} \exp\left(-\frac{E_j}{KT}\right)} = \frac{1}{Z(T)} \exp\left(-\frac{E_i}{KT}\right), \quad (3.60)$$

S kümesi tüm olası konfigürasyonları kapsar, K Boltzmann sabitidir, T sıcaklık ve $Z(T)$ ise bölüşüm fonksiyonudur ve şu şekilde ifade edilir:

$$Z(T) = \sum_{j \in S} \exp\left(-\frac{E_j}{KT}\right). \quad (3.61)$$

Sıcaklık termal denge sağlandıktan sonra kademeli olarak düşürülür ve $T \rightarrow 0$ limitinde en düşük enerji düzeyi çok büyük derecede olası hale gelir. Bu işlemdeki anahtar nokta termal dengenin sağlanmasıdır. Soğutma çok hızlı yapılırsa, madde enerjinin yerel bir en düşük noktasında donar ve böylece cam oluşur. Fakat madde yavaşça soğutulursa süreç sonuçta enerji fonksiyonunun evrensel en düşük noktasında veya ona çok yakın bir noktada sonuçlanır ki bu bir kristal yapıdır.

Bu tezde tartışılan problem ve benzeri eniyileme problemlerinde enerji fonksiyonu yerine $E(m)$ hata fonksiyonu kullanılır. Hata fonksiyonu farklı modeller veya konfigürasyonlar için farklı değerler alır. Biz ise problemimizde bu hata fonksiyonunun en düşük değeriyle ilgileniyoruz. SA metodu, evrensel en düşük enerji seviyesini bulmak için, bahsettiğimiz fiziksel soğuma sürecini taklit eden bir bilgisayar algoritması kullanır.

SA'nın daha önce gördüğümüz MC algoritmalarından farkını göstermek için grafiksel bir örnek üzerinde bir benzetim yapacağız.

Öncelikle Boltzmann sabitini 1'e eşitleyip, Gibbs olasılık yoğunluğu fonksiyonunu şu şekilde yazabiliriz:

$$P(m_i) = \frac{\exp\left(-\frac{E(m_i)}{T}\right)}{\sum_{j \in S} \exp\left(-\frac{E(m_j)}{T}\right)} \quad (3.62)$$

Burada T kontrol parametresidir.

Çizelge 3.1. Benzetimlenmiş Soğutma (Simulated Annealing) Algoritmalarının Listesi

Metropolis Algoritması

Isı Banyosu (HB: Heat Bath) Algoritması

Reddedilmeyen Hareketli SA Algoritması

Hızlı SA (FSA) Algoritması

Çok Hızlı Benzetimlenmiş Tekrar Soğutma (VFSR) Algoritması

3.2.9.1. Metropolis Algoritması

Dijital bilgisayarların bilimsel çalışmalarda kullanılmaya başlandığı ilk günlerde Metropolis vd. (1953) bir katının ısı banyosunda termal dengeye gelişini benzetimleyen bir algoritma geliştirdiler. Daha sonraki çalışmaları takiben (Kirkpatrick vd., 1983) Metropolis algoritması çok yaygın şekilde farklı uygulamalarda kullanıldı. Algoritma, genel olarak benimsendiği şekliyle Çizelge 3.2.'de gösterilen akışa sahiptir:

Çizelge 3.2. Metropolis Algoritması:

$E(m_0)$ enerjiye sahip m_0 rasgele konumunda başla

Sıcaklık (T) üzerinde döngü yap

Rasgele hareket sayısı/sıcaklık üzerinde döngü yap

m_1 yeni modeli için $E(m_1)$ hesapla

$\Delta E = E(m_1) - E(m_0)$

$P = \exp(-\Delta E/T)$

Eğer $\Delta E \leq 0$ ise;

$m_0 = m_1$

$E(m_0) = E(m_1)$

Sorgu sonu

Eğer $\Delta E > 0$ ise;

Rasgele bir sayı $r = U[0,1]$ belirle

Eğer $P > r$ ise;

$$m_0 = m_1$$

$$E(m_0) = E(m_1)$$

Sorgu sonu

Sorgu sonu

Döngü sonu

Döngü sonu

$E(\mathbf{m}_i)$ enerjisine sahip bir $\mathbf{m}_i$ başlangıç modeline, küçük bir sarsım uygulanarak yeni bir $\mathbf{m}_j$ modeli elde edilir:

$$\mathbf{m}_j = \mathbf{m}_i + \Delta \mathbf{m}_i \quad (3.63)$$

yeni modelin enerjisi $E(\mathbf{m}_j)$ 'dir. Metropolis vd. (1953) yeni durum (model)'i parçacığın (model parametresi) yer değiştirmesiyle üretmişti. Fakat denklemde verilen herhangi bir genel sarsım olarak kabul edilebilir. Eğer iki durum arasındaki enerji farkı ΔE_{ij} olursa, yani:

$$\Delta E_{ij} = E(\mathbf{m}_j) - E(\mathbf{m}_i) \quad (3.64)$$

yeni modelin kabul edilip edilmeyeceğine ΔE_{ij} değerine bakılarak kabul edilecektir. Eğer $\Delta E_{ij} \leq 0$ ise yeni model her zaman kabul edilir. Fakat eğer $\Delta E_{ij} > 0$ olursa yeni model şu olasılıkla kabul edilir:

$$P = \exp\left(-\frac{\Delta E_{ij}}{T}\right), \quad (3.65)$$

burada T sıcaklıktır. Yukarıdaki kabul kuralı Metropolis kriteri olarak bilinir.

Eğer yukarıdaki kriteri kullanarak üretme-kabul süreci her sıcaklık değeri için yeterince çok defa tekrarlanırsa her sıcaklık için termal dengeye erişileceği gösterilebilir. Eğer sıcaklık belli bir soğutma tarifesine uygun olarak, her sıcaklıkta

termal dengenin sağlanmasına izin verilecek şekilde yavaşça düşürülürse, sıcaklığın sıfıra yaklaştığı limitte evrensel en düşük enerji düzeyine ulaşılabilir. Evrensel en düşük noktaya yaklaşmanın istatistiksel olarak garantilendiği teorik soğutma tarifeleri türetilmiştir. (Geman ve Geman, 1984).

Yerel bir arama metodunda, bir referans modelinden başlanır ve yeni bir model ancak $\Delta E_{ij} < 0$ durumunda kabul edilir, yani her zaman tepeden aşağı gidişlere izin vardır. Halbuki Metropolis algoritmasında açıklandığı üzere SA'da her modelin $\Delta E_{ij} > 0$ olduğu durumlarda dahi her zaman belirli bir kabul olasılığı vardır. Dolayısıyla yerel arama metotları referans modele yakın olan yerel en düşük noktaya takılabildiği halde SA'nın yerel en düşük noktalardan dışarı atlama olasılığı vardır. Fakat sıcaklık sıfıra yaklaştıkça sadece modelde iyileşmenin görüldüğü durumlar kabul edilir ve $T \rightarrow 0$ limitinde algoritma bir yerel arama algoritmasına dönüşür.

3.2.9.2. Matematiksel Model ve Asimptotik Yaklaşım

Metropolis kriterine göre model üretme ve kabul süreci stokastik süreçlerdeki sonlu Markov zincirleri şeklinde modellenebilir. Markov zinciri stokastik süreçler içerisinde bir denemenin sadece ondan bir önceki denemeye bağlı olmasını ve diğer tüm denemelerden bağımsız olmasını gerektiren bir süreçtir. Metropolis SA'da da bir denemenin sonucu bir önceki denemeninkine Metropolis kriteri ile bağlı olduğu çok açıktır.

Markov zincirleri içerisinde indirgenememe ve aperiodyk özellik gösterenler için tek ve durağan bir dağılıma ulaşmak sözkonusudur ve bu dağılım başlangıç modelinden tamamen bağımsızdır. (Sen ve Stoffa, 1992) Dolayısıyla Metropolis SA'ya ait sözkonusu durağan dağılımı bulmak ve en önemlisi böyle bir durağan dağılımın varlığını ispatlamak için zincir için geçiş olasılık matrisinin, indirgenememe ve aperiodyklik özelliklerinin incelenmesi gerekir.

Aarts ve Korst (1989) ve van Laarhoven ve Aarts (1987) detaylı olarak gösterildiği üzere, Metropolis SA için durağan bir dağılım vardır ve bu dağılım Gibbs

dağılımıdır. Bu demektir ki Metropolis kuralı kullanılarak üretme-kabul işlemi yeterince çok kez tekrarlanırsa modeller Gibbs olasılık yoğunluk fonksiyonuna göre dağılırlar.

3.2.9.3. Isı Banyosu (HB: Heat Bath) Algoritması

Bir önceki bölümde anlatılan Metropolis SA algoritması iki basamaklı bir algoritmaydı, yani önce rastgele değişiklik yapıp, daha sonra bu değişikliğin kabul edilip edilmeyeceğine karar veriliyordu. Özellikle düşük sıcaklıklarda bir çok değişiklik reddediliyordu. Böylece bu verimsizliği ortadan kaldırmak üzere farklı algoritmalar geliştirilmiştir. Bunlardan bir tanesi Isı banyosu algoritmasıdır. (Geman ve Geman, 1984).

Isı banyosu algoritmasının özelliği her hareketin kabulü için relatif olasılık hesabı yaparak yukarıda anlatılan iki basamaklı hesap yöntemini bir basamağa indirmesidir. Yani metot kısaca her zaman kabul edilebilecek ağırlıklı seçimler üretmektedir. Aslında ağırlıklı seçimler yapmak da bir ikinci iş gibi gözükse de bu çok basit bir iş olduğu için verimi düşürmemektedir.

Isı banyosu algoritmasının detayları konuyla çok alakalı olmadığı için burada sadece algoritmanın akış şeması Çizelge 3.3 olarak verilmiştir. Daha detaylı bilgi için kaynaklara müracaat edilebilir (Sen ve Stoffa, 1992).

Çizelge 3.3. Isı Banyosu Algoritması:

$E(m_0)$ enerjiye sahip m_0 rasgele konumunda başla

Sıcaklık (T) üzerinde döngü yap

İterasyon sayısı/sıcaklık üzerinde döngü yap

Model parametre sayısı ($i=1, \dots, N$) üzerinde döngü yap

Model değerleri ($j=1, \dots, M$) üzerinde döngü yap

Değerlendir: $E(m | m_i = m_{ij})$

ve

Hesapla: $P_{ij} \propto \exp(-E(m_i=m_{ij})/T)$

Döngü sonu

Yukarıdaki dağılımdan bir j seç

Döngü sonu

Döngü sonu

Döngü sonu

3.2.9.4. Reddedilen Hareketleri Olmayan SA Algoritması

SAWR (Simulated Annealing Without Rejected Moves) şeklinde kısaltılan bu algoritma (Greene ve Supowit, 1986) ısı banyosu algoritması gibi fakat farklı bir yöntem kullanarak Metropolis SA 'da yüksek olan model reddedilme oranını düşürmektedir. Metropolis SA'dan farklı olarak bu metot her deneme hareketinin enerji fonksiyonu üzerindeki etkisini hesaplar ve bu bilgiyi hareket seçiminde kullanır.

Bu metotta önce $E(m_0)$ enerjisine sahip bir m_0 ilk modeliyle başlanır. Daha sonra $1 \leq i \leq N$ olmak üzere her deneme hareketi (i) için şu fonksiyon hesap edilir:

$$P_i = \frac{w_i}{\sum_{j=1}^N w_j}, \quad (3.66)$$

burada

$$w_i = \exp\left(-\frac{(E(m_i) - E(m_0))^+}{T}\right). \quad (3.67)$$

Model seçiminde yukarıdaki dağılım kullanılmaktadır.

SAWR algoritması yaptığı tüm deneme hareketlerini kaydettiği için klasik Metropolis SA algoritmasına kıyasla amaç fonksiyonu hakkında daha çok evrensel

bilgi biriktirmektedir. Isı banyosu algoritmasından farklı olarak da olasılık yoğunluğu fonksiyonunu oluşturulmasını sadece tek bir parametreyi pertürbe ederek sağlamamaktadır.

Bunlara ek olarak Greene ve Supowit (1986) SAWR'de oluşturulan model serilerinin Metropolis metodunda üretilen durum serileriyle eşdeğer olduğunu göstermişlerdir. Kendi uygulamaları olan bir mantık bölüşüm probleminde SAWR'nin Metropolis SA'dan daha iyi sonuçlar verdiğini göstermişlerdir.

3.2.9.5. Hızlı Benzetimlenmiş Soğutma (FSA)

SA'nın Markov zinciri modeli Boltzmann dağılımıyla verilen durağan bir dağılımın elde edilebileceğini ispatta kullanılabilir ve sıcaklığın sıfıra yaklaştığı limitte evrensel en düşük enerji düzeyinin olasılığı 1'e ulaşır. Fakat evrensel en düşük enerji düzeyine ulaşıp ulaşılamayacağı sıcaklığın hangi hızla düşürüldüğüne bağlıdır, yani soğutma tarifesine bağlıdır. Geman ve Geman (1984) SA algoritmasının evrensel en düşük noktaya ulaşabilmesi için gereken sıcaklık tarifesinin şu şekilde olmasının yeterli olduğunu gösterdiler:

$$T(k) = T_0 / \ln(k) \quad (3.68)$$

Burada $T(k)$ k'inci iterasyondaki sıcaklık ve T_0 ise yeterince yüksek bir ilk sıcaklık değeridir. Bu logaritmik sıcaklık tarifi oldukça yavaş ve evrensel optimal bir çözüme ulaşabilmek için uzun bir süre gerektirmekteydi.

Szu ve Harley (1987) bu sorunu çözebilmek için FSA isminde ve Metropolis SA algoritmasına çok benzeyen fakat fark olarak; Metropolis kriterine uyum için test edilmek için oluşturulan model parametreleri için düz bir dağılım kullanmak yerine Cauchy dağılımı kullanmaktaydı. Cauchy dağılımı (üretim olasılığı) yine sıcaklığın bir fonksiyonudur ve şu şekilde verilir:

$$f(\Delta m_i) \propto \frac{T}{(\Delta m_i^2 + T^2)^{1/2}} \quad (3.69)$$

T yine belli bir soğutma tarifesine göre soğutulur ve Δm_i o andaki model parametre değerinde yapılan sarsım değeridir.

Dikkati çeken bir nokta, yüksek sıcaklıklarda dağılım, o andaki pozisyonundan çok uzak noktalardan model seçimi yapmaya müsaade ederken düşük sıcaklıklarda o andaki pozisyonun yakınındaki modelleri seçmeyi tercih eder. Cauchy dağılımı Gauss dağılımına kıyasla daha düz bir kuyruğa sahiptir ve böylece yerel en düşük noktadan kurtulma şansı daha fazladır. FSA'da model üretme dağılımı Metropolis SA'dan farklı olmakla birlikte iki algoritmadaki model kabul kriteri aynıdır. Szu ve Harley (1987) daha sonraki çalışmalarında yaklaşıklık için gereken soğutma tarifi artık logaritmik değildi ve iterasyon numarasına ters orantıyla bağlı olması yeterliydi:

$$T(k) = T_0 / k \quad (3.70)$$

3.2.9.6. Çok Hızlı Benzetimlenmiş Tekrar Soğutma (VFSR) Algoritması

Ingber (1989; 1993) SA için farklı değişiklikler önerdi ve VFSR (Very Fast Simulated Reannealing) isminde yeni bir algoritma yazdı. Önerdiği değişiklikler şu sebeplere dayanıyordu:

a) NM model uzayında her parametrenin farklı tanım aralıkları vardır ve her parametrenin enerji fonksiyonuna olan etkisi farklı şekildedir. Dolayısıyla o andaki pozisyonunda yapılan sarsımlar her parametre için farklı olmalıdır.

b) FSA algoritması çok iyi olmasına rağmen, mevcut sayısal metotlarla, NM boyutlu ve hızlı bir Cauchy rastgele sayı üretici algoritma yazmak mümkün değildir (Ingber, 1993).

NM boyutlu Cauchy dağılımının oluşturulmasındaki problem bir boyutlu Cauchy dağılımının NM-çarpımı ile elde edilebilir. Böyle bir uygulamada ek olarak her model parametresi için ayrı bir sıcaklık da kullanılabilir. Fakat NM 1 boyutlu Cauchy dağılımının kullanılması yaklaşıklık için çok yavaş bir soğutma tarifesini gerektiriyordu. Ingber (1993) dolayısıyla model üretimi için daha farklı bir dağılım önerdi ve böylece yavaş soğutma tarifesine ihtiyaç olmayacaktı. Ingber'in algoritması (1993) şöyle açıklanabilir:

Varsayalım ki k'ıncı iterasyonda (soğutma adımı veya süre) model parametresi m_i^k şöyle ifade edilsin:

$$m_i^{\min} \leq m_i^k \leq m_i^{\max}, \quad (3.71)$$

$m_i^{\min}$ ve $m_i^{\max}$ model parametresi m_i 'in en yüksek ve en düşük değerleridir. Bu model parametresi (k+1)'inci iterasyonda şu bağıntıya göre pertürbe edilir:

$$m_i^{k+1} = m_i^k + y_i (m_i^{\max} - m_i^{\min}), \quad (3.72)$$

ve şu tanımlar geçerlidir:

$$y_i \in [-1,1] \quad (3.73)$$

ve

$$m_i^{\min} \leq m_i^{k+1} \leq m_i^{\max}. \quad (3.74)$$

y_i parametresi şu dağılımdan üretilir:

$$g_T(y) = \prod_{i=1}^{NM} \frac{1}{2(|y_i| + T_i) \ln \left(1 + \frac{1}{T_i} \right)} = \prod_{i=1}^{NM} g_{T_i}(y_i), \quad (3.75)$$

bu dağılım aşağıdaki yığılımlı olasılığa sahiptir:

$$G_{T_i}(y_i) = \frac{1}{2} + \frac{\text{sgn}(y_i)}{2} \frac{\ln\left(1 + \frac{|y_i|}{T_i}\right)}{\ln\left(1 + \frac{1}{T_i}\right)}. \quad (3.76)$$

Dolayısıyla $U[0,1]$ düzgün dağılımından üretilen bir rastgele sayı yukarıdaki dağılıma şu formül vasıtasıyla uygulanır:

$$y_i = \text{sgn}\left(u_i - \frac{1}{2}\right) T_i \left[\left(1 + \frac{1}{T_i}\right)^{|2u_i - 1|} - 1 \right]. \quad (3.77)$$

Ingber (1989) bu dağılım için evrensel en düşük noktanın istatistiksel olarak aşağıdaki soğutma tarifesini kullanarak elde edilebileceğini gösterdi:

$$T_i(k) = T_{0i} \exp\left(-c_i k^{1/NM}\right), \quad (3.78)$$

Burada T_{0i} i'nci parametre için ilk sıcaklık ve c_i ise sıcaklık tarifesini kontrol edebilmek ve özel problemler için ince ayar yapabilmek için konulmuş bir parametredir.

Model kabul kriteri Metropolis SA algoritması ile aynı olduğu için bu algoritmaya VFSA (Very Fast Simulated Annealing) denilmiştir. Algoritma özet olarak aşağıda verilmiştir (Çizelge 3.4).

Algoritmanın genel özelliklerini şöyle sıralamak mümkündür:

- a) Model parametreleri için sarsımları (4.19) da verilen dağılıma göre üretir.
- b) Her model parametresi için ayrı sıcaklık gerektirir ve bu sıcaklıklar farklı model parametreleri için farklı olabilir.

c) Kabul kriteri için ayrı bir sıcaklık gerektirir ve bu model parametreleri için kullanılan sıcaklıktan farklı olabilir.

Ingber (1989) kendi VFSA algoritmasında yukarıdaki algoritmaya fazladan bir değişiklik ilave etti. Bu da her model parametresi için sıcaklık tarifesini değiştirmesiydi. Bu değişikliği ise parametrelerin enerji fonksiyonuna olan etkilerinin farklılığına aşağıdaki şekilde dayandırdı.

Bir model parametresi olan m_i için bir hassasiyet S_i tanımlayalım:

$$S_i = \frac{\partial E(m)}{m_i}. \quad (3.79)$$

T_{ik} i'nci model parametresinin k soğutma zamanındaki sıcaklığı olarak kabul edilirse, yukarıdaki hassasiyet değeri şu şekilde değişime uğrar:

$$T_{ik'} = T_{ik} \left(\frac{S_{\max}}{S_i} \right), \quad (3.80)$$

Çizelge 3.4. VFSA Algoritması:

$E(m_0)$ enerjiye sahip m_0 rasgele konumunda başla

Sıcaklık (T) üzerinde döngü yap

Rasgele hareket sayısı/sıcaklık üzerinde döngü yap

Model parametreleri $i=1, \dots, NM$ üzerinde döngü yap

$u_i \in [0,1]$

$y_i = \text{sgn}(u_i - 1/2) T_i^{\text{mod}} [(1 + T_i^{\text{mod}})^{|2u_i - 1|} - 1]$

$m_i^{\text{yeni}} = m_i^{\text{eski}} + y_i (m_i^{\text{max}} - m_i^{\text{min}})$

$m_i^{\text{max}} \leq m_i^{\text{yeni}} \leq m_i^{\text{min}}$

döngüyü bitir

şimdi yeni bir modelimiz var: m^{yeni}

$\Delta E = E(m_1) - E(m_0)$

$$P = \exp(-\Delta E/T)$$

Eğer $\Delta E \leq 0$ ise;

$$m_0 = m^{\text{yeni}}$$

$$E(m_0) = E(m^{\text{yeni}})$$

Sorgu sonu

Eğer $\Delta E > 0$ ise;

Rasgele bir sayı $r = U[0,1]$ belirle

Eğer $P > r$ ise;

$$m_0 = m^{\text{yeni}}$$

$$E(m_0) = E(m^{\text{yeni}})$$

Sorgu sonu

Sorgu sonu

Döngü sonu

Döngü sonu

S_{maz} , S_i 'nin en büyük değeridir. S_i 'nin küçük değerleri için $S_{\text{maz}}/S_i > 1$ 'dir ve $T_{ik}' > T_{ik}$ dir. Bu sıcaklığı yükseltir ve böylece daha az hassas olan parametreler için arama aralığını daha hassas olanlarınkine nazaran uzatır (Ingber, 1993). Sıcaklığın artırılmasına izin veren bu algoritmayı, belli bir soğutma tarifesine göre sadece sıcaklık azalmasına izin veren SA algoritmasından ayırmak için “annealing” yani soğutma kelimesinde “reannealing” yani yeniden soğutma şeklinde bir değişiklik yapılmıştır. Ingber ve Rosen (1992) VFSA algoritmasını altı test fonksiyonu için Genetik Algoritmalarla (GA) karşılaştırmış ve kat kat daha verimli olduğu sonucunu çıkarmışlardır.

3.2.10. Elektromanyetik Simülasyonlar

FDTD sinyallerinde dışdeğerleme olan ikinci problemde simülasyon sinyallerinin yanısıra yapay veriler de kullanılmıştır. Sinyal yapılarını anlayabilmek için elektromanyetik simülasyonlarını ve FDTD'nin bunlar arasındaki yerini incelemek gerekir.

Analitik metotlar yüksek derecede simetri taşıyan bazı problemlerin çözümünde çok faydalı olabilir ve birçok konfigürasyonun davranışının belirlenmesinde çok büyük kavrama sağlayabilir. Fakat birçok gerçekçi elektromanyetik konfigürasyonun tam bir değerlendirmesi için sayısal yaklaşım gerekir. Bu yaklaşımlar şu şekilde özetlenebilir:

3.2.10.1. Momentler Metodu

Ağırlıklı kalıntılara dayalı sayısal tekniklere moment metotları denir. EM modelleyiciler moment metodunu sınır elemanı metoduyla eşanlamli olarak kullanagelmışlerdir. Sınır elemanı metodu yüzey integral denklemlerinin çözümüne uygulanan bir moment metodudur. Çoğu ticari moment metodu kodları sınır elemanı kodlarıdır fakat ağırlıklı kalıntılar metodu integral denklemlerinin yanısıra diferansiyel denklemlere de uygulanabilmektedir. Genellikle moment metodu teknikleri sınırsız radyasyon problemlerinin analizinde mükemmel olarak kullanılabılır ve PEC (mükemmel elektrik iletici) konfigürasyonlarında ve homojen dielektriklerde çok iyi iş görürler. Karmaşık homojen olmayan geometrilerin analizine uygun değildirler.

3.2.10.2. Sonlu Eleman Metodu

Sonlu eleman teknikleri sadece yüzeylerin ızgaralanmasını gerektiren yüzey integral tekniklerinin tersine tüm konfigürasyon hacminin ızgaralanmasını gerektirirler. Fakat Herbir ızgara elemanı komşu elemanlardan tamamen farklı madde özellikleri gösterebilirler. Genellikle sonlu eleman teknikleri karmaşık homojen olmayan konfigürasyonların modellenmesinde iyidirler. Fakat bağımsız radyasyon problemlerinde moment metotları kadar iyi değildirler.

3.2.10.3. FDTD

Sonlu fark zaman boyutu teknikleri de tüm hacmin ızgaralanmasını gerektirir. Normalde bu ızgara uniform olmalıdır, böylece ızgara yoğunluğu konfigürasyonun

en küçük detayı tarafından belirlenebilir. Çoğu sonlu eleman ve moment metodu tekniklerinin aksine FDTD teknikleri zaman boyutunda çalışır. Bu onları transient analizi için çok uygun yapar. Sonlu eleman metodu gibi FDTD metotları karmaşık homojen olmayan konfigürasyonların modellenmesinde çok iyidir. Yine FDTD metotları sınırsız problemleri de sonlu eleman kodlarından daha iyi modellerler. Sonuç olarak, FDTD teknikleri sınırsız karmaşık homojen olmayan geometrilerin modellenmesinde seçilecek bir metottur.

3.2.10.4. Diğer Teknikler

Sayısız diğer elektromanyetik modelleme tekniği vardır. İletim Hattı Matrisi Metodu (TLM), genelleştirilmiş çoklu kutup tekniği (GMT) ve diğerleri herbiri belli uygulamalarda avantaja sahiplerdir.

3.2.10.4.1. Sonlu Farklı Zaman Boyutu Metodu (FDTD)

FDTD metodu Maxwell'in zaman bağımlı dönme denklemlerinin doğrudan çözümünden ibarettir:

$$\nabla \times \mathbf{E} = -\mu \frac{\partial \mathbf{H}}{\partial t} \quad (3.1)$$

$$\nabla \times \mathbf{H} = \sigma \mathbf{E} + \epsilon \frac{\partial \mathbf{E}}{\partial t} \quad (3.2)$$


Zaman ve uzay türevlerini hesaplamak için basit merkezsiz fark yaklaşımları kullanılır.

FDTD bir zaman adımlama sürecidir. Girdiler zamansal örneklenmiş analog sinyallerdir. Modellenen bölge birbiri arasına girmiş ve kesikli noktalardan oluşan iki ızgara yapısı ile temsil edilir. Bunlardan bir tanesi manyetik alanın hesaplanacağı noktaları ve diğeri elektrik alanın hesaplanacağı noktaları kapsar.

FDTD uzay penceresinin basit bir elemanı Şekil 3.18’de gösterilmektedir. Her bir manyetik alan vektör bileşeninin dört elektrik alanı bileşeni ile çevrelendiğine dikkat edin. Birinci derece bir merkezsiz fark yaklaşımı şu şekilde ifade edilebilir:

$$\frac{1}{A} \left[E_{z1}(t) + E_{y2}(t) - E_{z3}(t) - E_{y4}(t) \right] = -\frac{\mu_0}{2\Delta t} \left[H_{x0}(t+\Delta t) - H_{x0}(t-\Delta t) \right] \quad (3.3)$$

burada A Şekil 3.18’de görünen hücrenin yakın yüzünün alanıdır. $H_{x0}(t+\Delta t)$ bu denklemden tek bilinmeyendir çünkü diğer tüm değerler bir önceki adımda hesaplanır. Bu şekilde t zamanında hesaplanan elektrik alan değerleri $t+\Delta t$ zamanındaki manyetik alan değerlerinin hesaplanmasında kullanılır. İkinci Maxwell dönme denkleminin de benzer şekilde bir merkezsiz fark yaklaşımı hesaplanır ve $t-t+2\Delta t$ anındaki elektrik alan değerlerinin $t+\Delta t$ deki manyetik alan değerlerinden hesaplanmasına uygulanır. Dönüşümlü olarak elektrik ve manyetik alanların adım adım hesaplanması yoluyla alanlar ızgara boyunca yayımlanır.




Şekil 3.18. FDTD Uzay Örgüsünün Temel Elemanı

Zaman adımlaması durağan bir çözüme veya istenen cevaba ulaşıncaya kadar devam ettirilir. Her bir zaman adımında alan bileşenlerini güncelleştirmede kullanılan denklemler tamamen sarihtir. Hiçbir doğrusal denklem sisteminin çözümü gerekmez.

Bilgisayar hafıza ve çalışma süresi modellenen hacmin elektriksel büyüklüğüne ve pencere çözünürlüğüne bağlıdır.

Şekil 3.19, FDTD uzay ızgarasına gömülmüş rastgele bir saçıcıyı göstermektedir. Izgaranın dış sınırında sinyaller buraya gelince istenmeyen yansımaların önlenmesi için özel emici elemanlar kullanılmıştır. Herbir hücredeki alan bileşenleri için atanan μ , ϵ ve σ değerleri saçıcının konum ve elektriksel özelliklerini belirlemektedir. Bu parametreler anizotropik maddelerin modellenenebilmesine izin vermek için farklı alan yönelimleri için farklı değer alabilmektedir. Bu değerler doğrusal olmayan maddelerin modellenenebilmesini kolaylaştırabilmek amacıyla herbir zaman adımında yeniden ayarlanabilir.



Şekil 3.19. FDTD Uzay Örgüsündeki Saçıcı

Temel elamanlar küp şeklinde olduğu için saçıcıdaki eğimli yüzeylerin merdiven şeklinde modellenmesi gerekir. Birçok konfigürasyon için bu bir problem oluşturmaz. Fakat sivri akut kenarlı konfigürasyonlar için merdivenlenmiş bir yaklaşım çok ince ızgara genişliği gerektirebilir. Bu ise problemin hesap büyüklüğünü çok fazla artırabilir. Bu problemi çözebilmek için dikdörtgen olmyan elemanlar kullanan yüzeye uyumlu FDTD teknikleri geliştirilmiştir. Bu tekniklerden en gelecek vadedeni FVTD (sonlu hacim zaman boyutu) olarak ızgaradaki herbir

elemanın herhangi bir şekli alabildiği bir metot olarak geliştirilmiştir (EM Wavetracer).

Frekans boyutu sonuçları zaman boyutu sonuçlara kesikli Fourier dönüşümü uygulanarak elde edilebilir. Bu ilave hesap gerektirir fakat sistemin dürtü cevabı dönüştürülerek geniş bantlı bir frekans boyutu analizi elde edilebilir.

FDTD ve FVTD metotları çok geniş EM modelleme problemlerine uygulanmakla birlikte en geniş olarak radar kesit analizlerinde kullanılmaktadır. En büyük avantajları esnek oluşlarıdır. Rastgele sinyal dalgaları karmaşık iletken, dielektrik ve kayıplı doğrusal olmayan izotropik olmayan madde konfigürasyonları boyunca yayılırken modellenenebilir. Bu tekniklerin bir başka avantajı paralel bilgisayar sistemleri üzerinde uygulanabilir olmalarıdır, özellikle vektör işlemciler ve SIMD makinaları üzerinde.

Wavetracer firması EM modelleme için paralel bilgisayarlar ve FDTD yazılımları satmaktadır. Lawrence Livermore (Associated Western University Summer Graphics Project) ve Boston Üniversitesi (Hohlfeld, R.G., 1991) Bağlı makinalar (connection machine) üzerinde FDTD algoritmaları çalıştırmışlardır. Bu uygulamalar EM dalgalarının çok çeşitli konfigürasyonlar içerisinde ve dışarısında yayılırken canlı grafik animasyonlarını göstermek için kullanılmışlardır.


Bu tekniğin tek önemli dezavantajı problem büyüklüğünün bazı konfigürasyonlarda kolaylıkla elden çıkmasıdır. Izgaranın inceliği genellikle modellenmesi gereken en küçük nitelikler tarafından belirlenmektedir. Izgaranın hacmi ise tüm nesneyi ve yakın alanın çoğunu kaplayacak şekilde büyük olmalıdır. Küçük ve karmaşık geometriler içeren büyük nesneler büyük ve ince ızgaralar gerektirebilir. Bu durumda diğer sayısal teknikler FDTD veya FVTD metotlarından çok daha verimli olabilir.

4. ARAŞTIRMA BULGULARI VE TARTIŞMA


4.1. FDTD Benzetimlerinde Veri Dışdeğerlemesi

4.1.1. Yapay Sinyal Üzerinde Uygulama

Çalışmanın ilk aşamasında alışıl gelmiş olmayan ve doğrusal olmayan bir metot olan MLP'nin, kesintiye uğramış olan yapay sinyalleri tahmin etmekteki başarısı doğrusal bir metot olan sinyalin karmaşık sinüzoidlerden oluştuğunu varsayan ve katsayı kestiriminde MPM kullanan bir model ile karşılaştırılmaktadır. Kullanılan yapay sinyal yapı olarak FDTD sinyallerine benzeyecek şekilde superpoze edilmiş belli sayıda rastgele sönümlenen sinüzoidlerden oluşturulmuştur.




Şekil 4.1. Sinyalin %16'sından sonraki kısmının çıkartıldığında MPM dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal ise kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir.



Şekil 4.2. Sinyalin %16'sından sonraki kısmının çıkartıldığında MLP dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir.


Çalışmada kullanılan MLP mimarisinde 6 nörondan oluşan bir giriş katmanı, 8 nörondan oluşan bir gizli katman ve geciktirilmiş girdi zaman serisi penceresi olan girdiyi bir sonraki zaman adımı olarak çıktı veren bir nöronlu bir çıktı katmanı vardır. Gizli katmandaki nöronlar tanjant sigmoid transfer fonksiyonuna sahipken çıktı katmanında doğrusal transfer fonksiyonu kullanılmıştır. Ağ kalan sinyal üzerinde uyarlanabilir olarak geriyealım algoritması kullanılarak eğitilmiştir. Daha sonra bir adımlık tahminler şeklinde sinyalin gerisini oluşturmaktadır.



Şekil 4.3. Sinyalin %32'sinden sonraki kısmının çıkartıldığında MPM dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal ise kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir.

Çizelge 4.1. Tahmin hatalarının karşılaştırılması (% RMS)

Metot\Çıkarım noktası (%)	16	32
MLP (%)	4.02	545.58
MPM dışdeğerlemesi (%)	0.05	1.12



Şekil 4.4. Sinyalin %32'sinden sonraki kısmının çıkartıldığında MLP dışdeğerlemesi. Gerçek sinyal düz, tahmin edilmiş sinyal kesikli çizgiyle temsil edilmiştir. Dikey çizgi çıkartılan kısmın başladığı yeri gösterir.

Matris Pencil Metodu sistemin bir dürtüye erken zaman cevabını kullanarak sistem tanımlaması yapan bir metottur (Sarkar vd., 1995). Bu cevaptan elde edilen veri iki matrise uydurulur ve genelleştirilmiş bir özdeğer problemi oluşturulmak üzere birleştirilir. Daha sonra bazı manipülasyonlardan ve daha önce bulunan özdeğerlerden yola çıkarak sistem gerçek ve sanal kısımları sağlanan karmaşık üsteller toplamı olarak temsil edilir. Metot kendi kendine uyarlanabilir değildir fakat pratikte matrislerden çıkarılan özdeğerlerin sayısında bir sınır yoktur.

MLP'nin diğer doğrusal metotlara olan bir üstünlüğü uyarlanabilir olmasıdır ve gözetim gerektirmemesidir. MLP FDTD ile ya eğitim tatmine ulaşınca ya da sinyal istenen frekans bant genişliğini içerinceye kadar paralel olarak çalışma kapasitesine sahiptir.

İki metodun sinyalin iki farklı uzunlukta kesildiği durumlardaki tahmin sonuçları Şekil 4.1 ve 4.4 arasında görülmektedir. Şekil 4.1 ve 4.2 sinyalin ilk %16'sını kullanarak MLP ve MPM yoluyla oluşturulan sinyalleri gösterirken Şekil 4.3 ve 4.4 sinyalin ilk %32'sini kullanarak oluşturulan sinyalleri göstermektedir. MLP'nin kısa kesimde (%16) çok daha iyi sonuç verdiği çok açıktır. Daha uzun kesimlerde (toplam sinyalin %32'si) her iki metod da iyi sonuç vermiştir fakat MLP daha az hataya sahiptir. İki metoda ait yüzde RMS tahmin hataları Çizelge 4.1'de görülmektedir.

4.1.2. Öğrenme ve Parametre İlk Değerlerinin Atanması

Geri yayılım şeklindeki öğrenme ve diğer kılavuzlu öğrenmelerde dinamik bir modelleyicinin çıktısı istenen çıktıyla karşılaştırılır ve ağ değişkenleri elde edilen masraf fonksiyonu ile karşılaştırılarak eniyelenir. Yapay sinir ağı büyük ihtimalle herbiri çok farklı sistemleri temsil eden ve aynı eğitim verisine karşılık gelen birden çok optimaya sahiptir. En verimli çözüm gibi görünen evrensel en düşük çoğu pratik durumda en etkili çözüme karşılık gelmez çünkü en etkili çözüm olsaydı çözümdeki esnekliği kısıtlardı. Örneğin NN'lerdeki aşırı eğitim durum evrensel en iyi değere karşılık gelse bile genelleştirme kabiliyetini azaltır. 'Genelleştirme' gibi tüm istenen özellikleri numerik değişkenler olarak belirleyip evrensel eniyileme işlemine dahil etmek mümkün olmadığı için bu gibi durumlarla mücadele etmek için farklı bir yaklaşıma ihtiyacımız var olduğu görülmektedir.

Yapay sinir ağları sistemleri modellemede en verimli yöntemler olmayabilir. Fakat etkililerdir çünkü daha önceden bilinen bilgiyi kullanırlar. Bir yapay sinir ağının önceden öğrenmesi ise daha sonraki bir problem için ağırlık ilk değerlerinin atanmasına karşılık gelir. Tipik olarak ağ topolojisinde türev-tabanlı eğitimle ulaşılabilen yerel optimaları içeren bölgelerin varlığı kabul edilirse, bu bölgelerdeki çözümlerin diğer çözümler için ağırlık ilk değerlerinin atanmasında kullanılabileceği varsayılabilir.


Evrensel eniyileme yöntemini kullanan çoğu ters problem yukarıdaki öğrenme paradigmasıyla benzer özelliklere sahiptir ve bu alandaki bir iyileştirme hepsinin sonucunu değiştirecektir.

Önceden eğitim için kullanılan sinyaller NN dışdeğerleyici'nin testinde kullanılan sinyallerle aynı çeşittendir, yani üstel olarak sönümlenen sinüzoidler. Sönümlenme sabitleri ve sinüzoidal frekanslar olan üretici değişkenler Şekil 4.5'de gösterilen önceden kestirilen sinyalin %100 komşuluğunda rastgele başlatılmışlardır. Şekil 4.6 değişmiş sinyallerden bir örnek göstermektedir. Herbir sinyal için başarılı prediktörlere ait topolojiler değiştirilmiş sinyallerin başlangıç eğitim durumu için kullanılmıştır. Sonuçlar başarılı tahminler ve gereken BP algoritması eğitim döngü sayısı bakımından rastgele ilk değer atanması durumuyla karşılaştırılmıştır (Çizelge 4.2).


Sinyaller arasındaki ortalama ortak bilginin iki sinyal için kullanılabilen dışdeğerleyicilerin birbirinin ilk ağırlık değerlerinin atanmasında kullanılıp kullanılamayacağı konusunda iyi bir gösterge olduğu görülmüştür. Sonuçlar rastgele başlatımlara kıyasla kayda değer iyileşmenin olduğunu göstermiştir.

Çizelge 4.2. Tahminlerin karşılaştırılması

Ağırlık ilk değerlerini n atanması	Asıl sinyal ve önceden eğitimde kullanılan sinyal arasındaki ortalama ortak bilgi		Başarılı tahminlerin oranı (%)		Yakınsama için gereken eğitim döngüsü	
	Ortalama	Std. sapma.	Ortalama	Std. sapma	Ortalama	Std. sapma
Önceden eğitimle	5.9	1.8	88	8	90	32
Rastgele	0.001	0.01	6	2	350	180



Şekil 4.5. Dışdeğerleme yapılan sinyallerden bir örnek




Şekil 4.6. Dışdeğerleme yapılan sinyalin değiştirilmiş versiyonu


4.1.3. Kod Uyarlama Problemleri

Kodun farklı zaman adımı hassasiyetine göre uyarlanabilir olması ve aşırı örnekleme iki önemli problemdir. Daha önce yapılan bir çalışma (Ababarnel, H. D. I., 1993) örnekleme hızının adaptasyonunda ortak bilgiyi ve uygun pencere genişliğinin belirlenmesinde yanlış en yakın komşuluk metodunu önermiştir. Bu çalışmada bir değişiklik yapılarak pencere genişliğinin belirlenmesinde de ortalama ortak bilginin kullanılması önerilmiştir. Adımlar:

1. Sinyalin aşırı örneklenmediğine emin olduğumuz bir durum için uygun girdi büyüklüğünün belirlenmesi: Bu amaçla kayan pencereler arasındaki ortalama ortak bilginin pencere genişliğine bağlı grafiğindeki ilk en düşük noktayı aldık. Bu bizim sinyallerimiz için 6 nöron'a karşılık gelmektedir (Şekil 4.7).
2. Optimal ağ topolojisinin bulunması: Bu genişletme metodu kullanılarak gerçekleştirilmiştir. Ağımız 3 nörondan oluşan bir gizli katmana sahiptir. İleribeslemeli bir ağ mimarisi seçtik. Bunun sebebi bir önceki bölümde belirtilen eğitim analizleri için daha uygun olduğudur.
3. NN'ün eğitim algoritmasıyla eğitilmesi (Geri yayılım algoritması).
4. Yeni bir sinyal için kayan pencereler arasındaki ortalama ortak bilginin örnekleme hızına bağlı grafiğindeki ilk en düşük noktaya göre yeniden örneklenmesi (Şekil 4.8).




Şekil 4.7. Kayan pencereler arasındaki ortalama ortak bilgi ve pencere genişliğine bağlı grafiği




Şekil 4.8. Kayan pencereler arasındaki ortalama ortak bilginin örnekleme hızına bağlı grafiği

4.1.3.1. Sinüs Dalgasına Uygulama




Şekil 4.9. Saf sinüs dalgası ve ortalama ortak bilginin pencere genişliğine bağlılığı



Şekil 4.10. Üç kez fazla örneklenmiş olarak 4.9 grafiğinin aynısı

Genellikle olduğu gibi gradyana bağlı basit bir eniyileme kullanıldığı zaman kayan pencereler arasındaki ortalama ortak bilginin pencere genişliğine veya örnekleme hızına bağlı grafiğinin ilk en düşük nokta optimayı verecektir.


Kullanılan yöntem yani hem pencere genişliğinin hem de örnekleme frekansının kayan pencereler arasındaki ortalama ortak bilgi ile belirlenmesi varsayımımızı test etmek için bilinen saf sinüs dalgası üzerinde test yapıldı. Şekil 4.9’da örneklenmiş saf sinüs dalgası ve ona karşılık gelen ortalama ortak bilginin pencere genişliğine bağlılığı grafiği verilmiştir. Görüldüğü üzere ortalama ortak bilginin en düşük noktası sinüs dalgasının dalga boyunun yarısındaki noktaya denk gelmektedir. Daha sonra örnekleme frekansının eniyilemesi için Şekil 4.10’da aynı sinüs dalgası üç kat hız ile örneklenmiş ve ortalama ortak bilginin örnekleme frekansına göre çizimi yapılmıştır (Şekil 4.11). Görüldüğü üzere ilk en düşük değer 3’e denk gelmektedir bu ise bizim fazladan örneklemiş olduğumuz frekansı göstermektedir. Yani sinüs dalgası hem örnekleme frekansı hem de pencere genişliğinin eniyilenmesinde kullanılabilecek bir hedef fonksiyonudur.




Şekil 4.11. Kayan pencereler arasındaki ortalama ortak bilgi ve örnekleme hızı

4.1.4. Gerçek Sinyal Üzerinde Dışdeğerleme

Şekil 4.12 gerçek simülasyondan elde edilen zaman serisini ve MPM dışdeğerlemesi ile bulunan en iyi kesim noktası göstermektedir. Şekil 4.13’de ise özgün sinyal ve oluşturulan sinyaller frekans uzayında karşılaştırılmaktadır. Hata oranı gerçek sinyal ortalamasına göre %1’in altında ve bu dışdeğerleme başarısı ümit vericidir.



Şekil 4.12. Özgün ve kesilmiş dalga formları



Şekil 4.13. Özgün (mavi)ve oluşturulmuş (kırmızı) sinyallerin frekans boyutunda karşılaştırılması

4.2. Elektromanyetik Kaynak Tanıma


4.2.1. STFT Metodu

Şekil 4.14 Missouri Üniversitesi Automotive EMC laboratuvarındaki çevre gürültü alanlarının kısa vadeli FFT çizimini göstermektedir. Yatay eksen zamanı (0 – 0.1 ms) ve dikey eksen frekansı (0 – 250 MHz) göstermektedir. 100 MHz yakınındaki üç yatay çizgi FM radyo istasyonlarıdır. 10 MHz yakınındaki koyu bant belirlenemeyen geçici gürültü kaynağıdır. Bazı çevre ölçülerinde görülmekle birlikte hepsinde yoktur. Başka frekanslardaki daha silik yatay çizgiler ve 10 MHz'deki sıçramalar serisi odadaki elektronik aletlerden ve tespit edilemeyen gürültü kaynaklarındandır.

Şekil 4.15 ise 2003 Cadillac marka bir otomobilin rolantide çalışırken varlığında aynı yerdeki alanların kısa vadeli FFT çizimini göstermektedir. Çizimdeki dikey çizgi ise


ateşleme kıvılcımından dolayıdır. Farklı otomobillerde alınan ölçümlerde bu ateşleme kıvılcımının spektrumu ve süresi değişiklikler göstermiştir.

Laboratuvardaki alan ölçümleri otomobil varken ve yokken farklı zamanlarda muhtelif günler boyunca ölçülmüştür. Toplam 400 veri kümesi toplanmış ve her küme için veriler 155 parametreye düşürülmüştür. Bu parametrelerin boyutu PCA yardımıyla düşürülmüş ve MLP yapay sinir ağı yardımıyla analiz edilmiştir. Eğitim ve test “birini dışarıda bırak” yöntemiyle yapılmıştır. Yani verilerden diğerleriyle eğitilirken kalan bir tanesi test için kullanılarak bu döngü sürdürülmüş dolayısıyla hem eğitim hem test için 400 veri kullanılmıştır.




Şekil 4.14. Otomobil EMC laboratuvarındaki çevre gürültüsünün kısa-vade FFT çizimi

Yapay sinir ağının ateşlemenin varlığında ölçümü farketmesine şaşırmamakla birlikte ölçüm için zaman penceresinin 0.1 ms olurken ateşleme işaretinin ortalama 12 ms’de bir oluştuğunu hesaba katmak gerekir. Dolayısıyla motor çalışırken alınan verilerin çoğu ateşleme işareti içermemekteydi.



Şekil 4.15. Otomobil rolantide çalışırkenki alanın Kısa-vade FFT çizimi



Şekil 4.16. Otomobil rolantide çalışırkenki STFT çizimi (ateşleme işareti yokken)

Şekil 4.16 motor çalışırken fakat ateşleme işaretinin olmadığı bir ölçümün kısa vade FFT çizimini göstermektedir. Bu çizim odadaki gürültü ölçümlerindeki çizimlere çok

benzemesine rağmen yapay sinir ağı çevre gürültüsü ve arabadan yayılan gürültü arasındaki farkı %100 tutarlılıkla ayırt etmiştir. Bu çevre gürültüsünde ve otomobilin gürültüsünde zamanla çok farklı değişimler olmasına rağmen doğru çıkmıştır.

Bu başlangıç sonuçları bu tekniğin farklı otomobillerin EM yayımlarından tanınması için ümit verici bir teknik olduğunu göstermiştir. Benzer bir işlem daha başka EM kaynaklarının varlığını gürültünün varlığında bile kullanılabileceği görülmektedir.

Çizelge 4.3. STFT dönüşümünden çıkarılan istatistiksel değişkenler kullanılarak yapılan sınıflandırma başarıları

Kullanılan değişken seti	PCA'dan sonraki değişken sayısı Bu aynı zamanda girdi katmanının genişliğini göstermektedir.	En iyi gizli katman genişliği	En iyi tanıma yüzdesi
DEĞ 4, 5	9	5	94
DEĞ 5	10	3	86
DEĞ 4	10	3	80
DEĞ 3	3	5	77
DEĞ 2	7	5	80
DEĞ 1	6	3	99
DEĞ 1, 4, 5	8	4	98
DEĞ 1, 5	6	4	99
DEĞ 1, 2	8	4	85
DEĞ 3,4, 5	8	4	80
DEĞ 1,2,4,5	8	4	87

Çizelge 4.4. STFT dönüşümünden çıkarılan istatistiksel değişkenler kullanılarak iki kademeli sınıflandırma sonuçları


Kullanılan değişken seti	PCA'dan sonraki değişken sayısı Bu aynı zamanda girdi katmanının genişliğini göstermektedir.	En iyi gizli katman genişliği	En iyi tanıma yüzdesi
TÜMÜ	7	1	100
DEĞ 1	6	1	98
DEĞ 2	7	1	75
DEĞ 3	3	3	74
DEĞ 4	10	1	98
DEĞ 5	10	3	95

4.2.2. Dalga Paketçisi Metodu

Şekil 4.4., 4.5., 4.6. ve 4.7. WP ayrışım sonuçlarından üç örnek sunmaktadır.


Gürültü giderme sonuçların görsel ayırt edilmesinde yardımcı olmamıştır. Dolayısıyla eğer gürültü giderme yapılmadan önceki nitelik vektörlerinden işlemsel tanıma başarıya ulaşırsa gürültü gidermeye gerek yoktur (ki öyle olmuştur). Bu nedenle gürültü gidermede potansiyel bilgi kaybı da önlenmiştir.

Bir imgenin enerjisi o imgedeki tüm noktaların karelerinin toplamı ile ifade edilmektedir. Şekillerden görüldüğü üzere optimal ağaç sinyalden sinyale farklılık göstermektedir. Bu demektir ki her ölçüm için standart ölçüde olması gereken nitelik vektörünün optimal ağaç yardımıyla çıkarılması anlamlı değildir. Bunun yerine normal nitelik vektörlerinin dönüşümü için PCA kullanılması ve dolayısıyla nitelik vektörlerinin ilintisiz olması daha uygun bir yöntemdir. Buna ek olarak sadece verideki toplam varyasyona %2 nin üzerinde katkısı olan veriler tutulmuş ve böylece veri boyutu küçültülmüştür. Sonuç vektörler sadece 3 bileşene sahiptir.




Şekil 4.17. Araç 1 için WP ağacı ve alt imgeleri

Dolayısıyla MLP girdisi 3 genişliğindedir ve çıktı olarak veri sınıfının numarasını vermektedir. Yapay sinir ağı 1 gizli nöron sahibi olan en basit mimari ile başlatılmış ve %100 başarı sağlayarak ağı daha fazla büyötmeye gerek bırakmamıştır.



Şekil 4.18. Çevre Gürültü Sinyali için WP ağacı ve alt imgeleri



Şekil 4.19. Araç 2 için WP ağacı ve alt imgeleri

Çizelge 4.5. WP alt imge enerjileri kullanılarak yapılan sınıflandırma başarısı

Kullanılan değişken seti	PCA'dan sonraki değişken sayısı Bu aynı zamanda girdi katmanının genişliğini göstermektedir.	En iyi gizli katman genişliği	En iyi tanıma yüzdesi
15	3	1	100

4.2.3. Olasılıklı Yapay Sinir Ağları Sınıflandırması

MLP ile yapılan sınıflandırmalarda sadece kıvılcım içeren sinyal pencereleri hesaba katılmıştı. Şimdi ise PNN kullanarak kıvılcım varken ve yokken elde edilen sınıflandırma sonuçların ayrımını görelim.

Çizelge 4.6. PNN Kullanılarak yapılan sınıflandırma sonuçları

Kullanılan değişken seti	En iyi tanıma yüzdesi	
	Kıvılcım varken	Kıvılcım yokken
DEĞ 1	100	55
DEĞ 2	93	86
DEĞ 3	100	82
DEĞ 4	92	55
DEĞ 5	93	55
WP	100	88

Bu sonuçlar PNN sınıflandırma başarısını ortaya koyarken kıvılcımın da sınıflandırma başarısını olumlu etkilediğini göstermektedir.

4.3. Düşük Güç Tasarımı

Düşük güç için devre eniyilemesi metodumuzu ISCAS'85 benchmark devrelerinden bazılarına uyguladık. Ortalama güç azaltılması %26.2 iken pil boşalma zamanındaki artma ortalama %28.6 olmuştur. P4 işlemcinin kullanıldığı simülasyonlarda hedef fonksiyonu olan P/T_d ortalama %31.2 iyileşmiştir. Kapı ebatlandırmanın masraf fonksiyonunu eniyilemede en etkili yol olduğunu ve onu takiben de sırayla V_{dd} azaltımının ve eşik potansiyelini azaltmanın etkili olduğu tespit edilmiştir. Fakat anahtarlama faaliyetinin azaldığı durumlarda kayıp güç toplam güç harcamasında dominant duruma geçer ve böylece eşik potansiyelini artırmak güç tasarrufunda besleme potansiyelini azaltmaktan daha etkin hale gelir.


Çizelge 4.7. % olarak VFSR sonuçları

Örnek	Güç Azalması (%)	T_d artması (%)	P/T_d iyileşmesi (%)
C17	14.6	15.5	16.5
S27	18.2	19.1	20
B01	38.1	45.4	53.5
B02	33.7	34.2	34.8
Ortalama	26.2	28.6	31.2


4.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları

4.4.1 İş Yüğü ve Uzunluğunun Etkisi


Yapılan Monte Carlo Benzetimleri eniyilemedeki farkları ortaya koymaktadır. Şekil 4.23, 4.24 ve 4.25 farklı c ve s değerleri için enerji eniyilendiği zaman P_{max} 'taki hata dağılım grafiklerini ortaya koymaktadır. Görüldüğü üzere hata %16'ya kadar çıkmaktadır. Bu ise $s=\{1,2\}$ ve $c=\{1,2\}$ olduğu durumdur. Ara değerlerde hata biraz daha düşmektedir. En yüksek sıcaklıktaki hata ise %18'e kadar çıkmaktadır.




Şekil 4.23. Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,5\}$ ve $c=\{1,2\}$) Yatay eksen normal toplam esnekliği göstermektedir.



Şekil 4.24. Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=\{1,2\}$). Yatay eksen normal toplam esnekliği göstermektedir.




Şekil 4.25. Enerji masraf fonksiyonu iken $P_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=(1,2)$). Yatay eksen normal toplam esnekliği göstermektedir.



Şekil 4.26. $P_{\max}$ masraf fonksiyonu iken $T_{\max}$ daki hata yüzdesi ($s=\{1,2\}$ ve $c=(1,2)$). Yatay eksen normal toplam esnekliği göstermektedir.


4.4.2 Çoklu Amaç Fonksiyonu Kullanmanın Etkisi

Sıcaklık eniyilemesinde pencerelerde sadece $T_{\max}$ masraf fonksiyonu olarak alındığı zaman Şekil 4.27’de görüldüğü üzere sıcaklık eniyilemesi bazen enerji ve $P_{\max}$ eniyilemesine göre kötü olabilmektedir.




Şekil 4.27. $T_{\max}$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ ’ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.

Halbuki $T_{\max}+T_{\text{son}}$ masraf fonksiyonu olarak alındığı zaman Şekil 4.28’de görüldüğü üzere sıcaklık eniyilemesi her zaman enerji ve $P_{\max}$ eniyilemesinden farklı bir şekilde daha iyi olmaktadır. Bunun sebebi her pencereadaki T_{son} parametresinin kayan pencerelerde bir sonraki pencereye devredilmesidir.



Şekil 4.28. $(T_{\max}+T_{\text{son}})$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ 'ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.


4.4.3 Isınma Soğuma Katsayılarının Etkisi




Şekil 4.29. $(T_{\max}+T_{\text{son}})$ veya $P_{\max}$ veya enerji en iyi iken $T_{\max}$ 'ın gelişimi. Koyu renkteki çizgi $T_{\max}$ masraf fonksiyonunun etkisini ve yatay eksen geçen adım sayısını göstermektedir.

Şekil 4.29 Isınma soğuma katsayısı Şekil 4.28’dekine göre 100 kat düşürüldüğü yani ısıma ve soğumanın işlemci hızına göre yavaş olduğu durumdaki değişimi göstermektedir. İşlemci hızının ne kadar yüksek olduğu hesaba katılırsa katsayıları düşürmenin ne kadar gerçekçi olduğu ve sonuçların uzun dönemde sıcaklık eniyilemesinde ne kadar etkili olduğu gözükmemektedir.


Şekil 4.30 ila 4.33 arasında farklı ısınma soğuma katsayılarının etkisinde güç ile sıcaklığın nasıl farkettiğini göstermektedir. Gerçekçi olmayan yüksek soğuma ısınma katsayıları durumunda sıcaklık güç ile aynı olmaktadır. Dolayısıyla P_{max} eniyilemesi bu durumda sıcaklık eniyilemesinden farklı beklenmemelidir. Fakat gerçekçi olan katsayıların düşürülmesiyle sıcaklığın güçten ne kadar farklılaştığı şekillerden gözükmemektedir.




Şekil 4.30. P(t) ve T(t) (P_{av} eniyilenince) ($K=1/10$)




Şekil 4.31. P(t) ve T(t) (P_{av} eniyilenince) ($K=1/25$)



Şekil 4.31. $P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/50$)



Şekil 4.32. $P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/100$)



Şekil 4.33. $P(t)$ ve $T(t)$ (P_{av} eniyilenince) ($K=1/1000$)

5. SONUÇ

5.1. FDTD Benzetimlerinde Veri Dışdeğerlemesi

Çalışmanın bu kısmı literatürde daha önce yapılmış yalnızca bir adet çalışmaya oldukça önemli bir yenilik getirmiştir. Kısa vadeli önkestirimde MLP'nin FDTD tipi sinyaller için gürültü olmadığı durumlarda potansiyel olarak iyi bir uyarlanabilir dışdeğerleyici olduğu görülmektedir. MLP'nin giriş genişliğinin ve mimarisinin farklı zaman adımı hassasiyetlerine ve sinyal çeşitlerine uyarlanabilir hale getirilmesi için geliştirilen entropi istatistiğine dayalı yöntem oldukça başarılıdır.

Çalışma kısa vadeli veya yerel önceden tahmini uzun vadeli veya evrensel tahmin ile de karşılaştırmaktadır. Ve kısa vadeli tahmin yönteminin eğitim verisinin zamansal uzunluk bakımından kısa olması ve gürültü olmaması durumunda uzun vadeliden daha iyi sonuçlar verdiğini ve evrensel olarak yakalanamayan özelliklerin yerel olarak yakalanabilirliğini ve bunların tekrar evrensel sinyali tekrar oluşturmakta kullanılabileceğini göstermektedir. Gürültülü gerçek sinyallerde ise MPM yöntemi daha kararlı sonuçlar vermektedir.

Bu çalışma baz alınarak bazen haftalar sürebilen FDTD yöntemleri daha kısa sürelerde gerçekleştirilebilecektir.

5.1.1. Eğitim Problemleri

Çalışmanın başında FDTD tipi sinyallerin dışdeğerlemesinde kullanılan yapay sinir ağlarının eğitilmesindeki ağırlık ilk değerlerinin atanması problemi için önerilen çözüm de oldukça umut verici sonuçlar vermiştir. Aynı sınıfa mensup farklı sinyallerden elde edilen başarılı dışdeğerleyicilerin topolojisini kullanan bu ağırlık başlatma işlemi dışdeğerleme başarı hızını ve öğrenme hızını artırmaktadır. Bu metodun başka sinyal sınıflarına veya sistemlere genişletilmesi daha fazla çalışma sonucu ortaya çıkarılabilecek bir sonuçtur. Sonuçlara göre sinyaller arasındaki ortalama ortak bilgi bir sinyal için kullanılan dışdeğerleyici'nin başka bir sinyal için

kullanılıp kullanılamayacağını belirlemekte de kullanılabilir. Ayrıca ortalama ortak bilgi zaman boyutundaki sinyallerin örneklenme hızına ve bu sinyallerde kullanılacak kayan pencere NN dışdeğerleyicilerinin pencere genişliğinin belirlenmesinde kullanılabilecek iyi bir karar parametresidir. Farklı sinyallere genişletilmesi için ek çalışmalar gerekebilir.

5.1.2. Kod Uyarlama Problemleri

Örnekleme hızı önerilen metotla uyarlanabilir olarak eniyilenebilecektir. Pencere genişliği pencerenin boyutunu göstermektedir. Çoğu durumda ekipman veya metottan dolayı bu boyut önceden bellidir, örneğin bir NN veya başka bir uyarlanabilir dışdeğerleyici bilinen bir girdi boyutuna sahiptir. Dolayısıyla sinyalin örnekleme frekansı kayan pencereler arasındaki ortalama ortak bilgiyi performans ölçüsü olarak kullanarak eniyilenebilir.

En genel yaklaşım pencere genişliği ve örnekleme frekansını iki boyutlu uzay olarak alıp bu uzayda kayan pencereler arasındaki ortalama ortak bilgi yüzeyinin evrensel en düşük değerini bulmaya yönelik bir arama gerçekleştirmek olacaktır. Gradyan tabanlı bir aramada bulunabilecek ilk belirgin en düşük değer de optimal pencere genişliğini ve örnekleme frekansını verecektir. Bu iki faktörden herhangi birisinin önceden belirli bir kısıtlaması olduğu takdirde en iyi için yapılacak arama doğrudan bir boyuta inecektir. Genellikle optmanın bulunması için doğrusal türev tabanlı bir arama metodu yeterli olacaktır. Fakat ekstrem durumlarda VFSR veya GA gibi bir evrensel eniyileme metodu gerekebilir.

5.2. Elektromanyetik Kaynak Tanıma

Elektromanyetik kaynak olarak otomobillerin yaydığı yayımlar kullanarak tanınması ve sınıflandırılması konusunda literatürdeki ilk çalışma olan bu tez MLP ve PNN kullanarak %100'e varan tanıma başarısı elde ederek büyük bir başarı kaydetmiştir. WP Ayırımıyla elde edilen alt imgelerin enerjilerinin, EM sinyallerin tanımlanmasında çok uygun bir nitelik vektörü olduğunu göstermiştir.

Spektral analiz yönteminde elde edilen daha düşük tanıma başarılarıyla kıyaslandığı zaman WP'nin araç yayım sinyallerini spektral metotlardan daha iyi temsil edebileceğini ortaya koymaktadır. Bu da spektral metotların zaman boyutunda belirsiz oluşundan kaynaklanmaktadır. WP Ayırışımı istenen frekans aralığında istenildiği kadar çözünürlük sağlanabildiği için sinyal işleme için çok uygun ve uyarlanır bir yöntem sunmaktadır.

PCA tarafından veri boyutunun çok büyük bir yüzdeyle küçültülmesi alt imgelerdeki enerjilerin birbirinden çok bağımsız olmadığını göstermektedir. Çok uzun sinyallerin boyutunun WP yardımıyla oldukça düşürülmesi ve daha sonra da gerektiği yerlerde PCA ile daha da düşürülmesi ve bunun %100 tanıma başarısı sağlaması bu çözüm sırasının bu problem için çok uygun olduğunu ortaya koymaktadır.

Sonuç olarak WP Ayırışımı çok verimli bir nitelik çıkarma metodudur. MLP ve PNN araçların EM ışınlamaları kullanarak tanınması ve sınıflandırılmasında kullanılabilir. Ayrıca MLP ve PNN'in bir ilişkideki tekil değişkenlerin etkilerinin araştırmasında kullanılabileceği gözükmemektedir.

Ayrıca bu yöntemle gösterilen arabaların elektromanyetik tanınması güvenlik ağırlıklı olarak uygulamaya konulabilir. Görüntü almaya gerek duyulmadan araçlar tanınabilir. Araçların düşük güçle içerisindeki canlılara zarar vermeden durdurulması güvenlik açısından çok önemli bir uygulamadır. Çalışmada elektronik yayımları gösterilen gömülü mühimmatın farklı tiplerine de uygulanarak insancıl mayın temizlemede kullanılan bir sistem haline getirilmesi insanlığa büyük bir katkı sağlama potansiyeline sahiptir.

5.3. Düşük Güç ve Sıcaklık Tasarımı

Çalışmanın bu kısmında VFSR metodu kullanılarak güç tüketiminin endüşüklenmesi ve pil yük sığasının enyükselenmesine dayalı en iyi besleme ve eşik potansiyellerinin ve aygıt büyüklüğünün belirlenmesi yaklaşımı yapılmıştır.

Bu konuya yakın konularda her ne kadar daha önce çalışılmış ve halen de çalışılmakta olsa da güç tüketimi ve pil boşalma zamanını aynı anda eniyilemesi açısından bu çalışma ilktir.

VFSR'nin birden fazla eniyileme parametresinin bulunduğu ve kapılar arasında zamanlama bağımlılığı bulunan kapı seviyesi eniyileme problemleri için çok uygun olduğu görülmektedir. Amaç fonsiyonu güç eniyilemesinin pil yükleme zamanının enyükseklenmesi anlamına gelmediği için P/T_d olarak seçilmiştir.

Dinamik gücün kaçak güçle yakın etkilere sahip olduğu durumlarda güç azaltmanın en iyi yolunun kapı ebatlama olduğu sonucuna varılmıştır. Gücün eniyilemesi ve pil boşalma zamanının enyükseklenmesi açısından ikinci derecede etkili tasarım parametresi ise besleme potansiyelinin düşürülmesidir. Fakat bu sonuç kayıp gücün devredeki toplam güç tüketiminde dominant hale gelmesi durumunda değişecektir. Böyle bir durumda güç düşürümü için en etkili yol ise gecikmenin eşik potansiyelleri ile değiş tokuş edilmesi olacaktır.

Tümdevrelerin her alana girdiği ve bilgisayar teknolojilerinin büyük hızla ilerlediği günümüzde güç tüketimi ve pil boşalma zamanının birlikte eniyilenebilmesi teknolojiye katkıda bulunacaktır. Bu bölümde yapılan çalışmalar tümdevre dizayn ve eniyilemesi için bir alet kutusu haline getirilerek endüstriyel uygulamaya dökülebilir.

5.4. Dinamik Voltaj Ölçeklemesinde Sıcaklık, Enerji ve En yüksek Güç Eniyileme Farkları

İşlerin güç profilinin önceden bilindiğini varsaymıştık. Ayrıca işlevsel birimlerin anahtarlama faaliyet oranlarının en yüksek 2 olduğu gibi tutucu bir varsayım yapmaktayız.

Bu durumda bile enerji ve en yüksek güç eniyilemesi arasında %16'yı bulan bir hataya ulaşmaktayız. Sıcaklık gücün bir fonksiyonudur ve sıcaklığın, enerji veya en yüksek güç eniyilendiği zaman, en iyi değerinden %18 sapma gösterdiğini bulduk.

Mikroçiplerin termal özelliklerinin eniyilemedeki etkisini de inceledik. Mikroçipin sıcaklık hassasiyeti yüksek olduğu zaman (iş zamanına göre hızlı ısınıp soğuyunca) en yüksek güç eniyilemesinin sıcaklık düşürümünde oldukça iyi olduğu görülmüştür. Diğer tarafta mikroçipin sıcaklık hassasiyeti yüksek olduğu durumda yani yavaş ısınıp soğuyorsa sıcaklık eniyilemesinin sıcaklık düşürme bakımından en iyi yol olduğu görülmüştür.

İşgücü değişimlerinin arttığı durumlarda sıcaklık eniyilemesinin ne kadar etkilendiğini de inceledik. Fonsiyonel blokların anahtarlama kapasite oranlarının en yüksek 5 kat değişmesi durumunda enerji veya en yüksek güç eniyilendiği zaman sıcaklık en iyi değerinden %18 sapmaktadır. İş değişimleri arttıkça üç amaç fonksiyonunun (enerji, en yüksek güç ve sıcaklık) en iyi değerleri daha da farklı olmaktadır. Başka bir deyişle bir değerin eniyilenmesi diğerinde daha fazla hataya yol açmaktadır.

Tüm bu sonuçlar şimdiye kadar enerji eniyilemesinin veya en yüksek güç eniyilemesinin aynı zamanda sıcaklık eniyilemesi anlamına geldiği varsayımlarının doğru olmadığını göstermiştir. Her üç değerin ayrı ayrı eniyilendiği konfigürasyonların birbirinden ne kadar farklı olduğu ortaya konmuştur.

Ayrıca kayan pencereler yöntemiyle yapılan Monte Carlo Benzetimlerinde eniyileme hedef fonksiyonu olarak pencerelerdeki en yüksek sıcaklık yerine en yüksek sıcaklıkla penceredeki son sıcaklığın toplamını almanın çok daha iyi ve kararlı sonuçlar verdiği görülmüştür. Bu da çok amaçlı eniyileme problemlerine güzel bir örnektir ve zaman boyutunda sıcaklık gibi önceki değerlere bağlı gelişen sinyallerin analizinde seçilecek masraf fonksiyonlarının belirlenmesinde yol gösterebilecek güzel bir uygulama olmuştur.

6. KAYNAKLAR

- Aarts, E., ve Korst, J., 1989. Simulated Annealing and Boltzmann Machines, John Wiley and Sons, 284s.
- Ababarnel, H. D. I., Brown, R., Sidorowich, J. L., Tsimring, L. S., 1993. The analysis of observed chaotic data in physical systems. Rev. of Modern Physics. Vol. 65, 1331-1392
- Aktaş, K. ve Göksu, H., 2005. Machine Vision for Object Tracking and Obstacle Identification. SUSSP-05, St. Andrews, UK
- Arnéodo, A., Bacry, E., ve Muzy, J. F., 1995. Physica A, 213, 232
- Augsburger, S., Nikolij, B., 2002. Reducing power with dual supply, dual threshold, and transistor sizing. Proc of Int. Conf. on Comp. Design. (2002) 316–321
- Aunchaleevarapan, K., Paithoonwatanakij, K., Prempreaneerach, Y., Khan-ngern W., ve S. Nitta, 2000, Classification of PCB configurations from Radiated EMI by Using Neural Network, CEEM' 2000, Shanghai, China, 105-110.
- Bansal, N., Dynamic Speed Scaling to Manage Energy and Temperature, 2004, Proceedings of the 45th Annual Symposium on Foundations of Computer Science (FOCS'04)
- Bavier, A.C., Montz, A.B., ve Peterson, L.L. , 1998, Predicting MPEG execution times, Proceedings of ACM SIGMETRICS'98, 131–140
- Boltzmann, L., 1877, Ueber die Beziehung eines allgemeine mechanischen Satzes zum zweiten Hauptsatzes der Warmetheorie. Sitzungsber. Akad. Wiss. Wien, Math.-Naturwiss. Kl. 75, 67-73
- Coifman, R. R., Wickerhauser, M. V., 1993. Wavelets and Adapted Waveform Analysis- A Toolkit for Signal Processing and Numerical Analysis. Computer program and book, Massachusetts: A.K. Peters
- D' Amore, M., Morriello, A., ve Sarto, M.S., 1998, A Neural Network Approach for Identification of EM Field Sources: Analysis of PCB Configurations, 1998 IEEE Int. Symp. Electromagn. Compat. 664-669.
- Daubechies I, 1992. Ten Lectures on Wavelets 61 CBMS-NSF Regional Conference Series in Applied Mathematics (Philadelphia: SIAM Press)
- Dudczyk, J. , Matuszewski J. ve Wnuk, M., 2004, Applying the Radiated Emission to the Specific Emitter Identification, 15th International Conference on Microwave, Radio and Wireless Communications, 431-434

- Farge M Goirand E Meyer Y Pascal F and Wickerhauser M V, 1992. Fluid Dynamics Res 10 229
- Flautner, K., Reinhardt, S., ve Mudge, T., 2001, Automatic performance setting for dynamic voltage scaling, Proc. 7th Annu. Int. Conf. Mobile Computing and Networking (MobiCom'01), 260–271.
- Flautner, K., ve Mudge, T., 2002, Vertigo: Automatic performance-setting for linux, Proc. 5th Symp. Operating Systems Design Implementation, 105–116
- Geman, S. ve Geman, D., 1984. Stochastic Relaxation, Gibbs' Distribution and Bayesian restoration of images, IEEE Trans., PAMI 6, 421-741.
- Giuseppe S., 2004. Time Domain Extrapolation and Evaluation of Surface-Mount Component Parasitic Inductance. Yüksek Lisans Tezi. University of Missouri-Rolla, ABD.
- Göksu, H., 2002. Global Optimizasyon Yöntemiyle Elektromanyetik Ters Problem Çözümü. Yüksek Lisans Tezi. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü
- Göksu, H., Pommerenke, D. J., Wunsch, D. C. II., 2003-a. FDTD data extrapolation using multilayer perceptron (MLP). Proc. of the 2003 IEEE International Symposium on Electromagnetic Compatibility, Boston, 735-737
- Göksu, H., Wunsch, D. C. II, 2003-b. Information Theoretical Sliding Window Optimization Applied to Discretization of Continuous Signals. Proceedings of CMDS 10, Continuum Models and Discrete Systems No: 10, Shores, Israel
- Göksu, H., Wunsch, D. C. II., 2003-c. Neural Networks Applied to Electromagnetic Compatibility (EMC) Simulations. ICANN/ICONIP 2003, Istanbul.
- Göksu, H., Hubing, T. H., Beetner, D. G., Wunsch, D. C. II., 2004. Electromagnetic Detection and Identification of Automobiles. EUROEM'04, Germany
- Göksu, H., Pigg, P., Dixit, V., 2005-a. Music Composition Using Genetic Algorithms (GA) and Multilayer Perceptrons (MLP). Lecture Notes in Computer Science, Springer, vol. 3612, 1242-1250
- Göksu, H., Kaya, M. A., Kokce, A., 2005-b. Solution of the Inverse Electromagnetic Problem of Spontaneous Potential (SP) by Very Fast Simulated Reannealing (VFSR) Lecture Notes in Computer Science, Springer, vol. 3611, pp. 618-621

- Göksu, H., 2005-c. Quantum Theory and Interacting Ambiguities. 3rd International Workshop on Pseudo-Hermitian Hamiltonians in Quantum Physics, İstanbul
- Göksu, H., 2005-d. Quantum Logic vs. Ambiguity Logic. NATO ASI: Quantum Computation - Quantum Information, Crete, Greece
- Göksu, H., 2005-e. Electromagnetic Source Identification using MLP. SUSSP-05, St. Andrews, UK
- Göksu, H., 2005-f. Neural Networks Based Sensor Fusion for Autonomous Robot Navigation. NATO ASI Geilo 2005, Norway
- Greene, J.W., ve Spowit, K.J., 1986. Simulated Annealing without rejected moves, IEEE Trans. On Computer-Aided Design, vol. CAD-5, 1, 221-228.
- Gutnik, V. ve Chandrakasan, A. P., 1997, Embedded power supply for lowpower DSP, IEEE Trans. VLSI Syst., vol. 5, 425-435
- Hohlfeld, R. G. , Sparagna, S. M. Ve Sandri, G. v. H. , 1991. Direct Solution of the Wave Equation using Parallel Computational Techniques,” Proc. 7th Annual Review of Progress in Applied Computational Electromagnetics, 203-221.
- Hong, I., Kirovski, D., Qu, G., Potkonjak, M. ve Srivastava, M.-B., 1998, Power optimization of variable voltage core-based systems, Proc. Design Automation Conf., 176-81
- Hua, Y. , Sarkar, T. K. , 1988. Matrix Pencil Method and its Performance,” in Proc. IEEE ICASSP, 2476-2479.
- Hua, Y. , Sarkar, T. K. , 1990. Matrix Pencil Method for Estimating Parameters of Exponentially Damped/Undamped Sinusoids in Noise, IEEE Trans. Acoust. Speech, Signal Processing, Vol. 38, 814-824
- Hung, W., 2004. Total power optimization through simultaneously multiple-Vdd multiple- Vth assignment and device sizing with stack forcing. Proc. of the Int. Symp. on Low Power Electronics and Design.
- IBM PowerPC. [Online]. <http://www.chips.ibm.com/products/powerpc/>
- Ingber, L. , 1993. Simulated annealing: Practice versus theory, Mathl. Comput. Modelling, Vol. 18, Series 11, 29-57.
- Ingber, L., 1989. Very fast simulated reannealing, Mathl. Comput. Modelling, Vol. 12, 967-973.
- Ingber, L., Rosen, B., 1992. Genetic algorithms and very fast simulated reannealing: A comparison, Mathl. Comput. Modelling, Vol. 16, Series 11, 87-100.

- Intel XScale. [Online]. <http://www.intel.com/design/intelxscale/>
- Ishihara, T. ve Yasuura, H., 1998, Voltage scheduling problem for dynamically variable voltage processor, Proc. Int. Symp. Low-Power Design, 197–202
- Kaiser, G., 1994. A Friendly Guide to Wavelets, Woodbine: Birkhäuser
- Kirkpatrick, S., Gelatt, C.D., Jr., and Vecchi, M.P., 1983. Optimization by simulated annealing, Science, Vol. 220, Series 4598, 671-680.
- Koch, M., 1990. Optimal Regularization of the Linear Seismic Inverse Problem, Technical Report, FSU-SCRI-90C-32, Florida State Univ., Tallahassee, FL.
- Linden, H.D., 1995. Handbook of Batteries. 2nd edition. McGraw-Hill, New York
- Luo, X. , 1998. EMI Antenna Modeling and FDTD Time-Domain Extrapolation Using the Generalized Pencil of Function Method, Master Dissertation, Dept. Elec. Comp. Eng., Univ. Missouri – Rolla, MO
- Manzak A. ve Chakrabarti, C., 2001, Variable voltage task scheduling for minimizing energy, Proc. Int. Symp. Low-Power Design, 279–282
- Manzak, A., Goksu, H., 2005. Application of Very Fast Simulated Reannealing to Low Power Design. Lecture Notes in Computer Science, Springer, vol. 3553, 308–313
- Marculescu, R., Marculescu, D., ve Pedram, M., 1995, Efficient power estimation for highly correlated input streams, Proceedings of the 32nd Design Automation Conference, 628-634
- Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A., and Teller, E., 1953. Equation of state calculation by fast computing machines, J. Chem. Phys, Vol. 21, 1087-1092.
- Narendra, K., Parthasarathy, K., 1990. Identification and control of dynamical systems using neural networks. Trans. Neural Networks, Vol. 78 4-27
- Nguyen, D., 2003. Minimization of dynamic and static power through joint assignment of threshold voltages and sizing optimization. Proc. of the Int. Symp. on Low Power Electronics and Design.
- Pant, P., Roy, R., Chatterj, A., 2001. Dual-threshold voltage assignment with transistor sizing for low power CMOS circuits. IEEE Trans. on VLSI **9** 390–394
- Pouwelse, J., Langendoen, K., Sips, H. J., 2001, Energy priority scheduling for variable voltage processors, Proc. Int. Symp. Low-Power Design, 28–33,

- Pouwelse, J., Langendoen, K., Sips, H. J., 2003, Application-directed voltage scaling, *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, v.11 n.5, 812-826
- Prigogine, I., Stengers, I., 1984, *Order out of Chaos* (New York: Bantam).
- Quan G. ve Hu, X., 2001, Energy efficient fixed-priority scheduling for real-time systems on variable voltage processors, *Proc. Design Automation Conf.*, 828–833
- Rabaey, J. M. ve Pedram, M., 1996, *Low Power Design Methodologies*. Norwell, MA: Kluwer, 46–61
- Rioul O ve Vetterli M 1991 *IEEE SP Magazine* Oct. 14
- Ruddle, A.R., Topham, D.A., Ward D.D., 2003. Investigation of Electromagnetic Emissions Measurement Practices for Alternative Powertrain Road Vehicles, *IEEE Int. Symposium EMC*, 543-547.
- Rumelhart, D.E., vd McClelland J.L., 1986, *Parallel Distributed Processing*, MIT Press
- Sarkar, T. K. , Pereira, O. , 1995. Using the Matrix Pencil Method to Estimate the Parameters of a Sum of Complex Exponentials, *IEEE Transactions on Antennas and Propagation Magazine*, Vol. 37, No.1
- Sen, M.K., Stoffa, P.L., 1995. “Global optimization methods in geophysical inversion,” Elsevier Publications, 277s.
- Shannon, C.E. 1948, A mathematical theory of communication, *Bell System Technical Journal* 27, 379-423 ve 623-656
- Shieh, Ching-Sung ve Lin Chin-Teng, 2002, A Vector Neural Network for Emitter Identification, *IEEE Trans. Antennas and Propagation*, Vol. 50, No. 8, 1120-1127
- Stojanovic, V., 2002. Energy-delay tradeoffs in combinational logic using gate sizing and supply voltage optimization. *Proc. European Solid-State Circuits Conf.*
- Sullivan, B. J. , Liu, B. , 1984. On the Use of Singular Value Decomposition and Decimation in Discrete-Time Band-Limited Signal Extrapolation, *IEEE Transactions on Antennas and Propagation Magazine*, Vol. ASSP-32, No.6
- Szu, H., ve Hardley, R., 1987. Fast Simulated Annealing, *Phys. Lett. A.*, 122, 157-162.

- Taflove, A., Umashankar, K. R., 1989. Review of FDTD numerical modeling of electromagnetic wave scattering and radar cross section. *Proc. IEEE*, Vol. 77, 682-699
- Tarantola, A., 1987. *Inverse Problem Theory, Methods of Data Fitting and Model Parameter Estimation*, Elsevier Publishing Company, 614s.
- Theil, H. 1967, *Economics and Information Theory* (Amsterdam: North-Holland)
- Theil, H. 1972, *Statistical Decomposition Analysis* (Amsterdam: North-Holland)
- Turing, A.M., 1950. Computing Machinery and Intelligence, *Mind*, Vol. 59, 433-460
- Van Laarhoven, P.J.M., ve Aarts, E. H. L., 1987. *Simulated Annealing: Theory and Applications*, D. Riedel.
- Wasserman, P. D., 1993, *Advanced Methods in Neural Computing*, New York, Van Nostrand, 147-176
- Weiser, M. , Welch, B., Demers, A. ve Shenker, S., 1994, Scheduling for reduced CPU energy, *Proc. USENIX Symp. Operating Syst. Design and Implementation*, 13–23
- Wickerhauser, M. V., 1994. *Adapted Wavelet Analysis from Theory to Software*, Massachusetts: A.K. Peters
- Wornell, G. W., 1993. *Proc. IEEE*, 81, 1428
- Wu, C., Navarro, A., Litva, J., 1996. Combination of finite impulse response neural network technique with FDTD method for simulation of electromagnetic problems. *Electron. Lett.*, Vol. 32, 1112-1113
- Yao, F., Demers, A., ve Shenker, S., 1995, A scheduling model for reduced CPU energy, *Proc. IEEE Annu. Found. Comput. Science*, 374–82
- Zadjenweber, D. 1972, Une application de la théorie de l'information à l'économie: la mesure de la concentration, *Revue d'Economie Politique* 82, 486-510

ÖZGEÇMİŞ

Adı Soyadı : Hüseyin Göksu
Doğum Yeri : Ankara
Doğum Yılı : 1973
Medeni Hali : Bekar

Eğitim ve Akademik Durumu:

Lise 1984-1991 : Isparta Anadolu Lisesi, Isparta
Lisans 1991-1993 : Hacettepe Üniversitesi, Tıp Fakültesi, Ankara
Lisans 1993-1997 : Orta Doğu Teknik Üniv., Fizik E., Ankara
Y. Lisans 1999-2002 : Süleyman Demirel Üniversitesi, Fizik, Isparta
Y. Lisans 2002-2004 : Missouri Üniversitesi, Elektrik Mühendisliği, A.B.D.
Doktora 2002-2006 : Süleyman Demirel Üniversitesi, Fizik, Isparta

Yabancı Dil : İngilizce

İş Deneyimi:

1997-1998 : Araştırmacı, TÜBİTAK, Ulusal Elektronik ve Kriptoloji Araştırma Enstitüsü, Gebze, Kocaeli
1998-2001 : Öğretim Görevlisi, Vanderbilt Üniversitesi, Fizik ve Astronomi Bölümü, Nashville, Tennessee, Amerika Birleşik Devletleri
2002- : Okutman, Süleyman Demirel Üniversitesi, Isparta
2002-2004 : Araştırma Görevlisi, Missouri Üniversitesi, Elektrik ve Bilgisayar Mühendisliği Bölümü, İşlemsel Zeka Laboratuvarı, Rolla, Missouri, Amerika Birleşik Devletleri