

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

**BİLGİSAYARLI GÖRÜ TEKNİKLERİYLE KÖMÜR YAKITLI  
KAZANLARDAKİ YANMA VERİMİNİN TAHMİNİ**

**DOKTORA TEZİ**

**Sedat GOLGİYAZ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. Muhammed Fatih TALU**

**HAZİRAN 2020**

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

**BİLGİSAYARLI GÖRÜ TEKNİKLERİYLE KÖMÜR YAKITLI  
KAZANLARDAKİ YANMA VERİMİNİN TAHMİNİ**

**DOKTORA TEZİ**

**Sedat GOLGİYAZ  
(23613190322)**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. Muhammed Fatih TALU**

**HAZİRAN 2020**

## TEŐEKKÜR VE ÖNSÖZ

Bu tez alıőmasının her aőamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemedeni her konuda yönlendiren danışman hocam Sayın Muhammed Fatih TALU'ya,

Doktora eğitimim boyunca tecrübesiyle yardımlarını esirgemeyen Prof Dr. Ali KARCI'ya,

Maddi ve manevi desteęiyle yanımda olup doktora eğitimimde gösterdięi fedakarlıklardan dolayı eőim ve oęlum Halil Hubeyb GOLGIYAZ'a

Tezin uygulama aőamasında vermiő oldukları maddi ve manevi destekten dolayı, TÜBİTAK ve MİMSAN AŐ. firması ile deęerli alıőanlarına

teőekkür ederim.



## ONUR SÖZÜ

Doktora tezi olarak sunduđum “Bilgisayarlı Görü Teknikleriyle Kömür Yakıtlı Kazanlardaki Yanma Veriminin Tahmini” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldıđına ve yararlandıđım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Sedat GOLGİYAZ



## İÇİNDEKİLER

|   |           |
|---|-----------|
| TEŞEKKÜR VE ÖNSÖZ .....   | iii       |
| ONUR SÖZÜ .....   | iv        |
| İÇİNDEKİLER.....  | v         |
| ÇİZELGELER DİZİNİ.....  | vii       |
| ŞEKİLLER DİZİNİ.....  | ix        |
| SEMBOLLER VE KISALTMALAR DİZİNİ .....                               | xi        |
| ÖZET .....  | xiv       |
| ABSTRACT .....  | xv        |
| <b>1. GİRİŞ.....</b>  | <b>1</b>  |
| 1.1 Motivasyon .....  | 3         |
| 1.2 Tezin Amacı .....   | 3         |
| 1.3 Tezin Yaygın Etkileri .....                                     | 3         |
| 1.4 Tezin Organizasyonu .....                                       | 4         |
| <b>2. YANMA VERİMLİLİĞİ ÇALIŞMALARI .....</b>                       | <b>6</b>  |
| 2.1 Optik Sensörler .....   | 6         |
| 2.2 Basınç Transdüserleri .....                                     | 6         |
| 2.3 Ölçüm Çubuğu.....   | 7         |
| 2.4 Görüntüleme Teknikleri .....                                    | 7         |
| <b>3. ÖNERİLEN YANMA SİSTEMİ VE VERİ TOPLAMA.....</b>               | <b>12</b> |
| 3.1 Yanma Sistemi Deney Düzeneği .....                              | 12        |
| 3.1.1 Deney kazanı .....  | 13        |
| 3.1.2 Baca gazı analizörü ve referans verilerin elde edilmesi ..... | 14        |
| 3.1.3 Kameralar ve yanma odasının görüntülenmesi .....              | 15        |
| 3.1.4 Gömülü bilgisayar .....                                       | 17        |
| 3.2 Veri Kayıt Yazılımı .....                                       | 18        |
| 3.3 Deneysel Verilerin Toplanması .....                             | 20        |
| <b>4. ALEV GÖRÜNTÜLERİNDEN ÖZNETELİK ÇIKARMA.....</b>               | <b>21</b> |
| 4.1 RGB Renk Uzayında İdeal Yanma Noktası Metodu.....               | 23        |
| 4.1.1 İdeal yanma rengine projeksiyon.....                          | 25        |
| 4.1.2 İdeal yanma noktasına uzaklık metodu .....                    | 26        |
| 4.2 İdeal Yanma Bölgesi Görüntüsüyle Modelleme .....                | 27        |
| 4.3 Çok Görüntüyle İdeal Yanmanın Modellenmesi.....                 | 30        |
| 4.3.1 Ayırık benzerlik toplamı.....                                 | 32        |
| 4.3.2 Bağımsız olasılık çarpımı-naive bayes metodu .....            | 33        |
| 4.3.3 Çok değişkenli dağılım.....                                   | 34        |
| 4.3.4 Karışım modeli .....  | 34        |
| 4.4 İstatistiksel Momentler .....                                   | 35        |
| 4.5 Normlar.....  | 35        |
| 4.6 Uzamsal Yoğunluk Dağılımı .....                                 | 37        |
| 4.7 Kümülatif Uzamsal Yoğunluk Dağılımı.....                        | 37        |
| 4.8 Diğer Yöntemler .....   | 37        |
| 4.8.1 HSI renk uzayında öznitelik elde etme.....                    | 38        |
| 4.8.2 Gri eş oluşum matrisi yöntemi .....                           | 39        |
| 4.8.3 Radyan enerji sinyali .....                                   | 39        |
| 4.8.4 Özdeğerler .....  | 40        |
| 4.8.5 FFT ve spektral analiz .....                                  | 40        |
| <b>5. DOĞRUSAL OLMAYAN REGRESYON METODLARI.....</b>                 | <b>41</b> |
| 5.1 YSA Regresyon Modeli .....                                      | 41        |
| 5.2 DVR Modeli .....  | 42        |

|           |   |            |
|-----------|---|------------|
| 5.2.1     | Doğrusal DVR .....  | 42         |
| 5.2.2     | Doğrusal olmayan DVR .....  | 43         |
| 5.3       | Zaman Serisi YSA Regresyon Modeli .....   | 44         |
| 5.3.1     | Geribeslemeli .....   | 44         |
| 5.3.2     | Geribeslemesiz .....  | 45         |
| 5.4       | Evrişimsel Sinir Ağları .....   | 46         |
| 5.5       | Transfer Öğrenme .....  | 47         |
| 5.6       | Deneysel Sonuçların Değerlendirilmesi .....                                       | 48         |
| <b>6.</b> | <b>ÖZNİTELİKLERDEN <math>\lambda</math>, BGS ve BGE TAHMİNİ .....</b>             | <b>50</b>  |
| 6.1       | Modellemeyle $\lambda$ Tahmini .....  | 50         |
| 6.1.1     | İdeal yanma rengine projeksiyon ve uzaklık .....                                  | 50         |
| 6.1.2     | İdeal yanma rengi yaklaşımlarının birlikte değerlendirilmesi .....                | 53         |
| 6.1.3     | İdeal yanma bölgesi görüntüsüyle modelleme .....                                  | 55         |
| 6.1.4     | İdeal yanma bölgesi yöntemlerinin birlikte kıyaslanması .....                     | 58         |
| 6.1.5     | Ayrık benzerlik toplamı .....   | 59         |
| 6.1.6     | Bağımsız olasılık çarpımı .....   | 60         |
| 6.1.7     | Çok değişkenli dağılım .....  | 61         |
| 6.1.8     | Karışım modeli .....  | 61         |
| 6.1.9     | Çok görüntüyle modelleme yöntemlerinin birlikte değerlendirilmesi .....           | 62         |
| 6.2       | Uzamsal Yoğunluk Dağılımıyla BGS Tahmin Sonuçları .....                           | 65         |
| 6.2.1     | Sonuçlar ve değerlendirme .....   | 67         |
| 6.3       | Kümülatif Uzamsal Yoğunluk Dağılımı ile NO <sub>x</sub> Emisyonunun Tahmini ..... | 67         |
| 6.3.1     | Sonuçlar ve değerlendirme .....   | 69         |
| 6.4       | Görüntü Normları ile BGS Tahmini .....  | 69         |
| 6.4.1     | Sonuçlar ve değerlendirme .....   | 74         |
| 6.5       | Evrişimsel Sinir Ağları ile BGS Tahmini .....                                     | 74         |
| 6.5.1     | Sonuçlar ve değerlendirme .....   | 78         |
| 6.6       | Görüntü Momentleri ile $\lambda$ Tahmini .....                                    | 79         |
| 6.6.1     | YSA regresyon modeli ile $\lambda$ tahmini .....                                  | 79         |
| 6.6.2     | Zaman serisi ysa ile $\lambda$ tahmini .....                                      | 82         |
| 6.6.3     | Sonuçlar ve değerlendirme .....   | 84         |
| 6.7       | Evrişimsel Sinir Ağları ile $\lambda$ Tahmini .....                               | 87         |
| 6.7.1     | Sonuçlar ve değerlendirme .....   | 90         |
| 6.8       | Endüstriyel Kamera ve Web Kamerası Kıyaslaması .....                              | 91         |
| 6.8.1     | Sonuçlar ve değerlendirme .....   | 96         |
| <b>7.</b> | <b>GERÇEK ZAMANLI FAN KONTROL UYGULAMASI .....</b>                                | <b>97</b>  |
| 7.1       | Sistem Bileşenleri .....  | 97         |
| 7.2       | Regresyon Modeli Parametrelerinin Seçimi .....                                    | 97         |
| 7.3       | İlgilenilen Bölgenin Seçilmesi .....  | 99         |
| 7.4       | Yerel Pencere Boyutu, Nöron Sayısı ve Regresyon Modeli Seçimi .....               | 102        |
| 7.5       | Sonuçlar ve Değerlendirme .....   | 107        |
| 7.6       | Gerçek Zamanlı Fan Kontrol Uygulaması .....                                       | 107        |
| <b>8.</b> | <b>SONUÇLAR .....</b>   | <b>114</b> |
|           | <b>KAYNAKLAR .....</b>  | <b>119</b> |
|           | <b>EKLER .....</b>  | <b>119</b> |
|           | <b>ÖZGEÇMİŞ .....</b>   | <b>145</b> |

## ÇİZELGELER DİZİNİ

|  |    |
|--|----|
| Çizelge 1.1 : Değişik yakıt türleri için ideal $\lambda$ aralıkları .....  | 2  |
| Çizelge 3.1 : Deney kazanının ana parametreleri.....   | 14 |
| Çizelge 3.2 : Tez kapsamında kullanılan deneysel veriler için teknik bilgiler .....  | 20 |
| Çizelge 4.1 : Alev görüntüsünün farklı renk kanalları için eşik değerler .....   | 28 |
| Çizelge 4.2 : Norm formülleri.....   | 36 |
| Çizelge 5.1 : Ön eğitilmiş bazı ağlar için teknik bilgiler.....  | 47 |
| Çizelge 6.1 : Projeksiyon-oran yöntemi için regresyon modelleri test sonuçları .....   | 51 |
| Çizelge 6.2 : Projeksiyon-fark yöntemi için regresyon modelleri test sonuçları .....   | 52 |
| Çizelge 6.3 : Yanma noktasına uzaklık yöntemi için modellerin test sonuçları .....   | 52 |
| Çizelge 6.4 : Üç yöntem için kıyaslamalı sonuçlar.....   | 54 |
| Çizelge 6.5 : İkili görüntü için $\lambda$ tahmini .....   | 56 |
| Çizelge 6.6 : Biaslı görüntü için $\lambda$ tahmini .....  | 56 |
| Çizelge 6.7 : Satır-sütun toplamı metodu için $\lambda$ tahmini .....  | 57 |
| Çizelge 6.8 : Satır-sütun onluk metodu için $\lambda$ tahmini.....   | 57 |
| Çizelge 6.9 : Öznitelik yöntemleri için en iyi $\lambda$ tahmini sonuçları .....   | 58 |
| Çizelge 6.10 : Ayırık benzerlik toplamı yaklaşımı $\lambda$ tahmini sonuçları.....   | 60 |
| Çizelge 6.11 : Bağımsız olasılık çarpımıyla $\lambda$ tahmini sonuçları.....   | 61 |
| Çizelge 6.12 : Çok değişkenli dağılım $\lambda$ tahmin sonuçları .....   | 61 |
| Çizelge 6.13 : Modelleme yaklaşımlarının $\lambda$ tahmin sonuçları.....   | 63 |
| Çizelge 6.14 : Literatürdeki yaklaşımların $\lambda$ tahmin sonuçları ile kıyaslanması .....   | 64 |
| Çizelge 6.15 : Uzamsal yoğunluk dağılımıyla BGS'nin tahmin için DVR modelleri<br>başarımları.....  | 65 |
| Çizelge 6.16 : Önerilen öznitelik elde etme yöntemi ve diğer yöntemlerin kıyaslanması 66   |    |
| Çizelge 6.17 : Kümülatif uzamsal yoğunluk dağılımı ile NO <sub>x</sub> emisyonunun tahmin için<br>YSA regresyon modeli sonuçları .....           | 68 |
| Çizelge 6.18 : Yerel pencere boyutu ve öznitelik yönteminin (normlarının) BGS tahminine<br>etkisi.....   | 71 |
| Çizelge 6.19 : Renk kanalları ve farklı pencere sayısı için BGS tahmini başarımlar .....   | 72 |
| Çizelge 6.20 : Önerilen yöntemin mevcut yöntemlerle karşılaştırılması.....   | 74 |
| Çizelge 6.21 : Geliştirilen ESA mimarisi.....  | 75 |
| Çizelge 6.22 : Geliştirilen ESA için tekil kanal başarımları .....   | 76 |
| Çizelge 6.23 : Geliştirilen ESA için çoklu kanal başarımları.....  | 76 |
| Çizelge 6.24 : DigitsNet ESA'sı için tekil kanal başarımları.....  | 77 |
| Çizelge 6.25 : Ön eğitilmiş ESA'lar için BGS tahmin sonuçları.....   | 78 |
| Çizelge 6.26 : İlgili YSA öğrenme modeli için en kötü tüm sistem, en iyi tüm sistem ve<br>test sonuçlarının alındığı model başarımları .....     | 80 |
| Çizelge 6.27 : Farklı çözünürlük ve farklı gizli katman nöron sayısında $\lambda$ tahmini için YSA<br>regresyon modeli performans sonuçları..... | 81 |
| Çizelge 6.28 : Farklı çözünürlük ve farklı yerel pencere boyutunda $\lambda$ tahmini için YSA<br>regresyon modeli performans sonuçları.....      | 82 |
| Çizelge 6.29 : Farklı öznitelik elde etme yöntemleri için NARX model ile $\lambda$ tahmini<br>sonuçları .....                                    | 83 |
| Çizelge 6.30 : Önerilen öznitelik elde yönteminin mevcut yöntemlerle karşılaştırılması ..  | 86 |
| Çizelge 6.31 : Sunulan yöntemler ve diğer yöntemler için zaman (sn) kıyaslaması .....  | 87 |
| Çizelge 6.32 : Geliştirilen ESA için tekil kanal başarımları .....   | 88 |
| Çizelge 6.33 : Geliştirilen ESA için çoklu kanal başarımları.....  | 88 |
| Çizelge 6.34 : DigitsNet ESA'sı için tekil kanal başarımları.....  | 89 |
| Çizelge 6.35 : Ön eğitilmiş ESA'lar için $\lambda$ tahmini sonuçları.....  | 90 |

|   |     |
|---|-----|
| <b>Çizelge 6.36</b> : Endüstriyel ve web kamera için çözünürlük seviyeleri .....  | 92  |
| <b>Çizelge 6.37</b> : Diktötrgense ROI'de endüstriyel ve web kameraları için en iyi tüm sistem ve en iyi test modellerinin sonuçları .....        | 94  |
| <b>Çizelge 6.38</b> : Dairesel maskelenmiş ROI'de endüstriyel ve web kameraları için en iyi tüm sistem ve en iyi test modellerinin sonuçları..... | 95  |
| <b>Çizelge 7.1</b> : İlgili YSA öğrenme modeli için en iyi test sonuçlarına sahip 5 adet modelin parametreleri ve başarımları .....               | 98  |
| <b>Çizelge 7.2</b> : Kullanılan deney verileri .....  | 103 |
| <b>Çizelge 7.3</b> : DGÇ öğrenme modeli için optimum gecikmeli giriş sayısı ve optimum nöron sayısında modelin performans sonuçları.....          | 105 |
| <b>Çizelge 7.4</b> : YSA regresyon modeli için lambda tahmin sonuçları.....   | 106 |
| <b>Çizelge 7.5</b> : Derin öğrenme (ESA) için lambda tahmin sonuçları .....   | 106 |
| <b>Çizelge 7.6</b> : Gerçek zamanlı uygulama için oluşturulan veri tabanları .....  | 111 |
| <b>Çizelge B.1</b> : BGA cihazı için teknik bilgiler .....  | 132 |



## ŞEKİLLER DİZİNİ

|  |     |
|--|-----|
| Şekil 1.1 : Yanma grafiği .....  | 2   |
| Şekil 3.1 : Geliştirilen sistemin genel bir gösterimi.....   | 12  |
| Şekil 3.2 : Deney kazanı: (a) ön ve (b) arka görüntüleri.....  | 14  |
| Şekil 3.3 : Kullanılan kameralar; (a) Basler, (b) Logitech ve (c) Microsoft.....   | 16  |
| Şekil 3.4 : Deney-2 için $\lambda$ değişiminin grafiksel gösterimi ve bazı alev görüntüleri.....   | 17  |
| Şekil 3.5 : Latte Panda gömülü bilgisayar ve çevresel donanımlar .....   | 18  |
| Şekil 3.6 : Geliştirilen veri kayıt yazılımı. (a) Kayıt sayfası, (b) Video kontrol, (c) “Video Renk İşlemci/Yükselteç ayarları .....   | 19  |
| Şekil 4.1 : Örnek bir alev görüntüne ait kanallar. (a) orijinal alev görüntüsü ve kanallar: (b) R, (c) G, (d) B, (e-h) Gr1-4.....  | 22  |
| Şekil 4.2 : Alev görüntüsünün gridlere bölünmesi .....   | 23  |
| Şekil 4.3 : Aynı görüntü için farklı eşik değerlerinde optimum yanmanın değişimi.....  | 24  |
| Şekil 4.4 : Örnek bir görüntü için birinci satır ve sütundan öznelik elde edilmesi .....   | 25  |
| Şekil 4.5 : Izgara renginin optimum yanma vektörüne projeksiyonu .....   | 26  |
| Şekil 4.6 : Alev görüntü kanalları ve model sonucundaki öznelik görüntüleri: (a-b) R, (c-d) G, (e-f) B, (g-n) Gr1-4 ve (p-r) H (HSI-Ton) .....   | 29  |
| Şekil 4.7 : R kanalı için birinci satır ve sütundan öznelik elde edilmesi .....  | 29  |
| Şekil 4.8 : Birden fazla görüntüyle ideal yanmanın modellenmesi .....  | 31  |
| Şekil 4.9 : İdeal yanma görüntü kanallarının gauss fonksiyonuyla modellenmesi.....   | 32  |
| Şekil 4.10 : Ayrık benzerlik olasılıkları yönteminin G kanalı için şematik gösterimi.....  | 33  |
| Şekil 4.11 : Spektral norm ile ÖV elde edilmesi.....   | 36  |
| Şekil 4.12 : RGB→HSI dönüşümü. Kanallar: (a) RGB, (b) HSI, (c) I, (d) S ve (e) H.....  | 38  |
| Şekil 5.1 : NARX YSA modeli için örnek bir modelin yapısı.....   | 45  |
| Şekil 5.2 : Doğrusal olmayan giriş-çıkış YSA modeli için örnek bir modelin yapısı.....   | 45  |
| Şekil 5.3 : Transfer öğrenmenin şematik gösterimi .....  | 48  |
| Şekil 6.1 : İdeal yanma noktasına uzaklık yöntemi için gerçek ve tahmin edilen $\lambda$ .....   | 55  |
| Şekil 6.2 : İkili görüntü yöntemi için gerçek ve tahmin edilen $\lambda$ .....   | 59  |
| Şekil 6.3 : Ayrık benzerlik toplamı yöntemi için gerçek ve tahmin edilen $\lambda$ .....   | 63  |
| Şekil 6.4 : Kübik DVR kullanılarak BGS tahmini modelinin tahmin ettiği baca gazı sıcaklığı .....   | 66  |
| Şekil 6.5 : YSA modeli için gerçek ve tahmin edilen NOxdeğeri.....   | 68  |
| Şekil 6.6 : Deney boyunca (a) BGS (°C)-O <sub>2</sub> (%) konsantrasyonu, (b) SO <sub>2</sub> (mg/kwh)-NO <sub>x</sub> (mg/kwh) ve (c) CO <sub>2</sub> (mg/kwh)-CO (mg/kwh) emisyon grafikleri ... | 70  |
| Şekil 6.7 : Gizli katman nöron sayısının modelin başarımına olan etkisi.....   | 72  |
| Şekil 6.8 : YSA modeli için gerçek ve modelin tahmin ettiği BGS.....   | 73  |
| Şekil 6.9 : Resnet18 (ESA) ve YSA modelleri için gerçek ve tahmin edilen BGS .....   | 78  |
| Şekil 6.10 : Deney-2 verileri için ölçüm verileri giriş verilerle (a) ve model tahmin sonuçları giriş verilerle (b) gerçekleştirilen NARX regresyon grafikleri....                                 | 83  |
| Şekil 6.11 : Tüm deney verileri için ölçüm verileri giriş verilerle (a) ve model tahmin sonuçları giriş verilerle (b) gerçekleştirilen NARX regresyon grafikleri....                               | 84  |
| Şekil 6.12 : YSA modeli için tahmin edilen $\lambda$ ve BGA'nın ölçtüğü $\lambda$ .....  | 85  |
| Şekil 6.13 : Resnet101 modeli ve YSA için tahmin edilen ve gerçek $\lambda$ .....  | 90  |
| Şekil 6.14 : Kameralar için (a-d) diktörtgensel ROI seçimi, (b-e) dairesel maske ve (c-f) ROI'nin maskeyle filtrelenip görüntünün ayrıştırılması .....   | 93  |
| Şekil 7.1 : Diktörtgensel ROI'nin (a) web ve (b) endüstriyel kamerada seçimi.....  | 99  |
| Şekil 7.2 : Daire içi ızgara ROI'nin (a) 16x16 ve (b) 4x4'lük ızgara için seçimi.....  | 100 |
| Şekil 7.3 : ROI'nin (a) dairesel maske ile (b) örnek bir görüntüye uygulanışı.....   | 101 |
| Şekil 7.4 : Alev görüntüsünün her bir bileşeninin filtrelenmesi .....  | 101 |

|  |     |
|--|-----|
| <b>Şekil 7.5</b> : ROI seçimi için (a) diaresele maske, (b) maskenin şekli ve (c) örnek bir görüntüye uygulaması .....   | 102 |
| <b>Şekil 7.6</b> : Örnek bir görüntü için (a) orjinal (b) ters çevrilmiş görüntü .....   | 103 |
| <b>Şekil 7.7</b> : Gerçek lambda ve ESA ve YSA modellerinin tahmin ettiği lambda .....   | 107 |
| <b>Şekil 7.8</b> : Fan kontrolü için deney düzeneği .....  | 109 |
| <b>Şekil 7.9</b> : Fan kontrolü için geliştirilen Gauss kontrol işareti-hata değişimi .....  | 110 |
| <b>Şekil 7.10</b> : Veri tabanı-1 için YSA ve DGÇ modeli $\lambda$ tahmini.....  | 112 |
| <b>Şekil 7.11</b> : Gerçek $\lambda$ değişimi, (a) deney 10-a ve (b) deney 10-b için.....  | 113 |
| <b>Şekil 7.12</b> : Önerilen YSA ve ESA modeller için deney 9-a için gerçek ve tahmin edilen $\lambda$ değerleri.....  | 113 |
| <b>Şekil A.1</b> : Enerji kaynağına göre dünya enerji tüketimi (a) ve bölgelere göre dünya kömür tüketimi (b) (Noktalı çizgi ile belirtilende ABD, TEP dahil verileri ifade etmektedir), 1990–2040(Katrilyon Btu - İngiliz ısı birimi (British thermal units)) ..... | 128 |
| <b>Şekil A.2</b> : Sektörlere göre enerji tüketimi - Katrilyon Btu (a) ve ilgili yakıtlardan net elektrik üretimi - milyar kilovat saat (b) (Noktalı çizgi ile belirtilende ABD'nin TEP dahil verileri ifade etmektedir), 1990–2050 .....                            | 129 |
| <b>Şekil A.3</b> : 1990-2016 yılları arasında Türkiye için TBK .....   | 129 |
| <b>Şekil A.4</b> : Ülkemiz için türüne göre kömür üretimi kt (kilo ton) .....  | 130 |
| <b>Şekil A.5</b> : Sektörlere göre enerji kaynaklı CO <sub>2</sub> emisyonları - milyar ton CO <sub>2</sub> (a) ve son kullanım sektörüne göre CO <sub>2</sub> yoğunluğu – her milyar Btu başına metrik ton CO <sub>2</sub> (b).....                                 | 131 |
| <b>Şekil C.6</b> : Geliştirilen C# programı ve alev bölgesinin kullanıcı tarafından belirlenmesi .....   | 134 |
| <b>Şekil C.7</b> : Kullanıcı ara yüzü için “Veri Hazırlama” sekmesi.....   | 135 |
| <b>Şekil C.8</b> : Deney-2 için gerçek $\lambda$ ve kamera görüntüleri.....  | 136 |
| <b>Şekil C.9</b> : Verinin uygunluğunun grafiksel olarak gösterilmesi.....   | 137 |
| <b>Şekil C.10</b> : Gerçek ve ara değer ile üretilmiş $\lambda$ ile ara değer üretmede salınım grafikleri .....  | 138 |
| <b>Şekil C.11</b> : Veri hazırlama kısmı için görüntü ve $\lambda$ bilgilerinin tablolarda verilmesi.....  | 138 |
| <b>Şekil C.12</b> : Kullanıcı ara yüzü için “Öznitelik Elde Etme” sekmesi.....   | 139 |
| <b>Şekil C.13</b> : Kullanıcı ara yüzü için “Regresyon” sekmesi .....  | 140 |
| <b>Şekil C.14</b> : YSA regresyon modeli için örnek bir sonuç dosyası içeriği .....  | 141 |
| <b>Şekil C.15</b> : Geliştirilen gömülü kontrol uygulamasının ekran görüntüsü .....  | 142 |

## SEMBOLLER VE KISALTMALAR DİZİNİ

|                                  |  |
|----------------------------------|--|
| <b>CO</b>                        | : Karbon monoksit  |
| <b>CO<sub>2</sub></b>            | : Karbon dioksit   |
| <b>D<sub>i</sub></b>             | : i. görüntüye karşılık gelen baca gazı analiz cihazı verisi         |
| <b>D'<sub>i</sub></b>            | : i. görüntüye karşılık gelen tahmini baca gazı analiz cihazı verisi |
| <b><math>\bar{D}</math></b>      | : Tüm D <sub>i</sub> verilerinin ortalama değeri                     |
| <b><math>\bar{D}'</math></b>     | : Tüm D' <sub>i</sub> verilerinin ortalama değeri                    |
| <b>D(t)</b>                      | : Anlık ilgili BGA verisini  |
| <b>F</b>                         | : Titreşim veya ağırlıklı ortalama salınım frekansı                  |
| <b>Gr1 – 4</b>                   | : Gri skala görüntüleri  |
| <b>H</b>                         | : Ton Seviyesi   |
| <b>Hist</b>                      | : Histogram dağılımı   |
| <b>k</b>                         | : Renk kanalı  |
| <b>k<sub>ij</sub></b>            | : Görüntünün (k) yoğunluk değeri                                     |
| <b>m</b>                         | : İlgilenilen görüntünün sütun sayısı                                |
| <b>mg/kwh</b>                    | : Miligram / kilovat saat  |
| <b>M</b>                         | : Toplam alev görüntüsü sayısı                                       |
| <b>n</b>                         | : İlgilenilen görüntünün satır sayısı                                |
| <b>NO</b>                        | : Azot monoksit  |
| <b>NO<sub>x</sub></b>            | : Azot oksitler  |
| <b>NO<sub>2</sub></b>            | : Azot dioksit   |
| <b>O<sub>2</sub></b>             | : Oksijen  |
| <b>OH</b>                        | : Hidroksit  |
| <b>R</b>                         | : Korelasyon katsayısı   |
| <b>sn</b>                        | : Saniye   |
| <b>SO<sub>2</sub></b>            | : Kükürt dioksit   |
| <b>t</b>                         | : Yerel pencere (grid) indisi  |
| <b>T</b>                         | : Toplam yerel pencere (grid) sayısını                               |
| <b>U</b>                         | : Fan kontrol işareti  |
| <b>w</b>                         | : Ağırlık katsayısı  |
| <b>Xtop</b>                      | : Satır toplamı  |
| <b>XKtop</b>                     | : Kümülatif satır toplamı  |
| <b>v</b>                         | : Volt   |
| <b>Ytop</b>                      | : Sütun toplamı  |
| <b>YKtop</b>                     | : Kümülatif sütun toplamı  |
| <b>λ</b>                         | : Lambda - Hava fazlalık katsayısı                                   |
| <b>°C</b>                        | : Santigrat derece   |
| <b>%</b>                         | : Yüzde  |
| <b>σ</b>                         | : Standart sapma   |
| <b>μ</b>                         | : Ortalama değer   |
| <b>γs</b>                        | : Çarpıklık  |
| <b>γk</b>                        | : Basıklık   |
| <b> k </b>                       | : Büyüklük   |
| <b><math>\ k\ _F</math></b>      | : Frobenius normu  |
| <b><math>\ k\ _1</math></b>      | : Norm-1   |
| <b><math>\ k\ _\infty</math></b> | : Sonsuzluk normu  |
| <b><math>\ k\ _S</math></b>      | : Spektral norm  |
| <b>AB</b>                        | : Avrupa Birliği   |
| <b>ABD</b>                       | : Amerika Birleşik Devletleri  |

|               |   |
|---------------|---|
| <b>AR-GE</b>  | : Araştırma-Geliştirme  |
| <b>BFG</b>    | : BFGS Quasi-Newton   |
| <b>BGA</b>    | : Baca Gazı Analizörü   |
| <b>BGE</b>    | : Baca Gazı Emisyonları   |
| <b>BGS</b>    | : Baca Gazı Sıcaklığı   |
| <b>BSD</b>    | : Berkeley Yazılım Dağıtımı (Berkeley Software Distribution)          |
| <b>BTU</b>    | : İngiliz ısı birimi (British thermal units)                          |
| <b>CCD</b>    | : Yüklenme İliştirilmiş Araç (Charge Coupled Device)                  |
| <b>CD</b>     | : Kompakt Disk  |
| <b>CGF</b>    | : Fletcher-Powell Conjugate Gradient                                  |
| <b>CM</b>     | : Santimetre  |
| <b>ÇDGD</b>   | : Çok Değişkenli Gauss Dağılımı                                       |
| <b>DGC</b>    | : Doğrusal Olmayan Giriş-Çıkış  |
| <b>DVM</b>    | : Destek Vektör Makinası  |
| <b>DVR</b>    | : Destek Vektör Regreyon  |
| <b>ESA</b>    | : Evrimsel Sinir Ağları   |
| <b>FFT</b>    | : Hızlı Fourier Dönüşümü (Fast Fourier Transform)                     |
| <b>FPGA</b>   | : Alan Programlanabilir Kapı Dizisi (Field Programmable Gate Array)   |
| <b>FPS</b>    | : Saniyedeki Çerçeve Sayısı (Frame Per Second)                        |
| <b>GD</b>     | : Gauss Dağılımı  |
| <b>GKM</b>    | : Gauss Karışım Modeli  |
| <b>GPU</b>    | : Grafik İşleme Ünitesi (Graphics Processing Unit)                    |
| <b>GSY</b>    | : Güç Spektral Yoğunluğu  |
| <b>HSI</b>    | : Ton, doygunluk ve yoğunluk renk uzayı                               |
| <b>IR</b>     | : Kırmızı ötesi (Infrared)  |
| <b>GLCM</b>   | : Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix)      |
| <b>KT</b>     | : Kilo Ton  |
| <b>KTEP</b>   | : Kilo ton eşdeğer petrol   |
| <b>LM</b>     | : Levenberg – Marquardt   |
| <b>Matlab</b> | : Özel olarak tasarlanmış programlama platformu (Matrix Laboratory)   |
| <b>MBAR</b>   | : Milibar   |
| <b>MLP</b>    | : Çok katmanlı perceptron   |
| <b>MSE</b>    | : Ortalama kare hata (Mean Squared Error)                             |
| <b>NARX</b>   | : Dışsal (harici) giriş ile doğrusal olmayan otoregressif sinir ağı   |
| <b>OYF</b>    | : Olasılık Yoğunluk Fonksiyonu  |
| <b>ÖV</b>     | : Öznitelik Vektörü   |
| <b>ÖVS</b>    | : Öznitelik Vektörü Sayısı  |
| <b>PPM</b>    | : Milyonda bir (Birim)  |
| <b>PWM</b>    | : Sinyal Genişlik Modülasyonu (Pulse Width Modulation)                |
| <b>RES</b>    | : Radyal enerji sinyali (Radial Energy Signal)                        |
| <b>RGB</b>    | : Kırmızı, yeşil ve mavi renk uzayı (Red, Green and Blue color space) |
| <b>RMSE</b>   | : Kök ortalama kare hatası (Root Mean Squared Error)                  |
| <b>ROI</b>    | : İlgilenilen Bölge (Region of Interest)                              |
| <b>SDK</b>    | : Yazılım geliştirme kiti (Software Development Kit)                  |
| <b>SCG</b>    | : Scaled Conjugate Gradient   |
| <b>TBA</b>    | : Temel bileşenler Analizi (Principal Component Analysis)             |
| <b>OECD</b>   | : Ekonomik İş birliği ve Kalkınma Örgütü                              |
| <b>OpenCV</b> | : Açık kaynak kodlu bilgisayarlı Görü Kütüphanesi                     |
| <b>TBEK</b>   | : Toplam Birincil Enerji Kaynakları                                   |
| <b>TEP</b>    | : Temiz Enerji Politikaları   |

**TÜBİTAK**: Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu  
**TÜİK** : Türkiye İstatik Kurumu  
**YSA** : Yapay Sinir Ağları



# ÖZET

Doktora Tezi

## BİLGİSAYARLI GÖRÜ TEKNİKLERİYLE KÖMÜR YAKITLI KAZANLARDAKİ YANMA VERİMİNİN TAHMİNİ

Sedat GOLGİYAZ

İnönü Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

145 + xiii sayfa

2020

Danışman: Doç. Dr. Muhammed Fatih TALU

Kömür yakıtlı kazanlar kişisel ev, bina veya iş yerlerinin ısıtmalarında yaygın bir şekilde kullanılmaktadır. Kazanın verimli yakılması, ekonomik bir katma değer sağlamakla birlikte atmosfere bırakılan zararlı gazları azaltarak çevreye olumlu katkı sağlamaktadır.

Bu tez çalışmasında, ev tipi kömür kazanlarının yanma verimini bilgisayarlı görme teknikleriyle otomatik hesaplayabilen yeni bir sistem önerilmektedir. Bu sistem, yanma sürecinde kazan içerisindeki alev formu görselini elde ederek profesyonel baca gazı analizör cihazlarıyla ölçülen verim değerlerine eşlemektedir. Bunun için elde edilen yüksek boyutlu alev görüntüleri düşük boyutlu öznitelik vektörlerine indirgenmekte ve yapay öğrenme teknikleriyle kazan veriminin tahmini yapılmaktadır. Tez kapsamında, birçok farklı öznitelik çıkarma ve modelleme yaklaşımının eşleşme doğruluğu üzerindeki etkisi analiz edilmiştir.

Bu tezle sağlanan temel bilimsel katkı, mevcut yöntemlerle kıyaslandığında alev görseli ile verim ölçümü arasındaki en yüksek eşleştirme doğruluğunu sağlayan matematiksel modellerin geliştirilmesidir. Ayrıca alev görselinden baca gazı sıcaklığını tahmin edebilen matematiksel bir model de önerilmiştir. Geliştirilen tahmin modellerinin prototip bir kömür kazanı üzerinde gerçek zamanlı uygulamaları yapılmıştır.

**Anahtar Kelimeler:** Kömür yakıtlı kazan, kazan verimi, alev görüntüsü, yapay sinir ağları, baca gazı sıcaklığı

## ABSTRACT

Ph.D. Thesis

### ESTIMATION OF COMBUSTION EFFICIENCY IN COAL FIRED BOILERS WITH COMPUTER VISION TECHNIQUES

Sedat GOLGIYAZ

Inönü University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering

145 + xiii pages

2020

Supervisor: Assoc. Prof. Dr. Muhammed Fatih TALU

Coal fired-boilers are widely used in the heating of personal houses, buildings or workplaces. The efficient burning of the boiler provides an economic added value, while reducing the harmful gases released into the atmosphere and contributing positively to the environment.

In this thesis, a new system is proposed that can automatically calculate the combustion efficiency of household coal boilers using computer vision techniques. This system acquires the image of the flame form inside the boiler during the combustion process and maps it to the efficiency values measured with professional flue gas analyzer devices. For this, the high-dimensional flame images obtained are reduced to low-dimensional feature vectors and the boiler efficiency is estimated by artificial learning techniques. Within the scope of the thesis, the effect of many different feature extraction and modeling approaches on match accuracy was analyzed.

The main scientific contribution provided with this thesis is the development of mathematical models that provide the highest matching accuracy between flame image and efficiency measurement compared to existing methods. In addition, a mathematical model is proposed that can predict the flue gas temperature from the flame image. Real-time applications of developed prediction models on a prototype coal fired-boiler have been made.

**Keywords:** Coal fired-boiler, boiler efficiency, flame image, artificial neural networks, flue gas temperature

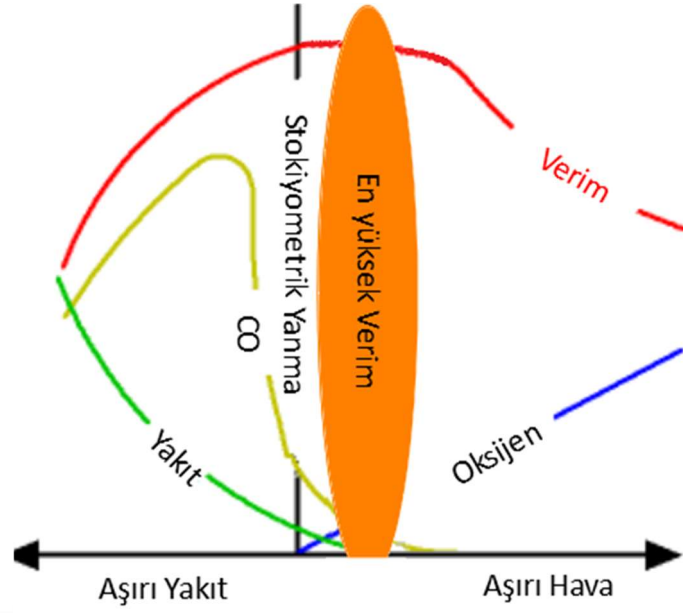
## 1. GİRİŞ

Kömür birçok ülke için önemli ve stratejik bir enerji kaynağıdır. Elektrik üretimi, demir-çelik sektörü, çimento sektörü ve ısıtma sistemleri gibi geniş bir alanda kömürün kullanıldığı ve gelecekte kullanılacağı ön görülmektedir [1]. Fosil yakıtlardan olan kömür, yenilenebilir enerji kaynağı değildir. Kömürün yakılması sonucunda oluşan emisyonların insan ve çevreye olumsuz etkileri bulunmaktadır [2, 3]. Bu olumsuz etkilerin minimize edilmesi için gerekli akademik çalışmalar yapılırken [4–13], diğer yandan kömürün tüketimi hakkında kapsamlı mevzuatlar uygulanmaktadır.

Kömürün verimli tüketilmesiyle maddi kazanç sağlanacağı gibi zararlı gazların çevreye yayılmasını azaltacağı için insan sağlığı ve çevreye olumlu katkısı bulunmaktadır. Kömür tüm ülkeler için önemli olmakla birlikte gelişmekte olan ülkeler için enerji ihtiyacının milli kaynaklarla karşılanması ve enerji güvenliği açısından son derece önemli olmaktadır. Ek A'da geçmiş ve gelecek perspektifinde dünya ve Türkiye'de kömür ile ilgili ayrıntılı bilgi verilmiştir.

Yakıt ve oksijen miktarlarının aşırı kullanımı yanma verimini düşürmektedir. İdeal yanma noktasına erişebilmek için bu iki parametrenin oldukça hassas bir oranda kullanılması gerekir. Literatürde yakıt-hava oranı hava fazlalık katsayısı-lambda ( $\lambda$ ) parametresiyle ifade edilmektedir ve yanma verimliliğini etkileyen en önemli parametre olarak öne çıkmaktadır. Şekil 1.1'de yanma grafiği verilmiştir. Teoride yanma veriminin maksimum olduğu nokta "Stokiyometrik Yanma" olarak ifade edilir ve bu nokta grafikte dikey siyah çizgi şeklinde gösterilmektedir. Uygulamada yanma veriminin maksimum olduğu nokta ise tam (ideal) yanma olarak adlandırılır ve grafikte elips şekliyle gösterilmektedir. Teorik olarak birçok parametreye bağlı olan tam yanma noktasının uygulamada elde edilebilmesi oldukça güçtür. Kazandaki ısı kayıpları, dış ortam hava koşulları, yakıttaki fiziksel ve kimyasal çeşitlilik gibi birçok etken tam yanma noktasının uygulamada tespitini zorlaştırmaktadır.

Farklı yakıt türleri için yakıt-hava oranı değişiklik göstermektedir. Çizelge 1.1'de yakıt türüne göre değişen  $\lambda$  değer aralıkları verilmektedir. Bu tez çalışması kapsamında yapılan çalışmalarda yakıt türü olarak fındık kömürü kullanılmıştır.



Şekil 1.1 : Yanma grafiği [14]

Çizelge 1.1 : Değişik yakıt türleri için ideal  $\lambda$  aralıkları [15]

| Yakıt Türü    | Hava Fazlalık Katsayısı ( $\lambda$ ) |
|---------------|---------------------------------------|
| Toz kömür     | 1,15 – 1,40                           |
| Fındık kömürü | 1,20 – 1,50                           |
| Sıvı yakıt    | 1,05 – 1,20                           |
| Doğal gaz     | 1,05 – 1,12                           |

Günümüzde kömür kazanının yanma veriminin hesaplanabilmesi için Baca Gazı Analizörü (BGA) cihazları kullanılmaktadır. Yüksek maliyetli bu cihazlar bir prob yardımıyla kazan bacasından ölçümler almakta ve anlık verimliliği hesaplayabilmektedir. Yüksek maliyetleri BGA cihazlarının sınırlı çalışma sürelerine sahip olmaları, sarf malzeme ve periyodik bakım giderleri araştırmacıları ekonomik ve pratik sistemler bulmaya yönlendirmiştir.

Son yıllarda kazan içerisindeki yanma odasının kameralar ile görüntülenmesine dayalı çalışmalar yapılmaktadır [12, 16–19]. Genel olarak bu çalışmalarda yanma odası görseli kullanılarak kazan verimliliğinin ve alev sıcaklığının hesaplanması üzerine durulduğu görülmüştür. Bu tez kapsamında, yanma odası görselinden  $\lambda$  parametresinin yüksek doğrulukta tahmini ile ilgili çalışmalar yapılmıştır. Bununla birlikte tahmin edilen parametrenin ideal aralıkta olması için bir fan kontrol sistemi geliştirilmiştir. Ayrıca,  $\lambda$  parametresinin dışında Baca Gazı Sıcaklığı (BGS) ile alev görseli arasındaki ilişki de incelenmiştir.

## 1.1 Motivasyon

Bu tez çalışmanın dört temel motivasyon kaynağı bulunmaktadır.

1. BGA cihazlarının yüksek maliyetlere sahip olması ve pratik bir kullanımının olmaması.
2. Sadece belirli ölçümler yapan mevcut BGA cihazlarına yazılım yüklenememesi. Daha açık bir ifadeyle, ideal yanmayı temin etmek için gerekli olan fan ve kömür besleme düzeneklerinin yazılımla kontrol edilebilme imkanını sağlayamaması.
3. Alev görüntülerinden verimlilik tahmini yapan mevcut yöntemlerin tahminleme doğruluklarının yüksek olmaması.
4. Kömür kazanı için alev görüntülerinden verimliliği tahmin edebilen gerçek zamanlı bir sistemin henüz mevcut olmaması.

## 1.2 Tezin Amacı

Bu tezin amacı, kömür kazanının hangi verimde yakıldığını yüksek doğrulukta tahmin edebilen ve kazanın bileşenlerini (fan ve kömür besleme) kontrol etmeye izin verebilen düşük maliyetli bir sistem geliştirmektir.

## 1.3 Tezin Yaygın Etkileri

Tezin yaygın etkileri akademik ve ekonomik olarak ele alınmıştır.

1. Gerçekleştirilen bilimsel yayınlar (akademik yaygın etkiler) aşağıda listelenmektedir:
  - Uluslararası konferans (IDAP-2016): Bu çalışmada, modelleme yaklaşımıyla alev görüntüsünden öznitelik çıkarılmış ve YSA kullanılarak bu öznitelikler  $\lambda$  değerleriyle eşleştirilmiştir [20].
  - Ulusal dergi yayını (TR-Dizin): Bu çalışmada, alev görüntüsünün gri seviyeli formundan elde edilen konum bağımsız öznitelikler Destek Vektör Regresyon (DVR) modeliyle birlikte kullanılarak BGS tahmin edilmiştir [21].
  - Uluslararası dergi yayını (SCI-E): Bu çalışmada,  $NO_x$  emisyonu ve alev görüntüsü arasındaki ilişki incelenmiştir. Öznitelik çıkarma aşamasında kümülatif uzamsal yoğunluk dağılımı kullanılmıştır. Regresyon modeli olarak YSA kullanılmıştır.
  - Uluslararası dergi yayını (SCI): Bu çalışmada, alev görüntüsü ve BGS arasındaki ilişki incelenmiştir. Öznitelik elde etme yaklaşımı olarak alev görüntüsünün spektral

normu ve regresyon modeli olarak YSA modeli kullanılmıştır. Ayrıca aynı model ile emisyon tahmin çalışmasında yapılmıştır.

- Uluslararası dergi yayını (SCI): Bu çalışmada, ideal yanmanın temsili, matematiksel olarak modellenerek elde edilmiştir. Daha sonra her bir görüntünün ideal modellere olan benzerlikleri dört farklı teknikte hesaplanarak alev görüntüsü- $\lambda$  eşleştirmesi yapılmıştır [22].
  - Tübitak Projesi (1005-117M121): Bu tez çalışması, “Otomatik Yüklemeli Kömür Kazanlarında Görüntü İşlemeli Adaptif Kontrol Ünitesi Geliştirilmesi” adlı proje kapsamında yapılmıştır.
2. Ekonomik yaygın etkisi, gerçekleştirilen projenin yaygınlaştırılması ile ülke ekonomisine katkı sağlamasıdır.

#### 1.4 Tezin Organizasyonu

Tez çalışmasının birinci bölümünde, tez hakkında temel bilgiler verilmiştir. Diğer bölümlerin organizasyonu aşağıda sunulmuştur:

**Bölüm 2’de**, yanma verimliliği hakkındaki literatüre girmiş çalışmalar kıyaslamalı bir şekilde verilmiştir. Mevcut yöntemlerin üstün ve zayıf yönleri değerlendirilmiştir.

**Bölüm 3’te**, önerilen yanma sistemi ve deney ekipmanları tanıtılmıştır. Tez kapsamında geliştirilen, iki adet web kamerası ile aynı anda veri almayı sağlayan evrensel görüntü yakalayıcı programı bu bölümde verilmiştir. Ayrıca veri temizleme ve senkronizasyon işlemi için kullanılan kullanıcı arayüzleri ve diğer yazılımlar bu bölümde tanıtılmıştır.

**Bölüm 4’de**, alev görüntülerinden öznitelik çıkarma yaklaşımları verilmiştir. İdeal yanmanın modellenmesi yaklaşımıyla ve klasik görüntü işleme tekniklerine konum bilgisi eklenerek yerel özniteliklerin nasıl elde edildiği sunulmuştur. Bu öznitelikler farklı renk kanalları için birbirinden bağımsız olarak ve bu özniteliklerin birleşim kombinasyonları şeklinde elde edilen yeni öznitelik vertörlerinin matematiksel alt yapısı verilmiştir.

**Bölüm 5’te**, öznitelik –  $\lambda$ /BGS eşlemesini yapabilmek için kullanılan doğrusal olmayan regresyon modelleri tanıtılmıştır. Klasik yaklaşımlarla birlikte derin öğrenme ve transfer öğrenme yaklaşımları sunulmuştur.

**Bölüm 6'da**, öznelik –  $\lambda$ /BGS eşlemesi için sunulan farklı teknikleri ile yapılan deneysel çalışmalar kıyaslamalı bir şekilde verilmektedir. Önerilen yöntemlerin üstünlüğü nicel verilerle sunulmuştur.

**Bölüm 7'de**, gerçek zamanlı fan kontrol uygulamasının bileşenlerinin ne olması gerektiği tartışılmıştır. Tüm deney verileri ile önerilen sistem parametreleri test edilmek suretiyle nihai sistem bileşenleri verilmiştir.

**Bölüm 8'de**, tüm çalışmalar neticesinde elde edilen sonuçlar irdelenmiş ve bilimsel katkılar vurgulanmıştır. Ayrıca gerçek zamanlı çalışacak bir ürünün geliştirilmesi için izlenecek deneysel çalışma önerileri tartışılmıştır.



## 2. YANMA VERİMLİLİĞİ ÇALIŞMALARI

Kömür kazanının yanma sürecinde verimini ölçebilen sistemler kullandıkları ekipmana göre farklılık göstermektedir. Bu sistemler, optik sensörler, basınç transdüserleri, ölçüm çubuğu (problama) ve görüntüleme olmak üzere dört farklı çatı altında gruplanabilir [23]. Bunun yanında yanma sürecinin daha iyi anlaşılması için benzetim tekniklerini kullanan sanal deney düzeneklerinin olduğu ve  $NO_x$  emisyonu gibi yanma parametrelerinin modellendiği bilinmektedir [24, 25]. Sanal ortamda yapılan bu benzetim çalışmalarından farklı olarak, tez kapsamında yapılan çalışmada gerçek kömür kazan sistemi kullanılmış ve önerilen görüntüleme tabanlı verim tahmin sistemi prototip bir kömür kazanında test edilmiştir.

### 2.1 Optik Sensörler

Yanma sonucu ortama radikallerin ( $CO$ ,  $OH$ ,  $H_2O$ ,  $CO_2$ ,  $M$ ,  $C_2$  ve  $H_2$ ) yayıldığı bilinmektedir [26]. Ortama yayılan molekül miktarının belirlenmesiyle yanma verimi hesaplanabilmektedir. Alev içindeki radikaller, karakteristik bantlar halinde gruplandırılabilen bir veya daha fazla emisyon hattı ile karakterize edilir ve çeşitli yayıcı radikallerin kombine katkısı, belirli bir alevin kimyasal ışıldama spektrumunu üretir [27]. Bir alevin kimyasal ışıldama spektrumunu optik sensörler yardımıyla ölçülür [28, 29]. Ölçüm yöntemi, görünür dalga boyunda [30] olabileceği gibi ultraviyole [31] veya kızılötesi [32]'de olabilir.

### 2.2 Basınç Transdüserleri

Yanma sonucu ortama yayılan ısı dalgaları kazan yüzeyinde basınca neden olmaktadır. Basınç miktarlarının ve dağılımının ölçülmesiyle kazanın yanma verimi hakkında bilgi elde edinilebilmektedir. Örneğin, dinamik basınç transdüserleri, zayıf ön karışımli yakıcılara sahip endüstriyel gaz türbinlerinde giderek yaygınlaşmaktadır. Bu teknoloji yanma kararsızlıklarını nispeten elimine edebilmektedir [33].

### 2.3 Ölçüm Çubuğu

Ölçüm çubuğu (proplama) yaklaşımı yanmayı karakterize etmek için uzun yıllardan beri kullanılmaktadır. Analiz yerine göre iki farklı tipi bulunmaktadır: 1) baca gazlarının incelenmesine [34, 35]; 2) yanma odasının incelenmesi [36]. BGA cihazları yanma işleminin izlenmesinde yaygın bir kullanıma sahiptir. Bacaya monte edilen bir ölçüm çubuğu yardımıyla toplanan ölçümlerle hava fazlalık katsayısı (hava/yakıt oranı), yanmamış yakıt ( $CO$ ) veya kirletici madde ( $NO_x, SO_2$ ) miktarları ölçülebilmektedir [23, 37]. Farklı değişkenlerin (sıcaklık, hız) ölçümü için özel ölçüm çubukları tasarlanmıştır [38]. Ölçüm çubukları uygun koruyucu malzemeye yapılmakta ve endüstriyel yanma ortamlarında rahatlıkla kullanılabilir. Kazan içerisine sokulan ölçüm çubuğu ile alev formu hakkında bilgi elde edilmektedir. Ölçüm çubuğunun kazan içerisine sokulması zamanla tortu birikimi, korozyon, emme hattının tıkanması gibi zorlukları beraberinde getirir. Bahsedilen olumsuzlukların haricinde, ölçüm çubuğu kullanmanın en önemli dezavantajı, lokal bir alev bölgesinden hassas ölçümler yapmasıdır. Yapılan lokal ölçümün yanma odasının tamamını hangi ölçüde ifade ettiği tartışmalı bir konu olmuştur [39, 40].

### 2.4 Görüntüleme Teknikleri

Kazan içerisindeki yanma görselinin analiziyle verimliliğin tahmin edilmesi konusuna giderek artan bir ilgi vardır. Ballester ve Armingol [23] ile Docquier ve Candel [41] bu konu hakkında kapsayıcı birer çalışma sunmuşlardır. Genel olarak kazan içi alev görseli kullanılarak üç farklı uygulama yapıldığı görülmektedir:

- 1) Yanma verimliliği [9, 42–47].
- 2) Emisyon tahmini [12, 13, 48–51].
- 3) Alev sıcaklık tahmini [52–57].

Yanma odasının dijital olarak görselleştirilmesinde CCD kameralar [9, 42–45, 53, 54, 58], spektroskopik kameralar [48] veya lazer bazlı görüntüleme [13, 26, 59–61] teknikleri kullanılmaktadır. Elde edilen görüntüler RGB [9, 42–45, 53, 54, 58] veya HSI [11, 13, 62–64] renk uzaylarıyla değerlendirilmektedir.

Alev görüntülerinden verimliliğin tahmin edilebilmesi için iki temel aşama bulunmaktadır:

- 1) Alev görüntülerinden özniteliklerin çıkarılması.
- 2) Özniteliklerden verimliliğin tahmini.

Öznitelik çıkarılması aşamasında veri boyutunun azaltılması/indirgenmesi yaklaşımlarının sıklıkla kullanıldığı görülmektedir. Bu yöntemler genellikle renkli görüntüleri tek renk kanalına (Gri) dönüştürmekte [42, 43, 45, 58, 65] veya belirli bir renk kanalını (örn. B-Mavi) kullanmaktadır [9]. Daha sonra tek renk kanalı üzerinde Temel Bileşen Analizi (TBA) gibi cebirsel yaklaşımlar kullanılarak matris formundaki veri tek boyutlu vektöre indirgenmektedir [66]. Literatürde renkli alev görsellerinin sadece iki renk kanalı (R-Kırmızı ve G-Yeşil) kullanarak verim [53, 54, 65, 67] veya alev sıcaklığı [70,54] hesaplayan çalışmaların olduğu görülmektedir. Ayrıca [18] nolu çalışmada alev sıcaklık dağılımının 3-B rekonstrüksiyon yöntemiyle hesaplandığı görülmektedir. Bu çalışmalar değerlendirildiğinde hangi renk kanalının yanma sürecini en iyi temsil ettiğinin önemli bir konu olduğu görülebilir. Bu nedenle tez çalışması kapsamında, renk kanalının ayrı ayrı veya birleşim kombinasyonlarının verimliliği tahmin etme başarımına etkisi gözlemlenmiştir.

Sujatha ve Pappa tarafından bir çalışmada, kömür yakıtlı kazanlarda yanma süreci CCD kameralarla görüntüleme yapılarak dijitalize edilmiş ve daha sonra her bir alev görüntüsü tam yanma, kısmi yanma veya eksik yanma olarak sınıflandırılmıştır [68]. Alev görsellerinin ortalama renk yoğunluğu, alanı, parlaklığı ve yönü gibi öznitelikler Fisher'in Lineer Diskriminant Analiziyle (LDA) yöntemiyle elde edilmiştir. Özniteliklerin sınıflandırılması için 51 adet eğitim, 51 adet test verisinin kullanıldığı görülmüştür. Bu çalışmanın iki önemli eksikliği olduğu değerlendirilmektedir. Birincisi veri kümesinin oldukça sınırlı olması sınıflandırma başarımını olumsuz etkilemektedir. İkincisi yanma sürecinin tam, kısmi ve eksik yanma olarak üç keskin sınıfla ifade edilmesi doğru bir yaklaşım olarak değerlendirilmemektedir. Tez kapsamında alev görüntülerinin sınıflandırılmasından ziyade regresyon yaklaşımı benimsenerek verim değerlerine eşlenmesi çalışmaları yapılmıştır.

Büchner v.d. konut sakinleri için kapsamlı bir anket kullanarak binalarda yapılan kurulumlar ve mevcut binalardaki kazan değiştirmeleri ve müşteri memnuniyetini nasıl etkiledikleri dikkate alınarak, Avusturya ve Almanya'daki küçük ölçekli kazan ısıtma sistemlerinin operasyonel davranışlarını incelemiştir [69].

Bir diğerk çalışmada deęişken yanma koşulları altında Destek Vektör Makinaları (DVM) tabanlı çevrimiçi kömür tanımlama sistemi önerilmiştir [60]. Kömür tanımlaması için uzamsal ve zamansal alev öznitelikleri çıkarılmıştır. Kömür alevinin kızıl ötesi (IR) sinyalinin ortalama deęerinin tahmin doğruluęu üzerinde en büyük etkiye sahip olduęu bulunmuştur. Bu çalışmalar hem kazanlar üstündeki çalışmalarını çeşitlendirmekte hem de alev görüntüsünde farklı bilgilerin bulunduęu ve farklı çalışmaların yapılabileceğini göstermektedir.

Hernandez ve Ballester tarafından alev görüntüsünün geometrik ve ışık ile ilgili verilerini kullanarak endüstriyel yanma işlemi için bir teşhis aracı sunulmuştur [70]. Sunulan yöntem, farklı durumlar için özel uyarlamalar olmaksızın farklı alev türlerine uygulanmıştır. Petrol/gazla çalışan, kararlı/titreşimli, difüzyon/önceden karıştırılmış, hızlı/aşamalı karıştırma ve takılı/ayrık gibi sistemlere uygulanmıştır. İlgili çalışmada  $NO_x$  ve  $CO$  emisyonları görüntüleme işlemi ile hesaplanıp ölçüm cihazı ile ölçülen deęerlerle doğrulanmıştır. Aynı araştırmacılar tarafından benzer bir çalışmada, toz haline getirilmiş kömür yakıtlı endüstriyel kazanın yanma sürecinin verimliliğini arttırmak ve kontrolünü geliştirmek için bir model önerilmiştir [43]. Deneydeki ekipman deęişkenlerinin çeşitli olması bu çalışmaların üstün yönlerindedir. Ölçüm cihazıyla referans verilerin alınması bu tez çalışması kapsamında da tercih edilen çalışma metodolojisidir.

Alev tarafından doğal olarak yayılan radyal enerji araştırmacılar tarafından yaygın olarak kullanılmıştır [45, 58]. İlgili bir çalışmada toz haline getirilmiş kömür yakıtlı kazanlar CCD kameralarla izlenmiş ve gri görüntülerin ortalamaları alınarak Radyal Enerji Sinyal (RES) hesaplanmıştır [45]. İlgili çalışmada  $NO_x$  emisyonları ve termal verimlilik gibi kazan ünitesi performansları analiz edilmiştir. Gonzalez ve Gil yarı endüstriyel ölçekte brülörde dijital görüntü işleme yoluyla kömür yakıtlı alev karakterizasyonu üzerinde çalışmıştır [42]. Sıcaklık ve hava-yakıt oranına en hassas parametreler; parlaklık (ortalama gri deęer), dalgalanma genlięi (standart sapma) ve titreşim (ağırlıklı ortalama salınım frekansı) olduęu bildirilmiştir. Bununla birlikte, tespit edilen bağımlılıkları doğrulamak için yeni deneysel testlere ihtiyaç olduęu vurgulanmıştır. Bir diğerk çalışmada alev görüntüsü gri görüntüye çevrilirken kazan dört bölmeye ayrılmış her bölmenin deęişik yükseklik ve köşelerine dört'er adet kamera yerleştirilmiştir. Bu şekilde toplam 16 adet alev görüntüsü birleştirilerek  $20 \times 20 = 400$  piksel boyutunda bir görüntü elde edilmiştir. Renkli görüntü kanalları  $gri = 0.11 * kırmızı + 0.59 * yeşil + 0.23 * mavi$  formülasyonu ile gri görüntüye

dönüştürülmüştür [58]. Elde edilen bu gri seviye görüntü ve güç çıkışının ortalama oranından RES hesaplanmıştır. Hesaplanan RES ile brülörde kömür yüklemesi kontrol edilmiştir. Bu çalışmalar yakıt-hava oranını alev görüntüsü ile tahmin etmek için hangi özniteliklerin kullanılması gerektiği ile ilgili ipucu veren çalışmalar olarak önplana çıkmaktadır.

HSI renk uzayında alev'in ton (H) seviyesinin ışık alanının baskın dalga boyunu temsil edeceği bildirilmiştir [13, 71]. Bu varsayım ile CCD kamera için  $OH$ ,  $CH$ ,  $C_2$ ,  $NO_2$ ,  $CO$  ve  $H_2O$ 'nun dalga boyları ile H seviyesi arasında bir ilişki kurulmuştur. İlgili çalışmada alevin H seviyesinin spesifik bandının kazanın  $NO_x$  ve yanmayan  $CO$  ile yakından ilişkili olduğu bulunmuştur. Bu yaklaşım kendinden sonraki birçok çalışmaya ilham verip CCD kamera ile yanma sisteminin kontrol edilebileceği yaklaşımını desteklemektedir.

Bir diğer çalışmada CCD tabanlı bir görselleştirme sistemi kullanılarak pulverize yakıt girdabı brülöründe biyokütle yanma alevlerinin deneysel analizi yapılmıştır [72]. İlgili çalışmada ortalama gri değer, standart sapma, kurtosis ve çarpıklık ile titreşim frekansı öznitelik olarak kullanılmıştır.

Chen v.d. düşük maliyetli bir kamera ile elde edilmiş alev görüntülerinde izli markov modeli (HMM) olasılığını kullanarak yanma sistemi modelleyen bir çalışma sunmuştur [73]. Önerilen yöntem HMM ve çoklu TBA içermektedir. Chen'in başka bir çalışmasında gerçek zamanlı alev görüntüsü ile  $\lambda$ 'nın tahmin edilebileceği gösterilmektedir [66]. İlgili çalışmada 300 adet renkli alev görüntüsü kullanılmıştır. TBA'nın ilk iki bileşeninin toplam varyansın %98,8'ini açıkladığı ifade edilmiştir.

Toth v.d. gerçek zamanlı görüntüleme ile kazanın çıkış suyu sıcaklığını tahmin etmek için derin sinir ağlarını kullanmıştır [47]. İlgili çalışmada 20 görüntü özelliği ve 7 operasyonel parametre özniteliği olmak üzere toplam 27 öznitelik kullanılmıştır. Bu öznitelikler derin sinir ağına giriş olarak verilmekte ve kazanın çıkış suyu sıcaklığı tahmin edilmektedir. Bu çalışmada operasyonel parametrelerin kullanılması sistem maliyetini arttıran ve sistemin bakımını zorlaştıran bir dezavantajdır.

Jiang v.d tarafından sıcaklık ve yayılımı türetmek için kömür ateşlemeli yanma süreçlerinin renkli CCD görüntüsünü kullanarak görüntü işleme sistemi ve CCD kameranın spektroskopik öznitelikleri ve temsili dalga boylarından bağımsız bir yöntem sunulmuştur [65]. Sunulan yöntem ile hesaplanan sıcaklık, termokupl tarafından elde edilen değer ile

doğrulanmıştır. Görüntü işleme sistemi tarafından hesaplanan sıcaklık, termokupl tarafından alınan sıcaklığa kıyasla hata oranının en fazla %10'dan daha az olduğu bildirilmiştir.

Literatürdeki diğer çalışmalardan farklı olarak  $\lambda$  ve alev görüntüsü arasındaki ilişkiyi regresyon problemi olarak ele alan çalışmada Gri Seviye Eş Oluşum Matrisi (GLCM), B kanalı histogramı ve indirgenmiş B kanalı histogramı ile öznelikler çıkarılmıştır [9]. Elde edilen alev görüntüleri medyan ve ortalama filtreler uygulanarak ve filtresiz olarak her biri için ayrı ayrı YSA modeli ile regresyon edilmiştir. Sonuçta en yüksek ilişki medyan fitrenin uygulandığı görüntünün GLCM kullanılarak elde edilmiş öznelikler için bulunmuştur. Farklı bir çalışma olarak baca gazının çıkış içeriğini hemen tahmin etmek için alev görüntülerinden öznelik alan bir yöntem sunulmuştur [74]. İlk olarak, çok sayıda alev görüntüsü verisinden, TBA ile öznelik çıkarılmıştır. Bu öznelikler kullanılarak önerilen bir gauss modeli ile yanma işleminin stokastik modellenmesi, oksijen içeriğiyle ilişkili alevin stokastik doğasını yakalamak için kullanılmıştır.


Literatürdeki çalışmalar genel olarak değerlendirildiğinde alev formu ile  $\lambda$  arasında doğal bir ilişkinin olduğu ve bu ilişkiyi tam olarak ortaya koymak için daha kapsamlı çalışmaların yapılmasına ihtiyaç duyulduğu açıkça görülmektedir. Genel olarak mevcut çalışmalarda aşağıda belirtilen eksikliklerin yer aldığı görülmektedir:

- 1) Renkli alev görüntülerinin griye dönüştürülmesiyle alev karakteristiğinin kaybedilmesi.
- 2) Alev karakteristiğini en iyi ifade eden renk kanalının hangisinin olduğunun tam bilinmemesi nedeniyle sınırlı renk kombinasyonlarının kullanılması.
- 3) Alev görüntülerine ait global özneliklerinin kullanılması, böylece pozisyon bilgisinin kaybedilmesi.

Bu tez çalışmasında, yukarıda bahsedilen üç eksikliği ortadan kaldıran yaklaşımlar benimsenmiş ve alev formunu en iyi ifade edebilen özneliklerin araştırılmıştır. Yapılan deneysel çalışmalar tez çalışması kapsamında sunulan yöntemlerin başarısını ortaya koymaktadır.

### 3. ÖNERİLEN YANMA SİSTEMİ VE VERİ TOPLAMA

Bu tez çalışması kapsamında ev tipi bir kömür kazanında yanma odası görüntülenerek yanma süreci ve alev görüntüsü arasındaki ilişki araştırılmıştır. Bu kapsamda  $\lambda$ , emisyon ve BGS değerleri ile alev görüntüsü arasındaki ilişki nicel verilerle ortaya konulmuştur. Şekil 3.1’de tez çalışmasında kullanılan sistemin genel bir gösterimi yer almaktadır. Bu bölümde kullanılan ekipmanlar ve geliştirilen yazılım uygulamaları tanıtılmıştır.



Şekil 3.1 : Geliştirilen sistemin genel bir gösterimi

#### 3.1 Yanma Sistemi Deney Düzenegi


Yürütülen tez çalışmasında farklı amaçlar için birden çok deney yapılmıştır. Yürütülen deneysel çalışmalar kapsamında düşük çözünürlüklü ve yüksek çözünürlüklü endüstriyel kameranın aynı anda kullanıldığı, farklı çözünürlüklerde veri alındığı ve farklı kömür yükleme-bekleme süreleri için kömür kazanına giren hava girişinin ölçüldüğü deneyler yapılmıştır.  $\lambda$ , emisyon ve BGS regresyonları için 2 adet deney çalışması (deney 2 ve deney 3) ayrıntılı ele alınacaktır. Ayrıca endüstriyel ve bayağı web kamerasının aynı anda kullanıldığı bir adet deney (deney 8-a), kameraları kıyaslamak için kullanılacaktır. Bu 3 adet

deney ve diğer deneyler gerçek zamanlı fan kontrolü için tasarlanan regresyon modellerinin eğitimi için kullanılmıştır. İlgili bölümde kısaca bu deneylere değinilmiştir. Verilerin elde edildiği deney düzeneği, kullanılan deney ekipmanları ve gerçekleştirilen deneyler hakkında teknik bilgiler bu bölümde kısaca anlatılmıştır.

### 3.1.1 Deney kazanı

Yürütülen tez çalışmasında TÜBİTAK'ın desteklediği projenin ortağı olan MİMSAN AŞ. firmasının kendi bünyesinde ürettiği fındık kömürü yakıtlı kömür kazanı kullanılmıştır. İlgili firma fabrika ortamında test kazanı montajı yapmıştır. Farklı zamanlarda yürütülen deneysel çalışmalar neticesinde elde edilen veriler yürütülen tez çalışmasında kullanılmıştır. Çalışmaların yapıldığı kazan; yarım silindirik ve üç geçişli katı yakıtlı otomatik yüklemeli kat kaloriferidir. Deneysel çalışmalarda fındık kömürü kullanılmıştır. Kazanın arka ve yan tarafına bir gözetleme penceresi açılmıştır. İlgili pencereler ısıya dayanıklı cam ile kapatılmıştır. Bu gözetleme deliklerinden CCD kamera ile yanma süreci görüntülenerek alev görüntüsü alınmıştır. Deneysel ortamda kullanılan kömür kazanının ana parametreleri Çizelge 3.1'de verilmiştir. Şekil. 3.2'de kullanılan deney kazanı verilmiştir. İlgili kazan Türkiye'de üretilmekte olup ev tipi kullanım için tercih edilmektedir. Kazanın hava girişi ve kömür beslemesi otomatik olarak ayarlana bilmektedir. Deneysel veriler elde edilirken yanma işlemi için geçici rejim göz ardı edilmiştir. Geçici rejim tamamlandıktan sonra yanma süreci devam ederken CCD kamera ile alev görüntüsü alınmıştır. Aynı anda BGA'dan  $\lambda$  ve ilgili diğer emisyon değerleri alınarak gerçek zamanlı kaydedilmiştir. Analizör verileri saniyede bir kaydedilirken, kamera görüntüsü saniyede en az 2 (iki) adet olarak kaydedilmiştir. Analizör ve görüntü verileri tek bir bilgisayar kullanılarak eş zamanlı olarak kaydedilmiştir.

BGA cihazı kullanıcı tarafından geliştirilen programdan otomatik veri çekmeyi desteklememektedir. Araştırdığımız kadarıyla Testo firması ilgili cihaz için Software Development Kit/Yazılım Gelistirme Kiti (SDK) desteği vermemektedir. Bu nedenle BGA cihazı verileri firmanın sunduğu uygulama vasıtasıyla kaydedilmiştir. İlgili çalışmalar firmanın uygulaması vasıtasıyla baca gazından ölçülüp kaydedilen bu veriler vasıtasıyla yapılmıştır. Benzer olarak deney boyunca kamera ile alınan görüntülerde zaman etiketiyle aynı bilgisayara kaydedilmiştir. İlgili deneysel çalışmalar, alev görüntülerinin kaydedilen bu verileri vasıtasıyla gerçekleştirilmiştir.



Şekil 3.2 : Deney kazanı: (a) ön ve (b) arka görüntüleri

Çizelge 3.1 : Deney kazanının ana parametreleri

|                                     |                      |
|-------------------------------------|----------------------|
| Yakıt tipi                          | Fındık Kömürü        |
| Kazan kapasitesi                    | 85,000 kcal/h        |
| Görüntüleme penceresinin çapı       | 10 cm                |
| Baca gazı analiz cihazı             | Testo Ltd, testo 350 |
| Baca gazı analizörü- kazan mesafesi | 120cm                |
| Baca gazı analizörü- yer mesafesi   | 210 cm               |
| Baca çapı                           | 170 mm               |

### 3.1.2 Baca gazı analizörü ve referans verilerin elde edilmesi

Bu tez çalışması kapsamında yanma olayının alev görüntüsü ile yorumlanması sürecinde, yanma işlemi tanıma problemi (eksik, tam ve aşırı yanma) yerine regresyon problemi olarak ele alınmıştır. Dolayısıyla anlık olarak alınan verilerle geliştirilen modellerin eğitim, doğrulama ve test aşamasında referans verilere ihtiyaç duyulmaktadır.  $\lambda$ , emisyon değerleri,  $O_2$  miktarı ve BGS referans verileri BGA cihazıyla (Testo Ltd, testo 350) elde edilmiştir [75].  $\lambda$ 'da temel olarak baca gazındaki  $O_2$  ve  $CO_2$  miktarına bağlı olarak Denklem (3.1) ve (3.2)'deki gibi hesaplanmaktadır [76]. Yanma analizinin yapılabilmesi için  $O_2$  ve  $CO_2$  miktarının her ikisinin ölçülmesi gerekmektedir.

$$\lambda = 1 + \frac{O_2}{20.9 + O_2} \quad (3.1)$$

$$\lambda = \frac{(CO_2)_{max}}{CO_2} \quad (3.2)$$

BGA cihazıyla ölçüm yapılan parametrelerin ölçüm aralığı, doğruluğu, hassasiyeti ve diğer bazı teknik bilgileri Ek B'de verilmiştir. Daha ayrıntılı teknik bilgi için ilgili dokümanlara bakılabilir [75, 77]. BGA cihazı deneysel çalışma için istenilen hassasiyet ve çalışma koşullarını sağlamaktadır. Özellikle emisyon değerleri ve oksijen ölçümleri önemli olmaktadır. Çünkü önerilen modellerin referans değerleri BGA cihazı verilerinden sağlanmaktadır. Dolayısıyla ölçüm aralığı, doğruluk ve hassasiyet ilgili ölçüm parametreleri için önemli olmaktadır.

Gerçek ortamdan veriler elde edildikten sonra ilk olarak veri senkronizasyon işlemi gerçekleştirilmiştir. Böylece her bir görüntü için ilgili BGA cihazından alınmış veriler için bir referans değer olması sağlanmıştır. Eksik değerlerin hesaplanabilmesi için doğrusal aradeğer üretme yöntemi kullanılmıştır. Bu şekilde kamera ile alınan görüntüler ile BGA cihazından alınan değerler senkronize edilmiştir. Senkronizasyon işleminde eksik veriler (BGA verileri veya görüntü alınmadığı durumdaki) elenmiştir. Zaman etiketine göre aradeğer üretme işlemi ile veri eşleştirmesi yapılarak veriler çalışılmaya müsait hale getirilmiştir. Fazla olan görüntülere karşılık gelen eksik BGA veriler için Denklem (3.3) deki gibi ara değer üretme işlemi uygulanmıştır. Kaç adet aradeğer üretileceği saniyede alınan kare sayısına göre değişmektedir. Veri temizleme ve senkronizasyon işlemi için Matlab ortamında bir kullanıcı arayüzü tasarlanmıştır. Ek C'de tasarlanan yazılımlar başlığında ilgili yazılımlar tanıtılmıştır.

$$D'_i = D_t + (i - 1)x \frac{D_{t+1} - D_t}{N}, \quad i = 1, 2, 3, \dots, N \quad (3.3)$$

Bu denklemde,  $N$  kaç adet aradeğer üretileceğini (ideal durumda saniyede yakalanan kare sayısına eşit olmakta),  $D_t$  ve  $D_{t+1}$  ölçüm alınan ardışık iki BGA verisini ve  $D'_i$  ise alev görüntüsüne karşılık gelen aradeğer üretilen BGA verisini ifade etmektedir.

### 3.1.3 Kameralar ve yanma odasının görüntülenmesi

Bu tez çalışması kapsamında optimum maliyetli bir sistem tasarlanmak istenildiğinden dolayı bir adet yüksek maliyetli (acA1600-20uc - Basler ace [78]) ve 2 adet

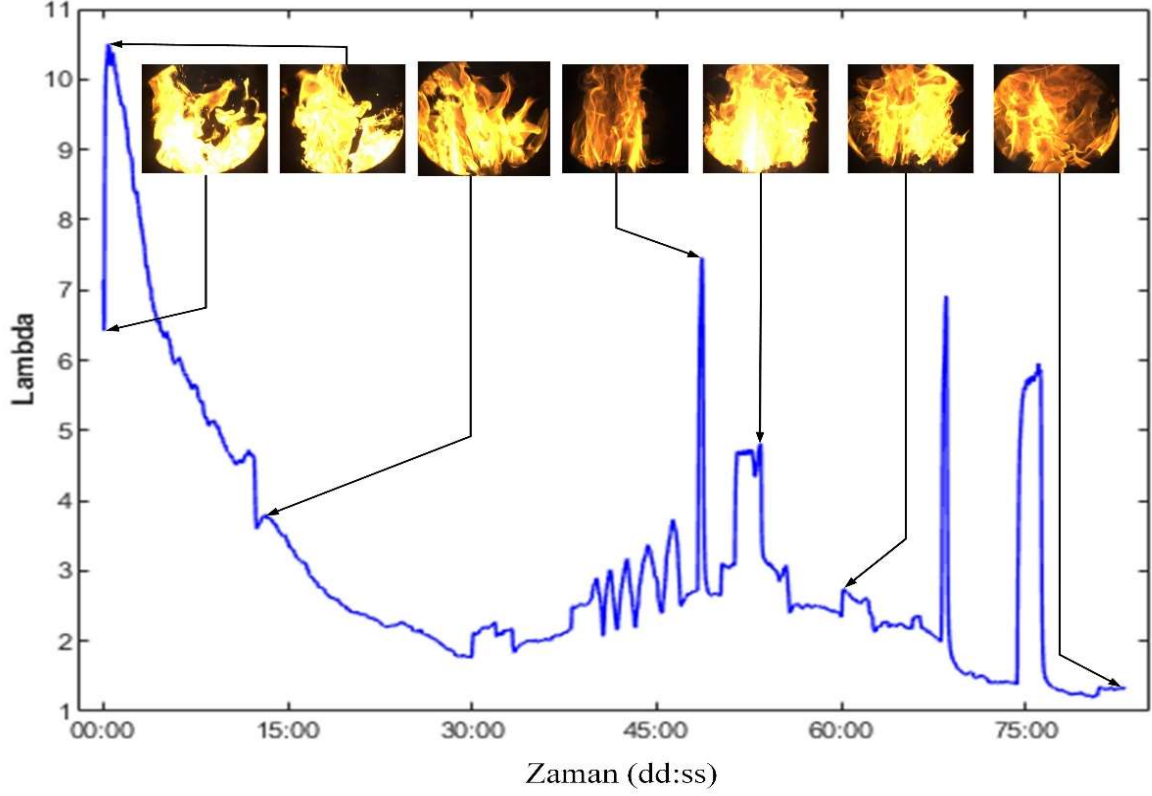
de düşük maliyetli web kamerası (Microsoft, LifeCam Studio [79] - Logitech C310 [80]) kullanılmıştır. Şekil 3.3'te ilgili kameralar gösterilmektedir.



**Şekil 3.3 :** Kullanılan kameralar; (a) Basler, (b) Logitech ve (c) Microsoft

1626x1234 piksel çözünürlüğü sağlayan acA1600-20uc - Basler ace kamerasının teknik özelliklerine [78] linkinden erişilebilir. Diğer iki kamera basit web kamerası olup 720p görüntü alınmasını destekleyen kameralardır. Basler kamera kendi özel programı üzerinden veri alınmasına izin verirken diğer iki kamera için genel video yaklama programlarını kullanmak yerine özel bir yazılım geliştirilmiştir. Geliştirilen yazılım ile kamera özellikleri ayarlanıp saklanabilmekte ve bir sonraki çalıştırılmada saklanan ayarlarla kameralardan görüntü alınmasına imkân vermektedir. Basler kamera çok kaliteli görüntü getirmesine rağmen pratikte bazı dezavantajları vardır. Basler kamera her şeyden önce pahalı bir endüstriyel kameradır. Basler kamerayı kontrol etmek için ya ilgili firmanın sağladığı program kullanılmak zorunda veya daha önce benzer bir çalışmada geliştirmek zorunda olduğumuz [81] ilgili firmanın sağladığı C++ kütüphanesi kullanılarak uygulama geliştirmek gerekmektedir. Firmanın sağladığı programla veri kaydı yapılabilmekte, ancak uygulama geliştirilmemektedir. C++ kütüphanesini kullanarak uygulama geliştirmek mümkün olmakla birlikte hem yazılım süreci zor olmakta hem de gömülü bilgisayar hedeflenerek geliştirilen uygulamalar için sistem kaynaklarının efektif kullanılması açısından efektif bir çözüm değildir.

Şekil 3.4'te gerçekleştirilen deney-2 verileri için BGA'yla ölçülen  $\lambda$  değerinin değişimi ve ilgili bazı  $\lambda$  değerleri için Basler kamera ile alınmış alev görüntüleri verilmiştir. Şekilden görüldüğü gibi yanma süreci görüntülenerek alınan alev görüntüleri ile  $\lambda$  değerleri arasında bir ilişkinin varlığı söz konusudur. Bu ilişkinin matematiksel olarak ortaya konulması bu tez çalışmasının temel hedefidir.




Şekil 3.4 : Deneysel ortamda  $\lambda$  değışiminin grafiksel gösterimi ve bazı alev görüntüleri

### 3.1.4 Gömülü bilgisayar

Tez çalışması kapsamında Matlab ortamında ilgili model eğitimleri yapıлып test işlemleri yapılmıştır. Fakat nihai hedef olarak C++ dilinde yazılmış gömülü bilgisayarda kořabilecek gerçek zamanlı bir uygulama hedeflenmiştir. Günümüzde gömülü bilgisayarlar hem işlem kabiliyetleri hem de çevresel donanım desteęi açısından kişisel bilgisayarlarla hemen hemen aynı kabiliyetlere sahiptir. Şekil 3.5'te Latte Panda gömülü bilgisayar ve çevresel donanımları verilmiştir.

Çoęu gömülü bilgisayarda artık özel işletim sistemi yerine kişisel bilgisayarlardaki işletim sistemin aynısı veya biraz özelleştirilmiş hali bulunmaktadır. Bu tez çalışması kapsamında USB'den kamera bilgisini alıp çıkış bacağından fan kontrol işareti göndermeye müsait olan Latte Panda gömülü bilgisayarı tercih edilmiştir. İlgili gömülü bilgisayarda Windows 10 işletim sistemi yüklemeye müsait olup C++ ile geliştirilmiş .Net uygulamalarını çalıştırmaya müsaittir. Fan kontrol işareti için ilgili gömülü bilgisayardaki Pulse Width Modulation/Sinyal Genişlik Modülasyonu (PWM) çıkış portu kullanılmıştır. Latte Panda giriş-çıkış işlemler için arduino kart entegresi içermektedir. Arduino kartın çok yaygın olması Latte Panda gömülü bilgisayar ile icra edilen uygulamalar için artı bir değerdir. Çünkü port adresleri aynı olmasından dolayı arduino için geliştirilen birçok uygulamanın

aynen kullanılmasını desteklemektedir. Bu durum uygulama geliştiriciler için kolaylık sağlayan ve Latte Panda'nın seçilmesi için artı bir özellik olmaktadır.




Şekil 3.5 : Latte Panda gömülü bilgisayar ve çevresel donanımlar [82]


### 3.2 Veri Kayıt Yazılımı

Deneyisel çalışmalarda iki adet kameradan aynı anda görüntü alınmıştır. İncelediğimiz kadarıyla iki adet kameradan aynı anda görüntü alınmasına izin veren, kamera özelliklerini kaydedip yeniden kullanıldığı bir evrensel görüntü yakalama programı yoktur. Bu yüzden yürütülen deneyisel çalışmalarda kullanılmak üzere web kameralar için evrensel bir sürücü yazılmasına karar verilmiştir. Burada temel olarak hedeflenen iki kameradan eş zamanlı olarak istenilen saniyedeki kare sayısı (FPS) ve istenilen çözünürlükte görüntü alınmasına izin veren bir programın geliştirilmesidir. Ayrıca kameraların kullanıcı tarafından değiştirilebilen parametrelerinin ayarlanmasına izin veren, ilgili kamera için bu ayarları kaydeden ve program tekrar çalıştırıldığında bu ayarlar ile kamerayı başlatabilen bir program geliştirilmesi hedeflenmiştir. Şekil 3.6'da geliştirilen kayıt programının ekran görüntüsü verilmiştir. Kayıt programı geliştirilirken kolaylık olması açısından VC++ .Net ortamında OpenCV kütüphanesi kullanılarak icra edilmiştir. İlgili yazılım ile iki kameradan


aynı anda veri alınması sağlanmıştır. Saniyede alınacak kare sayısını ve kayıt yerini kullanıcının belirlemesine imkân verecek şekilde yazılım geliştirilmiştir. İlgili program kayıt ve kamera ayarlarının belirlenmesi olmak üzere iki sekmeden oluşmaktadır.



(a)



(b)



(c)

**Şekil 3.6 :** Geliştirilen veri kayıt yazılımı. (a) Kayıt sayfası, (b) Video kontrol, (c) “Video Renk İşlemci/Yükselteç ayarları

Video kayıt uygulaması tek kamera ile görüntü almayı da destekleyecek şekilde farklı bir versiyonu tasarlanmıştır. Bu durumda sadece tek kameradan görüntü alınacağı için ikinci kamera için ayarlama kısımları kaldırılmıştır. Geri kalan her şey ana geliştirilen programla aynıdır. Bu yüzden ayrıca anlatılmamıştır.

### 3.3 Deneysel Verilerin Toplanması

Bu tez çalışması kapsamında elde edilen veriler TÜBİTAK 117M121 nolu proje kapsamında elde edilmiştir. MİMSAN A.Ş fiması proje ortağı olup deneysel çalışmalar ilgili firmada, test ortamında yapılmıştır. Yürütülen tez çalışmasından önce proje ekibindeki diğer kişiler tarafından TÜBİTAK 114M116 nolu proje başarı ile yürütülmüştür. İki adet deney verisi bu ilk projeden alınmıştır. Diğer 8 adet deney bu proje kapsamında gerçekleştirilmiştir. Ayrıca proje ekipmanında oluşan arızalardan dolayı iki adet deney başarısız olmuştur. Başarılı bir şekilde yürütülen 8 adet deney verisi ve önceki projeden elde edilmiş iki adet deney verileri Çizelge 3.2’de özet halinde verilmiştir. Deney isimlendirmesinde deney numarası aynı günde yapılan deneyleri ifade etmektedir. Deneyler yapılırken gözetleme deliğindeki islenme veya BGA cihazından kaynaklanan problemlerden dolayı deney durdurulup yeniden başlatıldığında deney isimleri harfle ifade edilmiştir (örnek deney 4-a gibi). Deney 9 gerçek zamanlı çalışma uygulaması için tam ekipmanla yapılan ilk deney olup proje ekibindeki makine mühendisliği ekibince kontrol uygulaması geliştirmek için yapılmıştır. Bu deneyde diğer kameradan veri kaydı deneyden bağımsız olarak yapılmıştır. Deney-10 kontrol algortiması geliştirilerek bunun test edildiği gerçek zamanlı deneydir. Bu deney verileri gerçek zamanlı fan kontrol uygulaması bölümünde ayrıntılı ele alınmıştır.

**Çizelge 3.2 :** Tez kapsamında kullanılan deneysel veriler için teknik bilgiler

| Deney No | Deney Tarihi | Deney Saati | Kamera-1 Çöz. | Kamera-2 Çöz. | Görüntü Adedi | $\lambda$ Aralığı | $\lambda$ Ort. |
|----------|--------------|-------------|---------------|---------------|---------------|-------------------|----------------|
| 1        | 04.06.2015   | 00:18       | 1200x1200     | -             | 17902         | 1,71-6,20         | 2,26           |
| 2        | 04.06.2015   | 15:00       | 1200x1200     | -             | 9956          | 1.21-10.50        | 3.11           |
| 3        | 19.02.2018   | 13:44       | 800x600       | 800x600       | 16908         | 0.98-2.63         | 1.87           |
| 4-a      | 07.03.2018   | 15:21       | 800x600       | 720x480       | 3986          | 1.79-14.07        | 1.99           |
| 4-b      | 07.03.2018   | 16:10       | 800x600       | 720x480       | 4770          | 1.46-2.16         | 1.81           |
| 5-a      | 08.03.2018   | 13:17       | 800x600       | 800x600       | 3523          | 1.92-2.57         | 2.22           |
| 5-b      | 08.03.2018   | 14:18       | 800x600       | 800x600       | 6479          | 1.82-7.57         | 2.29           |
| 5-c      | 08.03.2018   | 15:33       | 800x600       | 800x600       | 4924          | 1.74-2.47         | 2.05           |
| 6-a      | 09.03.2018   | 10:23       | 800x600       | 800x600       | 7003          | 1.10-14.30        | 2.17           |
| 6-b      | 09.03.2018   | 12:42       | 800x600       | 800x600       | 6994          | 1.17-13.11        | 1.95           |
| 6-c      | 09.03.2018   | 15:29       | 640x480       | 800x600       | 1990          | 1.40-8.47         | 1.91           |
| 7        | 16.08.2018   | 15:52       | 640x480       | 800x600       | 1199          | 1.03-1.87         | 1.41           |
| 8-a      | 17.08.2018   | 14:59       | 1624x1234     | 640x480       | 2979          | 1.37-2.94         | 2.05           |
| 8-b      | 17.08.2018   | 15:36       | 1624x1234     | 640x480       | 2640          | 1.28-6.32         | 1.55           |
| 8-c      | 17.08.2018   | 16:23       | 1624x1234     | 640x480       | 2456          | 1.24-1.59         | 1.36           |
| 9-a      | 14.02.2019   | 11:41       | 640x480       | 1280x1024     | 5137          | 1.51-3.87         | 2.47           |
| 9-b      | 14.02.2019   | 13:45       | 640x480       | 1280x1024     | 5410          | 1.2-1.67          | 1.35           |
| 10-a     | 15.02.2019   | 11:23       | 800x600       | 640x480       | 2675          | 1.37-1.69         | 1.50           |
| 10-b     | 15.02.2019   | 12:10       | 800x600       | 640x480       | 9842          | 1.30-2.33         | 2.01           |

#### 4. ALEV GÖRÜNTÜLERİNDEN ÖZNETELİK ÇIKARMA

Bu bölümde alev görüntülerinden öznitelik elde etme yaklaşımları ele alınmıştır. Temel olarak iki farklı yaklaşımla elde edilen öznitelikler ayrıntılı incelenmiştir. Bunlardan ilkinde farklı matematiksel yaklaşımlarla modelleme tekniğiyle elde edilen öznitelik vektörlerinin eşleştirme doğruluğu üzerindeki etkisi incelenmiştir. İkincisinde alev görüntüsünden direk öznitelik elde edildiği klasik yaklaşımlardır. Bu yaklaşımlar alev görüntüsünden anlamlı bilgi elde edilirken önerilen yaklaşımların zayıf yönleri değerlendirilerek yeniden yorumlanmıştır.

Modelleme yaklaşım ile yanma sürecinde alev formuna ait kamera görüntüleri giriş olarak alınmakta ve çıkışta görüntünün modelleme sonucu öznitelikleri elde edilmektedir. Modelleme yaklaşımları, görüntü kanallarını kullanmaktadır. Renkli alev formu görüntüleri RGB olarak üç kanaldan oluşmaktadır. İşlem maliyetinin düşüklüğü açısından üç renk kanalı tek kanala (gri) indirgene bilmektedir. Farklı indirgenme yaklaşımına ait denklemler, Denklem (4.1-4) arasında verilmiştir.

$$Gr1_{i,j} = \frac{R_{i,j} + G_{i,j} + B_{i,j}}{3} \quad (4.1)$$


$$Gr2_{i,j} = R_{i,j} * 0.11 + G_{i,j} * 0.59 + B_{i,j} * 0.3 \quad (4.2)$$

$$Gr3_{i,j} = \frac{R_{i,j} + G_{i,j}}{2} \quad (4.3)$$

$$Gr4_{i,j} = R_{i,j} * 0.3 + G_{i,j} * 0.1 + B_{i,j} * 0.6 \quad (4.4)$$

Denklem (4.1)'de RGB renk kanallarının ortalama yoğunluk bilgisini vermektedir. Denklem (4.2)'de en yaygın kullanılan gri görüntü elde etme yaklaşımı verilmiştir. Denklem (4.2) deki gri seviye elde etme yöntemi NTSC (parlaklık (Y) ve renklilik (I ve Q)) renk uzayında, parlaklık (Y) bileşenin hesaplanmasıyla eşdeğerdir [83]. Denklem (4.3) ve (4.4) de gösterilen yaklaşımlar tez kapsamında etkisi incelenmek istenilen dönüşümlerdir. Alev sıcaklığının hesaplanması hakkında sadece R ve G renk kanallarının kullanıldığı bazı

çalışmaların olduğu bilinmektedir [53, 54, 65, 67]. Bu nedenle sadece iki kanalın renk ortalaması Denklem (4.3)'te hesaplanmaktadır. Benzer şekilde literatürde sadece B kanalı kullanan çalışmalar bulunmaktadır [9]. Bu nedenle Denklem (4.4)'te B kanalı, etkisinin artırıldığı bir dönüşüm kullanılmıştır. Buna göre Şekil 4.1'de örnek bir alev görüntüsüne ait renk kanallarının görseli verilmektedir.



**Şekil 4.1 :** Örnek bir alev görüntüsüne ait kanallar. (a) orijinal alev görüntüsü ve kanallar: (b) R, (c) G, (d) B, (e-h) Gr1-4

Bu tez çalışmasında  $k$  değişkeniyle görüntü kanalları ifade edilirken, Şekil 4.1 de verilen görüntüler veya ızgaralanmış bu görüntülerden alınmış ilgilenilen yerel pencere (ROI) kastedilecektir. Alev görüntülerindeki parlaklık değişimlerinin lokal olarak değerlendirilebilmesi için gridleme tekniği kullanılmaktadır. Şekil 4.2'te örnek bir alev görüntüsünün gridlenmesi gösterilmektedir.



**Şekil 4.2 :** Alev görüntüsünün gridlere bölünmesi

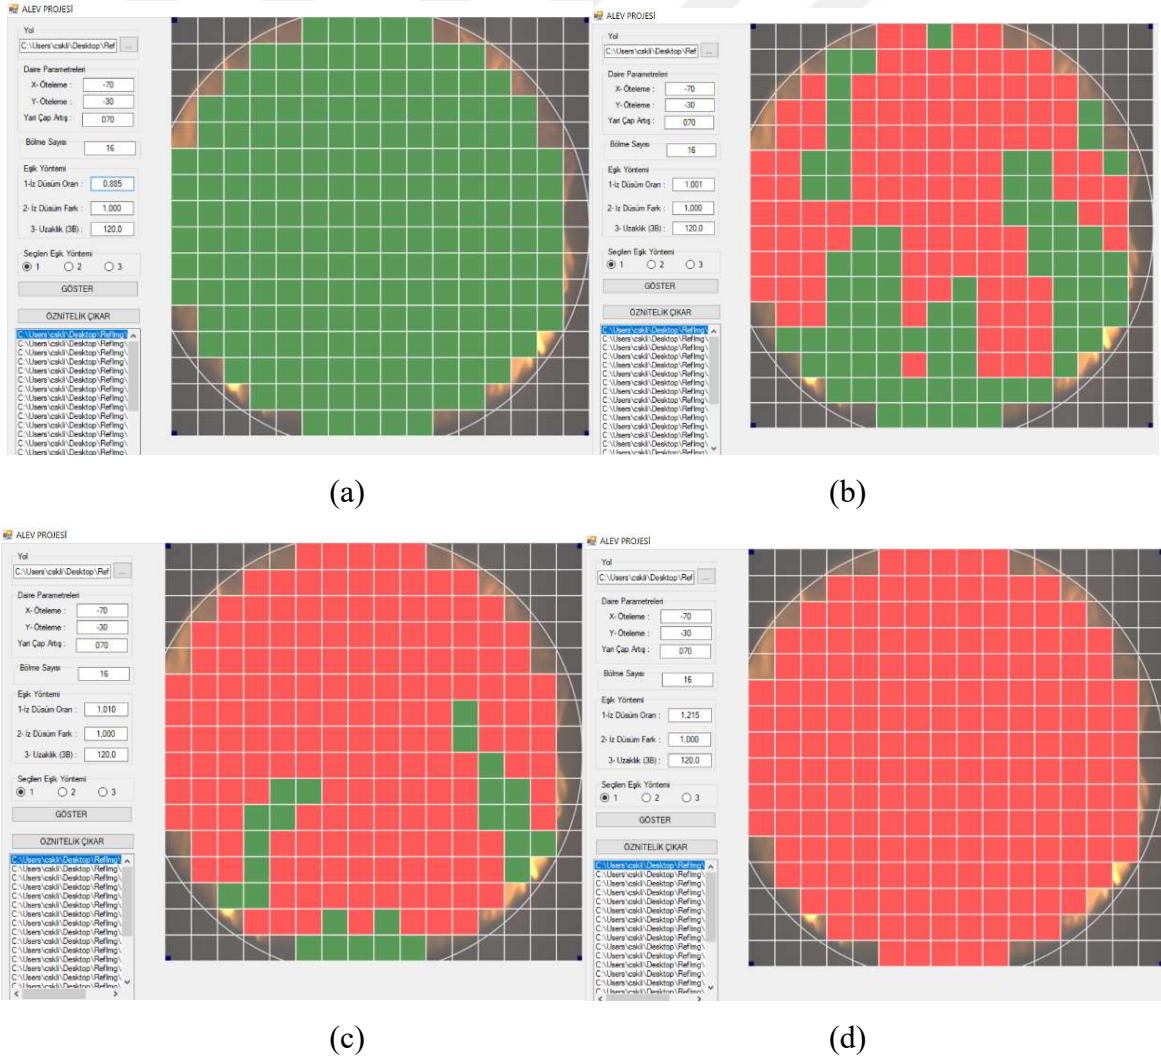
Alev görüntüsünden öznitelik elde edilirken konum bilgisini kaybetmemek için gridleme yaklaşımıyla alev görüntüsü  $T$  adet yerel pencereye bölünmektedir ( $\{k_1, k_2, \dots, k_T\} = \mathbf{Gridle}(\text{Alev Görüntüsü})$ ).

Herhangi bir yerel pencere (grid) görüntüsü  $k_t$  değişkeniyle ifade edilirken,  $t$  değişkeni grid indisini belirtir. Her bir gridin satır ve sütun sayısı  $m$  ve  $n$  değişkenleriyle ifade edilir.

#### 4.1 RGB Renk Uzayında İdeal Yanma Noktası Metodu

Baca gazından ölçülen  $\lambda$  değerinin optimal aralık içerisinde kaldığı durumlardaki görüntüler incelenmiş ve optimal yanmanın RGB uzayında renk vektörü [143, 66, 22] olarak belirlenmiştir. Herhangi bir alev görüntüsünün optimal yanma renk vektörüne uzaklığının hesaplanabilmesi için ilk olarak ROI içerisindeki görüntü belirlenen yatay ve dikey değerlere göre ızgaralanmaktadır. Izgara renk değerleri, ızgara içerisindeki piksellerin renk ortalamasıyla hesaplanmaktadır. Alev görüntüsüne ait olmayan pikselleri hesaba katmamak için, ızgaradaki her bir pikselin ROI içerisine çizilen çember içinde olup olmadığı göz önüne alınmaktadır. Bu yaklaşımlar ızgaralanmış alev görüntüsünün her bir ızgara ortalamasının optimal yanma vektörüne olan uzaklığı referans alınarak geliştirilen yöntemlerdir. Temelde 2 olmak üzere 3 farklı yaklaşımla gerçekleştirilmiştir. Uzaklık değeri belirlenen eşik değerinden küçükse kırmızı (ideal yanma), büyük eşitse yeşil (ideal olmayan yanma) olarak renklendirilmektedir. Bu şekilde 0-1 değerlerinden oluşan ızgara sayısı kadar öznitelik elde edilmektedir.

Kullanıcın belirlediği eşik parametresi optimum yanma yerel pencerelerini belirlemede en önemli kriter olmaktadır. Şekil 4.3'te farklı eşik değerleri kullanıldığında elde edilen sonuçlar gösterilmektedir. Eşik değerinin çok küçük olması tüm görüntünün optimum yanmada olmamasına (yeşil) sağlarken (a), çok büyük alınması tüm gridlerin optimum yanmada (kırmızı) (d) neden olmaktadır. Farklı ara değerlerde değişken bir sonuç (b, c) elde edilebilmektedir. Eşik değerlerinin optimum değeri deneysel çalışma sonucu belirlenmiştir. Eşik değeri belirlenirken optimum yanma anındaki bir görüntü alınmıştır. Tüm ızgaralar ideal olmayan yanma olacak şekilde alt eşik sınırı (mümkün olan en büyük değer), tüm ızgaralar ideal yanma olacak şekilde en küçük eşik değeri için üst eşik sınırı olarak seçilmiştir. Daha sonra bu alt sınır ve üst sınır arasında eşit uzaklıkta 10 adet eşik değeri alınarak hepsi için regresyon modelleri sonuçları elde edilmiştir. Bu nicel veriler değerlendirilerek 3 yöntem için optimum eşik değerleri belirlenmiştir.



Şekil 4.3 : Aynı görüntü için farklı eşik değerlerinde optimum yanmanın değişimi


Öznitelik elde edilirken; ikili görüntü (0-1), biaslı görüntü (1-2), satır toplamı, sütun toplamı, ikili satırın onluk karşılığı, ikili sütunun onluk karşılığı, satır-sütun toplamı ve ikili satır-sütun onluk karşılığı öznitelik vektörleri olarak alınmıştır. Bu özniteliklerin performans kriterleri deneysel çalışmalar sonucu elde edilen nicel veriler değerlendirilerek yapılmıştır. Şekil 4.4'te örnek bir görüntü için birinci satır ve birinci sütundan öznitelik elde etme yaklaşımları için öznitelik vektörleri verilmiştir. Bu deneysel çalışmada görüntü 16x16'lık ızgaralara bölünmüştür. Yani toplam ikili görüntü öznitelik sayısı 256 olmaktadır. Daire içindeki ızgaralar tek alındığında 193 adet öznitelik olmaktadır. Satır-sütun toplamı ile satır-sütunun onluk karşılığının alındığı yöntemlerde öznitelik sayısı 16 olmaktadır. Satır-sütunun toplam ile onluk karşılığından ayrı ayrı öznitelik elde edilip özniteliklerin birleştirildiği yöntemlerde öznitelik sayısı 32 olmaktadır.

| Yöntem                                      | Öznitelik             |
|---|-----------------------|
| İkili Görüntü<br>(Tüm Görüntü - İlk Satır)  | 0000010011000000      |
| İkili Görüntü<br>(Daire İçi - İlk Satır)    | 10011                 |
| Biaslı Görüntü<br>(Tüm Görüntü - İlk Satır) | 1111121122111111      |
| Biaslı Görüntü<br>(Daire İçi - İlk Satır)   | 21122                 |
| Satır Toplam                                | 3                     |
| Satır Onluk                                 | $(1100100000)_2=800$  |
| Sütun Toplam                                | 6                     |
| Sütun Onluk                                 | $(1111100000)_2=2016$ |

Şekil 4.4. Örnek bir görüntü için birinci satır ve sütundan öznitelik elde edilmesi

#### 4.1.1 İdeal yanma rengine projeksiyon

Optimum yanma rengine projeksiyon yaklaşımına dayanan bu yöntemde iki farklı eşikleme yöntemi kullanılmıştır. Yerel bir ızgaranın optimum yanmayı temsil edip etmediğine Şekil 4.5'te gösterilen hesaplamalarla karar verilir. Buna göre  $x_1$  [0,0,0] noktasını,  $x_2$  optimal yanma renk değerini [143,66,22] ve  $x_0$   $k_t$ 'nin ortalama renk yoğunluğunu  $[\mu_R, \mu_G, \mu_B]$  temsil ettiği düşünüldüğünde  $x_3$  projeksiyon noktası Denklem (4.5)'deki gibi hesaplanır.



Şekil 4.5 : Izgara renginin optimum yanma vektörüne projeksiyonu

$$x_3 = \frac{x_2^T x x_0}{x_2^T x x_2} x x_2 = \begin{bmatrix} R_{x_3} \\ G_{x_3} \\ B_{x_3} \end{bmatrix} \quad (4.5)$$

Benzerlik ölçütü için  $x_3$  ve  $x_0$  noktalarının  $x_1$  noktasına göre genlikleri hesaplanır. Hesaplanan bu genliklerin oranları (Denklem (4.6)) ve mutlak farkları (Denklem (4.7)) eşik değerden büyük olup olmadığına göre gridin optimum yanmayı temsil edip etmediğini belirlemek için kullanılmıştır.

$$k_t = \begin{cases} 1 \text{ (kırmızı)} & \frac{|x_3|}{|x_2|} < Eşik1 \\ 0 \text{ (yeşil)} & \frac{|x_3|}{|x_2|} \geq Eşik1 \end{cases} \quad (4.6)$$

$$k_t = \begin{cases} 1 \text{ (kırmızı)} & |x_3 - x_2| < Eşik2 \\ 0 \text{ (yeşil)} & |x_3 - x_2| \geq Eşik2 \end{cases} \quad (4.7)$$

#### 4.1.2 İdeal yanma noktasına uzaklık metodu

RGB renk uzayında ızgara görüntüsünün her bir renk kanalı için ortalama yoğunluk değerinin ideal yanma noktasına ([143, 66, 22]) olan uzaklığının belli bir eşik değerden küçük olup olmadığına dayanmaktadır. Izgaranın ortalama yoğunluk değeri  $R_I G_I B_I$  olmak üzere Denklem (4.8)'deki gibi ideal yanma hesaplanmaktadır. Izgara ortalama yoğunluk değeri kürenin içine düşüyorsa ideal yanma, kürenin dışında kalırsa ideal olmayan yanma olarak temsil edilmektedir. Bu yaklaşım ideal yanmanın 3B uzayda belli bant aralığında olabileceği varsayımı test etmek için oluşturulan matematiksel bir yaklaşımdır.

$$k_t = \begin{cases} 1 \text{ (kırmızı)} & \sqrt{(143 - R_t)^2 + (66 - G_t)^2 + (22 - B_t)^2} < Eşik3 \\ 0 \text{ (yeşil)} & \sqrt{(143 - R_t)^2 + (66 - G_t)^2 + (22 - B_t)^2} \geq Eşik3 \end{cases} \quad (4.8)$$

## 4.2 İdeal Yanma Bölgesi Görüntüsüyle Modelleme

İdeal yanma sürecindeki bir görüntüden ideal yanma bölgesi seçilmekte ve alev görüntüleri seçilen bu bölgeye benzerliği değerlendirilerek oluşturulan matematiksel modelleme yaklaşımına dayanmaktadır. Seçilen bölgenin parametrik hale dönüştürülebilmesi için Denklem (4.9) ve (4.10) kullanılmıştır.

$$\mu_k = \frac{1}{m \times n} \times \sum_{i=1}^m \sum_{j=1}^n k_{i,j} \quad (4.9)$$

$$\sigma_k = \sqrt{\frac{1}{m \times n} \times \sum_{i=1}^m \sum_{j=1}^n (k_{i,j} - \mu_k)^2} \quad (4.10)$$

Burada  $k$ , seçilen bölgenin renk kanalını ifade eder ve  $k \in \{R, G, B, Gr1, Gr2, Gr3, Gr4, H\}$  olmaktadır.  $m$  ve  $n$ ,  $k$ 'nın satır ve sütun değerini gösterir.  $k_{i,j}$  ilgili piksel değerini ifade etmektedir.

Elde edilen alev görüntülerinin ideal görüntüye benzerliği Denklem (4.11) da gösterildiği gibi hesaplanmaktadır. Hesaplanan benzerlik değerleri 0-1 aralığındadır. Benzerlik değerleri Denklem (4.12)'da gösterildiği gibi farklı eşik değerleri kullanılarak 0 (ideal görüntüye benzemez) veya 1 (ideal görüntüye benzer) sonucu elde edilmektedir. Benzerlik sonucunun öznitelik vektörüne dönüştürülmesi için alev görüntüleri ızgaralanır. Her bir ızgaranın ideal yanma rengine benzerliği, ızgara içerisindeki 0 veya 1 değerlerinin çokluğuna göre belirlenir.

$$P(k_{i,j} | \mu_k, \sigma_k) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp\left(-\frac{(k_{i,j} - \mu_k)^2}{2(\sigma_k)^2}\right) \quad (4.11)$$

$$\bar{O}V_t = \left[ \frac{1}{m \times n} \times \sum_{i=1}^m \sum_{j=1}^n 1\{P(k_{i,j} | \mu_k, \sigma_k) < P_{esik}\} \right] \quad (4.12)$$


Burada  $t$  grid indisini,  $[ ]$  notasyonu, yuvarlatma işlemini ifade etmektedir.

Yuvarlama sonucu grid öznitelik değeri 0 (sıfır) veya 1 (bir) olmaktadır. Şekil 4.6'da örnek bir alev görüntüsünün renk kanallarının gridlenmesi ve her bir gridin ideal yanma rengine benzerliğine göre özniteliklerinin elde edilmesi gösterilmiştir. Aşırı yanma (beyazımsı bölgeler) ve eksik yanma (koyu bölgeler) siyah olarak etiketlenmekte, sarı/turuncu rengindeki bölgeler ise ideal yanma bölgesi olup beyaz renkle gösterilmiştir. Bir görüntü bölgesinin ideal yanma olup olmaması renk kanalına ve eşik değerine göre değişebilmektedir. Bu kapsamda her bir renk kanalı için deneysel çalışma sonucu farklı eşik değerler alınmıştır. Bu eşik değerler Çizelge 4.1'de verilmiştir.

**Çizelge 4.1 :** Alev görüntüsünün farklı renk kanalları için eşik değerler

| Renk Kanalı | Eşik Değeri  | Renk Kanalı | Eşik Değeri  |
|-------------|--------------|-------------|--------------|
| R           | $< 10^{-14}$ | Gr2         | $> 10^{-12}$ |
| G           | $> 10^{-12}$ | Gr3         | $> 10^{-12}$ |
| B           | $> 10^{-2}$  | Gr4         | $> 10^{-7}$  |
| Gr1         | $> 10^{-12}$ | H           | $< 10^{-11}$ |

Öznitelik elde edilirken; ikili görüntü (0-1), biaslı görüntü (1-2), satır toplamı, sütun toplamı, ikili satırın onluk karşılığı, ikili sütunun onluk karşılığı, satır-sütun toplamı ve ikili satır-sütun onluk karşılığı öznitelik vektörleri olarak alınmıştır. Şekil 4.7'de örnek bir görüntünün R kanalı için birinci satır ve birinci sütundan öznitelik elde etme yaklaşımları verilmiştir. Bu deneysel çalışmada görüntü 16x16'lık ızgaralara bölünmüştür. Yani toplam ikili görüntü öznitelik sayısı 256 olmaktadır. Satır ve sütundan elde edilen yöntemlerde öznitelik boyutu 16 olmaktadır. Hem satır hemde sütunun birlikte kullanıldığı yöntemlerde öznitelik boyututu 32 olmaktadır. Ayrıca ikili resim, satır-sütun toplamı, satır-sütun onluk karşılığı ve satır-sütunün birlikte kullanıldığı öznitelik yaklaşımları için RG, RB, GB ve RGB renk kanalları için öznitelik birleştirme yöntemi ile öznitelikler elde edilmiştir.



Şekil 4.6 : Alev görüntü kanalları ve model sonucundaki öznelik görüntüleri: (a-b) R, (c-d) G, (e-f) B, (g-n) Gr1-4 ve (p-r) H (HSI-Ton)

| Yöntem                     | Öznitelik        |
|----------------------------|------------------|
| İkili Görüntü (İlk Satır)  | 0001111101110000 |
| Biaslı Görüntü (İlk Satır) | 1112222212221111 |
| Satır Toplam               | 8                |
| Satır Onluk                | 8048             |
| Sütun Toplam               | 10               |
| Sütun Onluk                | 8184             |
| Satır-Sütun Toplam         | [8,10]           |
| Satır-Sütun Onluk          | [8048,8184]      |

Şekil 4.7 : R kanalı için birinci satır ve sütundan öznelik elde edilmesi

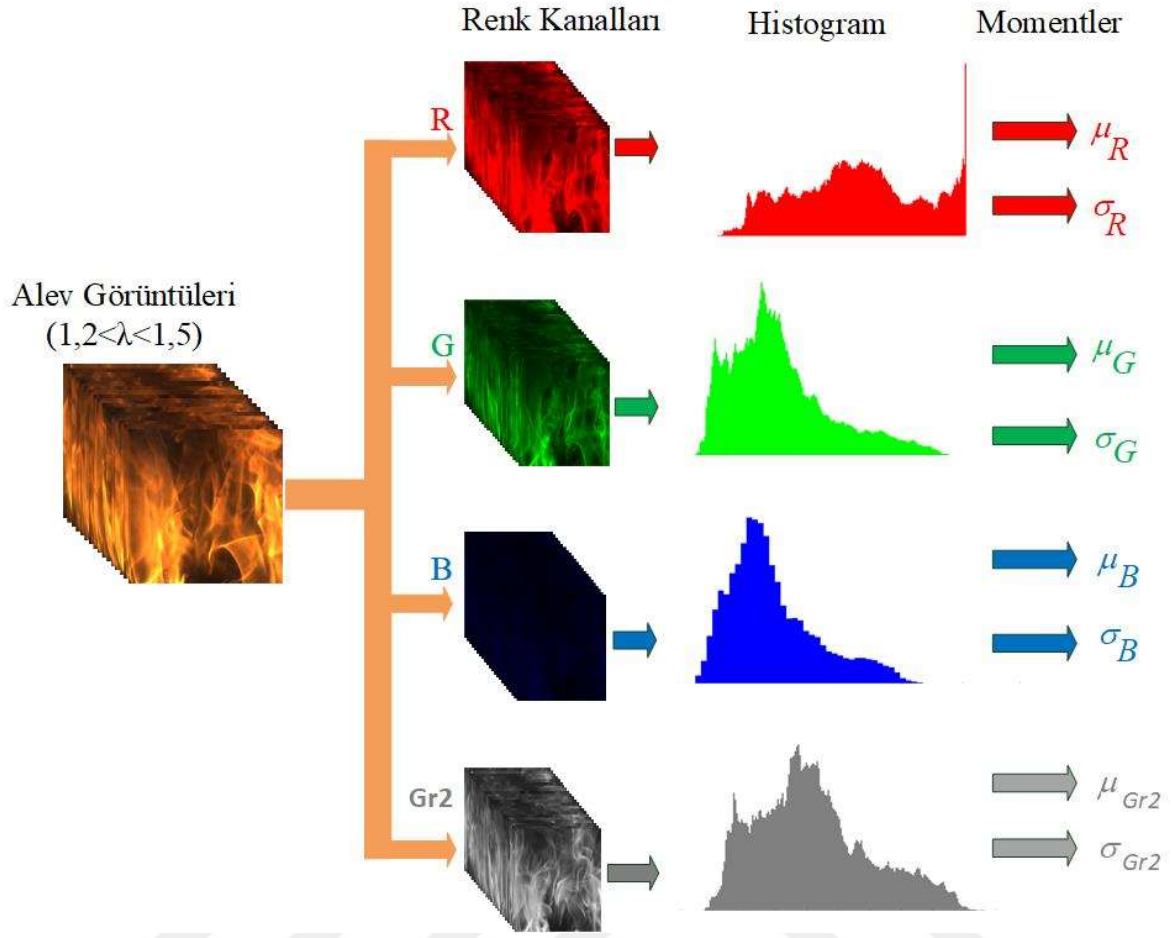
Tekil görüntüyle ideal yanmanın modellenmesi yaklaşımı başlangıç seviyesindeki bir çalışma olup asıl çalışmaya ön ayak olmuştur. Bu çalışmadan elde edilen tecrübeyle ideal yanmanın çok görüntü ile modellenmesi çalışması şekillenmiştir.

### 4.3 Çok Görüntüyle Ideal Yanmanın Modellenmesi

RGB renk uzayında alev görüntüsü, renk kanallarının yoğunluk değeri ile temsil edilmektedir. Bu yaklaşımda temel olarak piksel yoğunluk değeri yerine pikselin ideal yanmaya olan benzerlik olasılığı ile temsil edilmesi hedeflenmiştir. Bu işlem için Gauss (normal veya Laplace-Gauss) Dağılımı (GD) yaklaşımıyla 4 farklı teknikte ideal yanma modellenmiştir. Tek görüntü ile ideal yanmanın temsil edilmesi yaklaşımında görüntü bölgesinin modellenmesi hedeflenmişken bu yaklaşımda piksel bazında modelleme benimsenmiştir.

Olasılık teorisinde GD, çok yaygın olan bir sürekli olasılık dağılımıdır. Normal dağılım istatistikte önemlidir ve genellikle doğal ve sosyal bilimlerde dağılımları bilinmeyen gerçek değerli rastgele değişkenleri temsil etmek için kullanılır [84]. GD'nin ilgili parametreleri doğru bir şekilde belirlenmesi doğadaki birçok olay veya süreç için GD ile modellemeye imkân vermektedir.


Modelleme yaklaşımında kullanılacak GD dağılımı parametrelerini belirlemek için ideal yanma sürecinde alınmış alev görüntüleri kullanılmıştır. Alev rengini daha hassas modelleyebilmek için 22 adet ideal alev görüntüsü kullanılmıştır. Her bir görüntü R, G, B ve Gr2 renk kanallarına ayrıştırılmış ve her bir renk kanalının yoğunluk dağılımları (histogram) elde edilmiştir. Yoğunluk dağılımından ortalama ( $\mu$ ) ve standart sapma ( $\sigma$ ) parametreleri hesaplanmıştır (Şekil 4.8). Böylece her bir renk kanalının parlaklık dağılımı  $\sigma_k \in \{\sigma_R, \sigma_B, \sigma_G, \sigma_{Gr2}\}$  ve  $\mu_k \in \{\mu_R, \mu_B, \mu_G, \mu_{Gr2}\}$  parametreleriyle temsil edilmektedir. Şekil 4.9'da her bir renk kanalından hesaplanan parametreler kullanılarak modellenmesi gösterilmektedir.



**Şekil 4.8 :** Birden fazla görüntüyle ideal yanmanın modellenmesi

İdeal yanmanın modellenmesinden elde edilen 4 adet gauss modeli; tek değişkenli GD ile ayırık benzerlik olasılıklarından öznelik elde edilmesi, tekil kanalların tek değişkenli GD ile bağımsız olasılıklarının çarpılmasıyla öznelik elde edilmesi (Naive Bayes benzerlik metodu), ikili ve üçlü kanalların Çok Değişkenli Gauss Dağılımı (ÇDGD) ile öznelik elde edilmesi (ÇDGD benzerlik metodu) ve Gauss Karışım Modeli (GKM) [85] ile benzerlik olasılıklarıyla öznelik elde edilmesinde kullanılmıştır. Bu 4 adet birbirinden bağımsız öznelik çıkarma metodu ilgili her bir model için diğerlerinden bağımsız olarak tasarlanmıştır.

Görüntünün  $k$  kanalındaki  $(i, j)$  pikselin ideal yanmaya benzerliğini hesaplamak için Denklem (4.11) kullanılmaktadır. ÇDGD ile öznelik elde edilmesi için ideal modelde kullanılan RGB görüntülerinden hem ilgili ikili kanalların (R-G, R-B, G-B) hem de 3 birlikte (R-G-B) öznelik elde edilmesi için kovaryans matrisleri hesaplanmıştır. Burada gri seviye görüntüsü (Gr2) diğer kanallara bağımlı olduğu için dikkate alınmamıştır.



**Şekil 4.9 :** İdeal yanma görüntü kanallarının gauss fonksiyonuyla modellenmesi

Kovaryans hesaplamasında çok boyutlu olan ilgili görüntüler tek boyuta indirgenerek hesaplama yapılmıştır. Kovaryans değeri R ve G renk kanalları için Denklem (4.13)'deki gibi hesaplanmıştır.

$$\Sigma_{RG} = Cov(R, G) = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n (R_{i,j} - \mu_r)(G_{i,j} - \mu_g)^T \quad (4.13)$$

Burada  $\Sigma_{RG}$  R ve G görüntüleri için kovaryansı,  $R_{i,j}$  ve  $G_{i,j}$  piksel yoğunluklarını,  $m, n$  satır ve sütun sayısını,  $\mu_r$  ve  $\mu_g$  ise ilgili görüntüler için ortalamayı ifade etmektedir.


#### 4.3.1 Ayrık benzerlik toplamı

Alev görüntüsünün renk kanallarından öznelik elde edilirken her bir görüntü kanalı diğerinden ayrık olarak ele alındığı yöntemdir. İlgili kanaldan elde edilen ideal yanma modeli parametreleri ve tek değişkenli Olasılık Yoğunluk Fonksiyonu (OYF) yardımı ile pencerelerdeki piksel benzerlik olasılıkları toplamı Denklem (4.14)'deki gibi hesaplanmıştır.

Ayrık benzerlik olasılıklarından öznitelik elde edilmesi yaklaşımının G bileşenine uygulanışının şematik gösterimi Şekil 4.10'da verilmiştir. Bu piksel olasılığı toplamı o pencere için tekil öznitelik olarak alınmıştır. Bu işlem benzer olarak diğer görüntü kanalları için tekrarlanmıştır. Bu şekilde elde edilen tekil öznitelikler ilgili görüntüler için birleştirilerek (sağdan-sola, yukarıdan-aşağıya) ÖV elde edilmiştir. Ayrıca tekil bileşenlere ek olarak renk kanallarının ÖV'lerinin birleşim kombinasyonlarından farklı ÖV'ler elde edilmiştir.

$$\text{ÖV}_t = \sum_{i=1}^m \sum_{j=1}^n P(k_{i,j} | \mu_k, \sigma_k) \quad (4.14)$$

Burada  $t$  lokal pencere sayısını,  $m$  ve  $n$  lokal pencerenin satır ve sütun sayısını,  $k_{i,j} \in \{R, G, B, Gr2\}$ ,  $\sigma_k \in \{\sigma_R, \sigma_B, \sigma_G, \sigma_{Gr2}\}$  ve  $\mu_k \in \{\mu_R, \mu_B, \mu_G, \mu_{Gr2}\}$  ifade etmektedir.



Şekil 4.10 : Ayrık benzerlik olasılıkları yönteminin G kanalı için şematik gösterimi

### 4.3.2 Bağımsız olasılık çarpımı-naive bayes metodu

Birden fazla renk kanalı birlikte değerlendirilerek özniteliklerin hesaplandığı yöntemdir. İlgili bir piksel için bağımsız hesaplanan kanal olasılıkları çarpılarak o piksel için benzerlik hesaplanır. İlgili grid için benzerlik toplamı öznitelik olarak alınmaktadır (Denklem (4.15)). Gri seviye görüntüsü diğer renk bileşenlerinden elde edildiği için burada kullanılmamıştır. ÖV boyutu yerel pencere sayısı kadardır.

$$\ddot{O}V_t = \sum_{i=1}^m \sum_{j=1}^n \prod_{k \in \{RG, RB, GB, RGB\}} P(k_{i,j} | \mu_k, \sigma_k) \quad (4.15)$$

Burada  $t$  ızgara indisini,  $m$  ve  $n$  lokal pencerenin satır ve sütun sayısını,  $\sigma_k \in \{\sigma_R, \sigma_B, \sigma_G\}$  ve  $\mu_k \in \{\mu_R, \mu_B, \mu_G\}$  ise ideal gauss modellerinden gelen değerleri ifade etmektedir.

#### 4.3.3 Çok değişkenli dağılım

Renk kanallarının bağımsız olarak değil, birlikte değerlendirildiği yaklaşımdır. Bu yöntemde ÇDGD (Çok Değişkenli Gauss Dağılımı) modeli kullanılmıştır. Boyutu  $d$  olan ÇDGD için OYF Denklem (4.16)'daki gibi ifade edilebilir. ÖV Denklem (4.17)'deki gibi elde edilmektedir.

$$P(k_{i,j} | \mu_k, \Sigma_k) = \frac{1}{\sqrt{|\Sigma_k|} (2\pi)^d} \exp\left(-\frac{1}{2} (k_{i,j} - \mu_k) \Sigma_k^{-1} (k_{i,j} - \mu_k)^T\right) \quad (4.16)$$

Burada;  $d \in \{2,3\}$ ,  $\mu_k \in \{[\mu_R \ \mu_G \ \mu_B], [\mu_R \ \mu_G], [\mu_R \ \mu_B], [\mu_G \ \mu_B]\}$ ,  $\Sigma_k \in \{\Sigma_{RGB}, \Sigma_{RG}, \Sigma_{RB}, \Sigma_{GB}\}$  ve  $k \in \{RGB, RG, RB, GB\}$  olmaktadır.

$$\ddot{O}V_t = \sum_{i=1}^m \sum_{j=1}^n P(k_{i,j} | \mu_k, \Sigma_k) \quad (4.17)$$

#### 4.3.4 Karışım modeli

Birden fazla kanalın birbrinden bağımsız olarak benzerliklerinin hesaplanıp, farklı ağırlıklar verilerek incelendiği yaklaşımdır. Bu şekilde her bir renk kanalının ne kadar bilgi içerdiği ve renk kanallarının çoklu kullanımında hangi ağırlıklarla kullanılması gerektiğinin ortaya çıkarılması hedeflenmiştir. İdeal yanmaya benzerlik yaklaşımı için GKM yaklaşımı kullanılmıştır. Öznitelik elde edilirken Denklem (4.18)'de verilen GKM yaklaşımı ile hesaplanmıştır.

$$\ddot{O}V_t = \sum_{i=1}^m \sum_{j=1}^n w_k P(k_{i,j} | \mu_k, \sigma_k) \quad (4.18)$$

Burada;  $k \in \{RGB, RG, RB, GB\}$ ,  $w_k$  renk kanalının ağırlık katsayısıdır.  $w_k$  değerleri 3 renk kanalı için Denklem (4.19)'da ve 2 renk kanalı için Denklem (4.20)'deki gibi alınmıştır.

$$w_1 = 0.05 + 0.1 * b, w_2 = w_3 = (1 - w_1)/2, 0 \leq b \leq 9 \quad (4.19)$$

$$w_1 = 0.05 + 0.1 * b, w_2 = (1 - w_1) \quad 0 \leq b \leq 9 \quad (4.20)$$

Denklem (4.19)'da görüldüğü gibi ilgili bir görüntünün ağırlığı tekrarlı olarak arttırılmış diğer ikisi eşit alınmıştır. Bu işlem yani bir modelin ağırlığının arttırılarak diğer doğruluğun araştırılması işlemi R, G ve B görüntüleri için birbirinden bağımsız 3 adet GKM ile incelenmiştir. İki renk kanalındaki modeller, üç kanalın 2'li kombinasyonları için incelenmiştir.

#### 4.4 İstatistiksel Momentler

İstatistiksel momentler, bir veri dağılımı hakkında en öz bilgileri ihtiva etmektedirler. Bu yaklaşımda, her bir grid içerisindeki renk değerleri ilk dört moment kullanılarak özniteliklere dönüştürülmektedir. Birinci ve ikinci momentler (ortalama ve standart sapma) Denklem (4.21) ve Denklem (4.22)'de ifade edilmiştir. Üçüncü ve dördüncü momentler (basıklık ve çarpıklık) aşağıda gösterildiği gibi hesaplanır. Bir dağılımın yoğun kuyrukları varsa, basıklık değeri yüksek olmaktadır. Çarpıklık ise veri dağılımının ortalamaya göre simetrik olmama derecesini ifade etmektedir.

$$\text{ÖV}_t = \gamma S_k = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \left( \frac{k_{i,j} - \mu_k}{\sigma_k} \right)^3 \quad (4.21)$$

$$\text{ÖV}_t = \gamma k_k = \frac{1}{m \times n} \sum_{i=1}^m \sum_{j=1}^n \left( \frac{k_{i,j} - \mu_k}{\sigma_k} \right)^4 - 3 \quad (4.22)$$

#### 4.5 Normlar

Alev görüntüsünden öznitelik elde etmek için görüntü normları kullanılmıştır. Çizelge 4.2'de ifade edilen farklı norm tekniklerinin (Denklem 4.23-26) etkisi incelenmektedir. Spektral norm kullanılarak alev görüntüsünden (R ve G bileşenlerinden) öznitelik elde edildiği modelin şeması Şekil 4.11'de verilmiştir.

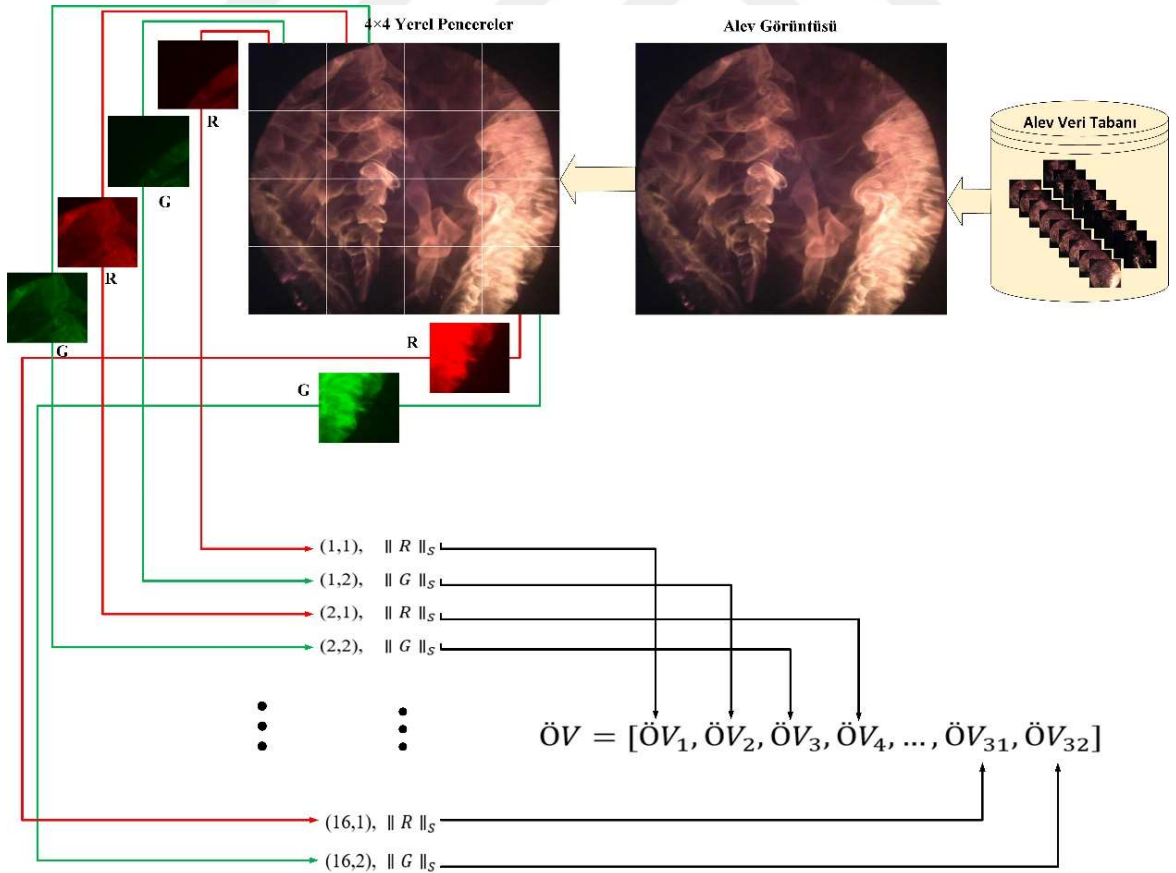
**Çizelge 4.2 : Norm formülleri**

| Norm Adı  | Norm Formülü   |        |
|-----------|--|--------|
| Frobenius | $\ k\ _F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n  k_{i,j} ^2}$   | (4.23) |
| Norm-1    | $\ k\ _1 = \max_{1 \leq j \leq n} \sum_{i=1}^m  k_{i,j} $  | (4.24) |
| Sonsuzluk | $\ k\ _\infty = \max \left( \sum_{j=1}^n  k_{1,j} , \sum_{j=1}^n  k_{2,j} , \dots, \sum_{j=1}^n  k_{m,j}  \right)$ | (4.25) |
| Spektral  | $\ k\ _S = \max_{x \neq 0} \frac{\ k x\ _S}{\ x\ _S}$  | (4.26) |

Buna göre  $t$ . grid'in öznitelikleri Denklem (4.27)'deki gibi ifade edilebilir.

$$\text{ÖV}_t = \{\|k_t\|_i\}, \quad i \in \{F, 1, \infty, S\} \quad (4.27)$$

Burada  $\{F, 1, \infty, S\}$  değişkenleri sırasıyla frobenius, norm-1, sonsuzluk ve spektral normları ifade etmektedir.



**Şekil 4.11 : Spektral norm ile ÖV elde edilmesi**

#### 4.6 Uzamsal Yoğunluk Dağılımı

Bu teknik ile öznitelikler elde edilirken gri alev görüntüsünün iki farklı şekilde elde edilmiş yoğunluk dağılımı kullanılmıştır. Birincisi 8 bit derinliğindeki gri görüntüsünden 256 çubukluk histogramı ile konumdan bağımsız yoğunluk dağılımı elde edilmesidir. İkincisi ise görüntünün her bir satır ve sütununun toplamını kullanarak uzamsal (konuma bağlı) yoğunluk dağılımının elde edilmesi yöntemiyle öznitelik elde edilmesidir. Renkli alev görüntüsü Gr2'ye dönüştürüldükten sonra görüntünün histogramı (Denklem (4.28)), satır toplamı (Denklem (4.29)) ve sütun toplamı (Denklem (4.30)) hesaplanmaktadır. Hesaplanan bu değerler görüntünün özniteliklerini (Denklem (4.31)) oluşturur.

$$Hist_t = Histogram(Gr2) \quad (4.28)$$

$$Xtop_t = sum(Gr2,1) \quad (4.29)$$

$$Ytop_t = sum(Gr2,2) \quad (4.30)$$

$$ÖV_t = \{Hist_t, Xtop_t, Ytop_t\} \quad (4.31)$$

#### 4.7 Kümülatif Uzamsal Yoğunluk Dağılımı

Uzamsal yoğunluk dağılımı yöntemine benzer olarak alevin gri seviye görüntüsünün kümülatif yatay ve kümülatif düşey iz düşüm vektörleri sırasıyla Denklem (4.32) ve Denklem (4.33) hesaplanabilir. Bu vektörler öznitelik olarak alınmıştır (Denklem (4.34)). Bu yöntemle elde edilen öznitelikler  $NO_x$  emisyonunun tahmin edilmesi çalışmasında kullanılmıştır.

$$XKtop_t = cumsum(sum(Gr2,1)) \quad (4.32)$$

$$YKtop_t = cumsum(sum(Gr2,2)) \quad (4.33)$$


$$ÖV_t = \{XKtop_t, YKtop_t\} \quad (4.34)$$

#### 4.8 Diğer Yöntemler

Denysel çalışmalar bölümünde önerilen öznitelik elde etme yaklaşımları literatürde sunulmuş öznitelik elde etme yaklaşımları ile kıyaslanması yapılmıştır. Bu başlıkta literatürde alev görüntüsünden öznitelik çıkarımı için sıklıkla kullanılan yaklaşımlar ele alınacaktır.

#### 4.8.1 HSI renk uzayında öznitelik elde etme

Literatürde yaygın olarak RGB renk uzayında çalışıldığı gibi HSI renk uzayı da yapılan çalışmalara mevcuttur [13]. HSI uzayında görüntü parlaklık (I), renk tonu (H) ve doygunluk (S) bileşenlerinden oluşur. Örnek bir alev görüntüsünün HSI bileşenleri Şekil 4.12’de gösterilmektedir.



Şekil 4.12 : RGB→HSI dönüşümü. Kanallar: (a) RGB, (b) HSI, (c) I, (d) S ve (e) H

Alev’in H seviyesinin ışık alanının baskın dalga boyunu temsil edebileceği bildirilmiştir [13]. Işıkla aydınlatılmış bir madde ile ilgili olarak, dalga boyu ve H seviyesi arasında bir ilişki olduğu bildirilmiştir [71]. Bu ilişki Denklem (4.33)’deki gibi ifade edilebilir. Işık  $OH$ ,  $CH$ ,  $C_2$ ,  $NO_2$ ,  $CO$  ve  $H_2O$  gibi maddeler ile radikal ışıdamaya sahiptir.

$$W = \frac{W_{max} - W_{min}}{2^d} Hue + W_{min} \quad (4.33)$$

Burada  $W$  dalga boyunu,  $W_{max} = 700nm$ ,  $W_{min} = 400nm$  ve  $d$  değeri ise ilgili görüntü için bit derinliğini ifade belirtmektedir.

Yanma sürecinin anlaşılmasında  $NO_2$  ve  $CO$  gibi maddelerin baca gazındaki oranı önemli olmaktadır. Dolayısıyla H seviyesinin ilgili aralıkları incelenerek yanma işlemi

hakkında fikir sahibi olunabilir. Dolayısıyla ilgili H seviyesi Denklem (4.34)'deki gibi öznitelik olarak alınmaktadır.

$$\ddot{O}V_i = \{H_k - H_l\} \quad (4.34)$$

#### 4.8.2 Gri eş oluşum matrisi yöntemi

GLCM hesaplanırken farklı iki konumdaki pikseller arasındaki gri seviye farklılıkları karşılaştırılarak doku bilgisi elde edilmeye çalışılır. Genellikle 8 bit derinlikteki gri seviyede çalışmak yerine bit derinliği 2 veya 3 olacak şekilde görüntüdeki pikseller indirgenerek işlem yapılır. Be şekilde hesaplama karmaşıklığı azaltılmaya çalışılır. Alevin farklı doku özniteliklerini ortaya çıkarmak için GLCM kullanılabilir [9]. GLCM, birinci dereceden gradyan dağılımları, kenar eş oluşum matrisleri gibi değişik yöntemlerle hesaplanabilir. Yaygın olarak Haralick [86] tarafından tanımlanan GLCM tercih edilmektedir. GLCM ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonunun,  $P(i, j|d, \theta)$  olabilirliğine dayanır. Bu matris görüntü pikselleri arasındaki uzaklık  $d$  ve açı  $\theta$  iken  $i$ . konumdaki gri seviyesinin,  $j$  konumundaki gri seviyeye geçme olasılığını göstermektedir. GLCM hesaplanırken arama penceresi olarak kare matris kullanılır. Dönmeye karşı değişmeyen doku özniteliklerinin elde edilmesi için genellikle  $\theta = 0^\circ, 45^\circ, 90^\circ$  ve  $135^\circ$  olacak şekilde dört yönde inceleme yapılır. Literatürde bu dört yön için bulunan GLCM'nin histogramı alınarak öznitelik çıkarıldığı gibi enerji, karşıtlık, korelasyon, homojenlik ve entropi gibi değişik yöntemlerle de GLCM'den öznitelikler çıkarılmıştır (Denklem 4.35).

$$\ddot{O}V_t = CoOccurence(k_t) \quad (4.35)$$

#### 4.8.3 Radyan enerji sinyali

Isı, Radyan Enerji Sinyali (RES)'ne bir örnek olup [87], hava/kömür optimizasyonu için önerilen bir çalışmalarda [45, 58] öznitelik olarak kullanılmıştır. İlgili çalışmada 12 farklı yere CCD kamera yerleştirilerek alev görüntüleri elde edilmiştir. Görüntü merkezlerinden alınan  $10 \times 10$  boyutlu bölgedeki renk yoğunlukların ağırlıklı ortalaması elde edilmektedir. Hesaplanan RES sinyali Denklem (4.36) verildiği gibi öznitelik olarak alınmaktadır.

$$\ddot{O}V_i = RES = \sum_{k=1}^K c_k \left( \sum_{a=1}^{10} \sum_{b=1}^{10} Alev(a, b) \right) \quad (4.36)$$

Burada;  $c_k$ ,  $k$ . kamera için bir düzeltme katsayısıdır.

#### 4.8.4 Özdeğerler

TBA yöntemi kullanılarak görüntünün özdeğerleri elde edilmektedir. İlk iki özdeğer ve özvektör kullanılarak görüntünün varyansın %98.8'inin ifade edebileceği gösterilmiştir [74]. Buna göre ilgili alev görüntüsü aşağıda gösterildiği gibi bileşen toplamı şeklinde yazılabilir (Denklem (4.37)) ve ilk iki bileşenin öz değeri öznitelik olarak kullanılır (Denklem (4.38)).

$$k_i = u_1 P_1^T + u_2 P_2^T + \dots + u_R P_R^T \quad (4.37)$$

$$\text{ÖV}_i = \{u_1, u_2\} \quad (4.38)$$

Burada;  $u_1$  ve  $u_2$  birinci ve ikinci özdeğerlerdir.

#### 4.8.5 FFT ve spektral analiz

Uzamsal alandaki renkli alev görüntünün herhangi bir kanalı frekans alanı taşınmaktadır. Frekans alanındaki her bileşenin gerçek (reel) ve sanal (imagine) katsayıları kullanılarak Güç Spektrum Yoğunluk (GSY) matrisi hesaplanmaktadır (Denklem (4.39)). Bu matrisin değerleri toplamı öznitelik değerini verir (Denklem (4.40)).

$$ps = abs(fft2(k)) \quad (4.39)$$

$$\text{ÖV} = \frac{\sum_{i=1}^N w_i * ps_i}{\sum_{i=1}^N w_i} \quad (4.40)$$

Burada;  $w_i$  ağırlık katsayısını gösterir ve güç spektrumundaki her bir frekans bileşeninin ağırlığını içerir. Güç spektrum matrisinden hesaplanan bu ağırlıklı toplam değeri, literatürde titreşim değeri (Flicker-F) olarak adlandırılmaktadır [43].

## 5. DOĞRUSAL OLMAYAN REGRESYON METODLARI

Bu tez çalışması kapsamında  $\lambda$ , Baca Gazı Emisyonu (BGE) ve BGS'nin tahmin edilmesi için farklı deneysel çalışmalar yapılmıştır. YSA, zaman serisi YSA (DGÇ), DVR ve derin öğrenme-Evrişimsel Sinir Ağı (ESA) modelleri ile doğrusal olmayan regresyon modelleri sunulmuştur. Yürütülen çalışmalarda regresyon modellerinin performanslarını kıyaslamak yerine problem bazında öznel yöntemleri için aynı regresyon modeli ile eğitilip öznel yöntemlerinin sonuçlarının kıyaslanması yaklaşımı benimsenmiştir. Regresyon modelleri içinde en iyi model ve parametre araştırması yapılmıştır.

### 5.1 YSA Regresyon Modeli

Bu tez çalışmasında önerilen YSA modellerinde giriş, gizli ve çıktı katmanı olarak adlandırılan en az üç katmandan oluşan çok katmanlı perceptron (MLP) yaklaşımı kullanılmıştır. Giriş katmanındaki nöronlar giriş değerlerini içermektedir. Gizli katmanda bulunan nöronlar girişleri YSA'nın çıkışına işler. Çıkış katmanındaki nöronlar çıkış değerlerini içerirler. Eğitim aşamasında, eğitim veri setindeki giriş ve istenen çıkış ile YSA beslenir. Bir sonraki adımda, giriş ve çıkış arasında bir ilişki ortaya koyan bir eğitim algoritması ihtiyaç vardır. En son aşamada, veri kümesinin geri kalanı modelin performansını test etmek için kullanılır [88]. Genel olarak YSA'da başlangıç ağırlıkları kullanılarak Denklem (5.1)'deki gibi verilen maliyet fonksiyonunu en aza indiren ağırlıklar güncellenmeye çalışır. YSA için birçok eğitim algoritması vardır. Bu çalışmada, MLP'yi eğitmek için en iyi algoritma olarak kabul edilen hata geri yayılım algoritmaları kullanılmıştır.

$$J(\theta) = \frac{1}{2M} \sum_{i=1}^M (h_{\theta}(x^{(i)}) - y^{(i)})^2 \quad (5.1)$$

Burada;  $M$  toplam alev görüntü sayısını,  $\theta$  YSA'nın ağırlıklarını,  $x^{(i)}$  öznel vektörünü,  $h_{\theta}(\cdot)$  hipotez fonksiyonunu,  $y^{(i)}$  beklenen çıkış değerini (gerçek verileri) ifade etmektedir.

YSA modellerinde ağırlık güncelleme yöntemi olarak temel olarak Levenberg-Marquardt (LM), OSS (One Step Secant) ve Scaled Conjugate Gradient (SCG) öğrenme yaklaşımlarının etkisi incelenmiştir. LM yöntemi eğitim aşamasındaki dezavantajına

rağmen aynı problem için daha düşük öznitelik boyutu için iyi sonuç vermektedir. SCG yöntemi eğitim aşamasında hızlı eğitilmektedir. Ayrıca Grafik İşleme Ünitesi-Graphics Processing Unit (GPU) gibi donanımlarda koşabilmektedir. Aynı problem için daha büyük veri boyutu için iyi performans vermektedir.

## 5.2 DVR Modeli

Destek Vektör Makinaları (DVM), bilgisayarlı görü alanında sınıflandırma problemlerinde başarılı bir şekilde kullanıldığı gibi regresyon problemlerinde de DVR kullanılmaktadır [89–91]. DVR, çekirdek fonksiyonlarını kullandığı için parametrik olmayan bir yöntemdir.

YSA ve DVR, en yaygın kullanılan doğrusal olmayan regresyon modelleridir. DVR modeli istatistik öğrenme teorisine dayanmakta ve hızlı öğrenme hızı, genelleme yeteneği ile gürültü toleransı özellikleriyle YSA daha avantajlı olduğu bildirilmiştir. DVR'nin YSA göre daha üstün olduğunu gösteren çalışmalar mevcuttur [92–94]. Bu tez çalışması kapsamında yürütülen bir çalışma kapsamında 6 adet DVR modeli için doğruluk kıyaslaması yapılarak nihai modele karar verilmiştir. İlgili deney çalışmasının sonuçları sonraki bölümlerde verilmektedir. İlgili çalışmada alev görüntülerinden elde edilen öznitelikler DVR yardımıyla BGS'ye eşlenmektedir.

### 5.2.1 Doğrusal DVR

Farz edelim ki  $x_n, y_n$  gözlemlenen yanıt değerlerine sahip çok değişkenli  $M$  adet gözlem verisinden oluşan bir veri setidir. Doğrusal fonksiyonu bulmak için Denklem (5.2)'deki denklem kullanılsın.

$$f(x) = x'\beta + b \quad (5.2)$$

Bu fonksiyonda  $f(x)$ 'i bulmak için minimum norm değeri ( $\|\beta\| = \beta'\beta$ ) bulunur. Bu fonksiyonu minimize etmek için dışbükey bir optimizasyon problemi olarak Denklem (5.3)'teki gibi ifade edilir.

$$J(\beta) = \frac{1}{2} \|\beta\|^2 \quad (5.3)$$

Denklem (5,6) verilen şartı yerine getirecek bir  $f(x)$  fonksiyonunun bulunmaması mümkündür. Bu durumda denklemi çözülebilir kılmak için, her nokta için  $\xi_n$  ve  $\xi_n^*$  gevşek değişkenleri kullanılır. Gevşek değişkenler regresyon hatalarının  $\xi_n$  ve  $\xi_n^*$  değerlerine kadar

var olmasına izin verir. Gevşek değişkenlerin dahil edilmesi, primal formül olarak da bilinen amaç fonksiyonuna dönüşümü sağlar [95]. Amaç fonksiyonu Denklem (5.4)'de verilmiştir.

$$J(\beta) = \frac{1}{2} \|\beta\|^2 + C \sum_{n=1}^N (\xi_n + \xi_n^*) \quad (5.4)$$

Burada  $C$  sabiti kutu kısıtıdır, epsilon marjının ( $\varepsilon$ ) dışında kalan gözlemlere uygulanan cezayı kontrol eden pozitif bir sayısal değerdir ve aşırı öğrenmenin önlenmesini sağlar.

### 5.2.2 Doğrusal olmayan DVR

Regresyon problemlerinin bazılarında doğrusal bir model kullanılarak yeterince tanımlanamaz. Bu durumda, Lagrange formülasyonu doğrusal olmayan fonksiyonları tanımlamak için kullanılabilir.  $x_1'x_2$  'nin iç çarpımı yerine doğrusal olmayan bir çekirdek fonksiyonu Denklem (5.5)'deki gibi yazılır.

$$G(x_1, x_2) = \langle \varphi(x_1), \varphi(x_2) \rangle \quad (5.5)$$

Bu şekilde  $x$ 'i yüksek boyutlu başka bir uzaya taşıyan bir dönüşüm kullanılmaktadır. Yani çekirdek fonksiyonlarıyla doğrusal ayrımı mümkün kılmak için verileri daha yüksek boyutlu bir uzaya dönüştürülmektedir. Bu tez çalışması kapsamında yapılan ilgili deneysel çalışma da doğrusal, kübik, ikinci dereceden, orta gauss, ince gauss ve kaba gauss modelleri kullanılmıştır. İlgili modeller için kıyaslamalı doğruluk analizi yapılarak kullanılacak modele karar verilmiştir. Bu modellerde doğrusal DVR'de doğrusal (iç çarpım) çekirdek fonksiyonu (Denklem (5.6)), kübik ve ikinci dereceden DVR modellerinde polinom çekirdek fonksiyonları (Denklem (5.7)) ve ince, orta ile kaba gauss DVR modellerindeyse gauss çekirdek fonksiyonu (Denklem (5.8)) kullanılmıştır.

$$G(x_j, x_k) = x_j'x_k \quad (5.6)$$

$$G(x_j, x_k) = (1 + x_jx_k)^q, \quad q \in \{2,3,\dots\} \quad (5.7)$$

$$G(x_j, x_k) = \exp(-\|x_j - x_k\|^2) \quad (5.8)$$

Bu durumda yeni değerleri tahmin etmek için kullanılan fonksiyon Denklem (5.9)'de verilmiştir.

$$f(x) = \sum_{n=1}^N (\alpha_n - \alpha_n^*) G(x_n, x) + b \quad (5.9)$$

Önerilen sistem eğitilirken de çapraz doğrulama yaklaşımı kullanılmıştır. Çapraz doğrulama işleminde tüm modeller için veri seti 5 parçaya bölünmüştür. Çekirdek fonksiyonlarının genişliği, giriş verisine göre hesaplanmıştır.

### 5.3 Zaman Serisi YSA Regresyon Modeli

Yanma işlemi belli bir süreçte olmakta ve bu süreçte ölçülen değerler ile gerçek ortam parametreleri farklı olabilmektedir. Örneğin ölçüm yapılan yer ve yanma sürecinin olduğu yer arasında bir uzaklık olmakta ve anlık kamera görüntüleri ile ölçülen verilerin ne derece örtüştüğü belirsiz olabilmektedir. Benzer olarak sistemdeki ani kararsız durumların ne derece sistem tarafından tolerans edilebildiği tartışma konusudur. Bu gibi durumlar göz önüne alınarak zaman serisi YSA ile sistem gerçekleştirilmiştir. Zaman serisi YSA’da temel olarak sistem çıkışı hesaplanırken sadece şuandaki giriş tek değil belli bir süre önceki geçmişteki girişler veya geçmişteki girişlerle beraber geçmişteki çıkışlar sistem girişine dahil edilir. Böylece daha iyi bir öğrenme modeli oluşabilmektedir. İki çeşidi incelenmiştir. Bunlara kısaca değinilecektir.

#### 5.3.1 Geribeslemeli


Birinci tür zaman serileri probleminde,  $y(t)$  (çıkış) zaman serisinin gelecekteki değerlerini o zaman serisinin geçmiş değerlerinden ve ikinci zaman serisinin geçmiş değerlerinden  $x(t)$  (giriş) tahmin etmek istenmektedir. Bu tahmin biçimine, dışsal (harici) giriş veya NARX ile doğrusal olmayan otoregressif olarak adlandırılmakta ve Denklem (5.10)’daki gibi yazılabilir [96]. Şekil 5.1’de NARX için örnek bir model diyagramı verilmiştir. Şekilde giriş sayısı 1536 ve geçmişe yönelik 5 adet veri kullanılmıştır.

$$y(t) = f(y(t-1), \dots, y(t-d), x(t-1), \dots, (t-d)) \quad (5.10)$$

Burada  $d$  kaç tane geçmiş değişkenin kullanılacağını belirtmektedir.

NARX modeli kâğıt üzerinde çok başarılı olsa da bu tez çalışması kapsamında yürütülen çalışmalar için uygun değildir. Bu model, işsizlik oranları gibi ekonomik değişkenlere dayanarak bir hisse senedinin veya tahvilin gelecekteki değerlerini tahmin etmek için kullanılabilir. Ayrıca kimyasallar gibi dinamik sistemleri temsil etmek için geliştirilen modellerin kullanıldığı sistem tanımlaması için de kullanılabilir. Deneysel sonuçlar bölümün de bahsedileceği gibi önceki çıkış değerinin kesin olarak doğru bilinmesine dayandığı için bu YSA tipi yanma sürecinin anlaşılması için pek uygun değildir.

İlk tahmin doğruluğu %99 olsa bile zamanla kümülatif hata sisteme bineceği için hata değeri %50'ye kadar bile çıkabilmektedir. Bu durum sonraki bölümde tartışılacaktır.



Şekil 5.1 : NARX YSA modeli için örnek bir modelin yapısı


### 5.3.2 Geribeslemesiz

İkinci zaman serisi YSA modeli birinci tipe benzemektedir. Çünkü iki serinin katılımıyla, bir giriş serisi  $x(t)$  ve bir çıkış / hedef serisi  $y(t)$  bulunmaktadır. Burada,  $y(t)$  değerlerini önceki  $x(t)$  değerlerinden tahmin etmek istiyoruz, ancak önceki  $y(t)$  değerlerini bilmeden bu işlem gerçekleştirilmektedir. Bu giriş/çıkış modeli Denklem (5.11)'deki gibi yazılabilir [96].

$$y(t) = f(x(t-1), \dots, x(t-d)) \quad (5.11)$$

Burada  $d$  kaç tane geçmiş değişkenin kullanılacağını belirtmektedir.

Önceki değerlerin kesin bilindiği problemlerde NARX modeli bu DGÇ modelinden daha iyi tahminler sağlayacaktır. Çünkü önceki  $y(t)$  değerlerinde bulunan ek bilgileri kullanır. Bununla birlikte, önceki  $y(t)$  değerlerinin mevcut olamayacağı bazı uygulamalar olabilir. NARX modeli yerine DGÇ modelini kullanmak isteyebileceğiniz bu durum bu tez çalışmasında yapılan çalışmalar için daha uygundur. Şekil 5.2'de 1536 adet girişli, giriş-çıkış YSA modeli için örnek bir modelin yapısı verilmiştir.



Şekil 5.2 : Doğrusal olmayan giriş-çıkış YSA modeli için örnek bir modelin yapısı

## 5.4 Evrişimsel Sinir Ağları

ESA, klasik öğrenme yaklaşımlarının zayıf yönleri değerlendirilerek oluşturulmuş gelişmiş YSA mimarisi olarak değerlendirilebilir. Geleneksel YSA'lar sadece 2 veya 3 katman içerirken derin ağlarda katman sayısı yüzlerce olabilmektedir. Klasik öğrenme yöntemlerindeki öznitelik çıkarma aşaması, derin öğrenme modellerinde modelin içine alınarak geliştirilmiştir. Derin öğrenme yaklaşımının model doğruluğu için üstün kabiliyetlerine rağmen bazı olumsuz yönleride bulunmaktadır. Herşeyden önce yüksek hesaplama maliyetinden dolayı üstün hesaplama yeteneğine sahip donanım gerektirmektedir. Eğitim aşamasında aşırı öğrenme olmaması için çok büyük veri boyutları ile icra edilmesi gerekmektedir. Çoğu zaman yüksek hesaplama maliyetinden dolayı özel GPU içeren donanımlar ile eğitilmektedir.

Derin öğrenmede eğitim verileri kullanılarak, nesnenin belirli özelliklerini ortaya çıkarılır ve bunları ilgili çıkışla ilişkilendirir. Ağdaki her katman bir önceki katmandan veri alır, dönüştürür ve aktarır. Ağ, katmandan katmana öğrendiklerinin karmaşıklığını ve detayını artırır. Ağ doğrudan verilerden öğrenmektedir. Hangi özelliklerin öğrenildiği üzerinde kullanıcının bir etkisi yoktur.

ESA, derin öğrenme için yaygın olarak kullanılan ağ mimarisi türüdür. Metin ve sürekli giriş verileri için de kullanılmasına rağmen, giriş olarak görüntüler için daha uygundur. Diğer sinir ağlarından bazı farkları bulunmaktadır. ESA'lar görsel bir korteksin biyolojik yapısından esinlenerek oluşturulmuştur [97]. Görsel bir korteksin hücrelerinin bir görme alanının alt bölgelerine dayanarak aktive oldukları bildirilmiştir. Bu çalışmanın bulgularından esinlenerek, ESA'lar, diğer sinir ağlarında olduğu gibi tamamen bağlı olmak yerine, bir tabakadan önceki tabakaların alt bölgelerine bağlanmaktadır. Nöronlar, görüntüdeki bu alt bölgelerinin dışındaki alanlara yanıt vermemektedir. Bu alt bölgeler üst üste gelebilmektedir. Bu nedenle ESA'lar mekansal olarak ilişkili sonuçlar üretirken, diğer sinir ağları türlerinde mekânsal bilgi üretilmemektedir. ESA mimarileri, maksimum havuzlama veya ortalama havuzlama katmanları ve tamamen bağlı katmanlar gibi birden çok katmandan oluşur. Bir ESA'nın her katmanındaki nöronlar, 3 boyutlu bir girişi 3 boyutlu bir çıktıya dönüştürecek şekilde düzenlenmiştir. Her bir katmandaki gizli birimler (nöronlar) orijinal girdilerin doğrusal olmayan kombinasyonlarını öğrenirler, buna özellik çıkarmada denir. Etkinleştirmeler olarak da bilinen bu öğrenilen özellikler, bir katmandan sonraki katman için girdi haline gelmektedir. Son olarak, öğrenilen özellikler ağın sonundaki

sınıflandırıcıya veya regresyon fonksiyonuna girdi olmaktadır [98]. Literatürde sık kullanılan ve transfer öğrenme yaklaşımıyla yeni problemlerin çözümüne uyarlanabilen ESA mimarileri Çizelge 5.1’de verilmektedir. [99].

**Çizelge 5.1 : Ön eğitilmiş bazı ağlar için teknik bilgiler**

| İsim                | Katman Sayısı | Eğitim Veri Seti        | Parametre (Milyon) | Giriş Görüntüsü Boyutu |
|---------------------|---------------|-------------------------|--------------------|------------------------|
| Googlenet [100]     | 22            | ImageNet veya Places365 | 7                  | 224x224                |
| Alexnet [101]       | 8             | ImageNet                | 61                 | 227x227                |
| Shufflenet [102]    | 50            | ImageNet                | 1.4                | 224x224                |
| Resnet18 [107, 108] | 18            | ImageNet                | 11.7               | 224x224                |
| Resnet50 [103]      | 50            | ImageNet                | 25.6               | 224x224                |
| Resnet101 [104]     | 101           | ImageNet                | 44.6               | 224x224                |

Googlenet ESA’sının ImageNet [105] ve Places365 [106, 107] veri setleri için önceden eğitilmiş iki versiyonu bulunmaktadır. ImageNet veri seti ile eğitilmiş ESA, giriş görüntülerini klavye, fare, kurşun kalem ve birçok hayvan gibi 1000 nesne kategorisinde sınıflandırır. Places365 veri seti ile eğitilmiş ESA, ImageNet ile eğitilmiş ağa benzer, ancak görüntüleri alan, park, pist ve lobi gibi 365 farklı yer kategorisine sınıflandırır.

## 5.5 Transfer Öğrenme

Transfer öğrenme, bir modelin öğrendiği bilgiyi farklı veya benzer problemin çözümünde kullanılması yaklaşımıdır. İnsanın öğrenme sürecinin temellinde, transfer öğrenme yaklaşımı bulunmaktadır [108]. Transfer öğrenme yaklaşımı YSA ağları arasında ayrılabilirliğe dayalı transfer algoritmasını geliştiren Lorien Pratt’in çalışmasıyla yaygın olarak kullanılmaya başlanmıştır [109]. Transfer öğrenme ile eğitim aşamasında zamandan tasarruf etmek ve daha iyi bir doğruluk elde etmek için kullanılmaktadır. Transfer öğrenme yaklaşımının öğrenmeyi geliştirdiği üç yaygın aşama vardır. Birincisi, hiç öğrenme olmayan bir modele göre modelin ilk performansının daha iyi bir noktada başlamasıdır. İkincisi, öğrenme süreci için geçen toplam süreyi kısaltmaktadır. Üçüncüsü, transfer öğrenmenin olmadığı modelin doğruluğuna kıyasla ulaşılabilen doğruluk seviyesinin daha iyi olmasıdır [110]. Derin öğrenme modellerinde eğitim kümesi büyük olup model mimarilerinin karmaşık yapısı olmaktadır. Dolayısıyla modelleri eğitmek hem işlem maliyetinden dolayı

pahalı donanım gerektirmektedir. Ayrıca eğitim süresinin uzunluğundan dolayı zaman açısından kısıtlamalar olabilmektedir. Bu dezavantajları üstesinden gelmek için transfer öğrenme, derin öğrenme problemlerinde yaygın olarak tercih edilmektedir.

Temelde iki tip transfer öğrenme yaklaşımı vardır. Bunlar; gelişmiş model metodu ve ön eğitilmiş model metodudur. Ön eğitilmiş model metodu derin öğrenme problemlerinde kullanılan metod olup eğitim süresinin kısaltılması ve hiç eğitilmemiş bir ağı göre performansın daha iyi olacağı varsayımlarından dolayı sıklıkla tercih edilmektedir. Transfer öğrenme bazı uygulamalarında ön eğitilmiş ağların belli katmanlarındaki ağırlıkların güncellenmesine müsaade edilmez. Be şekilde öznitelik çıkarılan katmanlar bozulmadan diğer katmanlardaki ağırlıklar güncellenerek öğrenmenin daha iyi olması beklenir. Şekil 5.3'te transfer öğrenme şematik olarak gösterilmektedir. Bu tez çalışması kapsamında  $\lambda$  ve BGS tahmini için transfer öğrenme yaklaşımıyla ön eğitilmiş ağlar kullanılarak tahmin modelleri oluşturulmuştur. Deneysel çalışmalar kısmında ilgili model sonuçları verilip yorumlanmıştır.



Şekil 5.3 : Transfer öğrenmenin şematik gösterimi

## 5.6 Deneysel Sonuçların Değerlendirilmesi

Önerilen yaklaşımları farklı öznitelik yaklaşımlarının birbiriyle ve literatürdeki benzer çalışmalarla kıyaslayabilmek için aynı veri kümesi üzerinde çalışan farklı deneysel çalışmalar yapılmıştır. Yaklaşımların regresyon doğruluklarının hesaplanmasında Ortalama Karesel Hata (MSE), Kök Ortalama Kare Hatası (RMSE) ve Korelasyon Katsayısı (R) metrikleri kullanılmıştır. MSE değerinin minimum olması arzu edilir. R değeri iki değişkenin ne derecede ilişkili olduğunu gösterir. R sıfıra yaklaştıkça değişkenler arasında herhangi bir ilişkinin olmadığı, bire yaklaşırsa iki değişkenin ilişkili olduğunu anlaşılmaktadır. MSE Denklem (5.12)'de ve RMSE Denklem (5.13)'te ve R Denklem (5.14)'deki gibi tanımlana bilir.

$$\text{MSE} = \frac{1}{M} \sum_{i=1}^M (D_i - D'_i)^2 \quad (5.12)$$

$$\text{RMSE} = \left[ \frac{1}{M} \sum_{i=1}^M (D_i - D'_i)^2 \right]^{1/2} \quad (5.13)$$

$$R = \frac{\sum_{i=1}^M (D_i - \bar{D})(D'_i - \bar{D}')}{\sqrt{\sum_{i=1}^M (D_i - \bar{D})^2 \sum_{i=1}^M (D'_i - \bar{D}')^2}} \quad (5.14)$$

Burada  $D_i$  ilgili görüntü için BGA verisi yani gözlenen değeri ifade etmektedir.  $\bar{D}$  ise tüm  $D_i$  verilerinin ortalamasını ifade etmektedir.  $D'_i$  ilgili görüntü için regresyon modelinin tahmin değerini yani gözlemlenen değeri ifade etmektedir.  $\bar{D}'$  ise tüm  $D'_i$  verilerinin ortalamasını ifade etmektedir.



## 6. ÖZİNİTELİKLERDEN $\lambda$ , BGS ve BGE TAHMİNİ

Bu bölümde alev görüntülerinden elde edilen öznelik vektörleri ile BGA'dan elde edilen  $\lambda$ , BGS ve BGE parametrelerinin eşleştirilmesi ile ilgili yapılan deneysel faaliyetler detaylı bir şekilde ifade edilmektedir. YSA regresyon modelleri için verilen sonuçlar, modellerin on kez koşturulup ortalamaları alınan sonuçlardır. Derin öğrenme modelleri için verilen sonuçlar, modellerin üç kez koşturulup ortalamaları alınan sonuçlardır.

### 6.1 Modellemeyle $\lambda$ Tahmini

Bu çalışmada RGB uzayında ideal yanma noktasına ([143, 66, 22]) projeksiyon (oran ve fark yaklaşımları) ve ideal yanma noktasına uzaklık (3B renk uzayında), ideal yanma bölgesi yaklaşımıyla bağımsız renk kanalı yaklaşımı (tek görüntü ile ideal yanma modellenmesi) ve birden çok görüntü ile ideal yanmanın modellenmesi yöntemlerinin  $\lambda$  tahmin doğrulukları incelenmiştir. Son yöntemde piksel yoğunlukları yerine ideal yanmaya olan piksel benzerlik olasılıkları 4 farklı teknikle (ayrık benzerlik toplamı, bağımsız olasılık çarpımı, çok değişkenli dağılım ve karışım modeli) ele alınmıştır. YSA mimarisi kurulurken tüm deneylerde gizli katman nöron sayısı 2-16 aralığındaki 8 adet çift sayı olarak alınmıştır. Yani tüm deneylerde 8 (gizli katman nöron sayısı) x YSA öğrenme modeli sayısı (2 veya 3) x öznelik yöntemi sayısı kadar model oluşturulmuştur.  $\lambda$  tahmini için verilen tüm modeller için deney 2 verilerinin hepsi kullanılmıştır. 1200x1200 olan görüntülerden 1160x1160 olacak şekilde ROI seçilmiştir.

#### 6.1.1 İdeal yanma rengine projeksiyon ve uzaklık

Bu deneysel çalışmada, renkli alev görüntüleri için RGB renk uzayında her bir ızgara için tek bir öznelik elde edilmiştir. Üç farklı eşikleme tekniği ile her bir ızgara (16x16) için öznelik değerleri (0-1/ikili görüntüsü) elde edilmiştir. Bunlar ideal yanma rengine projeksiyon oranı, ideal yanma rengine projeksiyon farkı ve ideal yanma noktasına uzaklık yaklaşımlarıdır. Eşik değerler için en iyi değer deneysel çalışma sonucu belirlenmiştir. Alt ve üst eşik sınırları arasında 10 adet eşik değeri için sonuçlar elde edilip en iyi eşik değeri belirlenmiştir. Izgaralar için öznelik değerleri (0-1/ikili görüntüsü) elde edildikten sonra öznelik vektörünün oluşturulması için ikili görüntü (0-1), biaslı görüntü (1-2), satır toplamı,

sütun toplamı, ikili satırın onluk karşılığı, ikili sütunun onluk karşılığı, satır-sütun toplamı ve ikili satır-sütun onluk karşılığı öznitelik vektörleri olarak alınmıştır. Projeksiyon oran yöntemi için eşik değer araştırması 1,004-1,04 aralığındaki değerler için yapılmıştır. Her üç eşik yöntemi ile 800 olmak üzere toplam 2400 adet model için sonuç elde edilmiştir. Çizelge 6.1’de projeksiyon oran eşikleme yöntemiyle elde edilen öznitelikler ile  $\lambda$  eşleştirmesi için LM, SCG ve OSS YSA öğrenme yöntemlerinin test sonuçları verilmiştir.

**Çizelge 6.1 : Projeksiyon-oran yöntemi için regresyon modelleri test sonuçları**

|                                 |     | YSA Öğrenme Yöntemi |        |                   |               |                   |        |
|---------------------------------|-----|---------------------|--------|-------------------|---------------|-------------------|--------|
|                                 |     | LM<br>Tüm Sistem    |        | SCG<br>Tüm Sistem |               | OSS<br>Tüm Sistem |        |
| Öznitelik Yöntemi               | ÖVS | MSE                 | R      | MSE               | R             | MSE               | R      |
| İkili Görüntü<br>(Tüm Görüntü)  | 256 | 0,5292              | 0,9180 | <b>0,4564</b>     | <b>0,9293</b> | 0,5567            | 0,9129 |
| İkili Görüntü<br>(Daire İçi)    | 193 | 0,5628              | 0,9133 | 0,4854            | 0,9245        | 0,5712            | 0,9107 |
| Biaslı Görüntü<br>(Tüm Görüntü) | 256 | 0,5566              | 0,9132 | 0,4836            | 0,9248        | 0,5704            | 0,9107 |
| Biaslı Görüntü<br>(Daire İçi)   | 193 | 0,5346              | 0,9175 | 0,4655            | 0,9278        | 0,5498            | 0,9140 |
| Satır Toplam                    | 16  | 1,0384              | 0,8302 | 1,3316            | 0,7751        | 1,4169            | 0,7587 |
| Satır Onluk                     | 16  | 0,8323              | 0,8665 | 1,1189            | 0,8154        | 1,2160            | 0,7974 |
| Sütun Toplam                    | 16  | 1,1891              | 0,8026 | 1,4604            | 0,7501        | 1,5052            | 0,7413 |
| Sütun Onluk                     | 16  | 1,0331              | 0,8312 | 1,2729            | 0,7868        | 1,3247            | 0,7770 |
| Satır-Sütun Toplam              | 32  | 0,5440              | 0,9150 | 0,7478            | 0,8808        | 0,8065            | 0,8709 |
| Satır-Sütun Onluk               | 32  | 0,5650              | 0,9116 | 0,7572            | 0,8794        | 0,8641            | 0,8608 |

Çizelge 6.1’de görüldüğü gibi en iyi sonuçlar SCG öğrenme yöntemi için ikili görüntünün olduğu gibi kullanıldığı öznitelik elde etme yöntemi  $R = 0,9293$  olarak elde edilmiştir. LM yöntemi için satır-sütun toplamı yönteminde öznitelik sayısı düşük olmasına rağmen  $R = 0,9150$  olarak elde edilmiştir. Çizelge 6.2’de Projeksiyon-fark eşikleme yöntemi için elde edilen öznitelikler ile  $\lambda$  eşleştirmesi için LM, SCG ve OSS YSA öğrenme yöntemlerinin test sonuçları verilmiştir. Projeksiyon oran yöntemi için eşik değer araştırması 0,5-5 aralığındaki değerler için yapılmıştır. Çizelge 6.2’de görüldüğü gibi en iyi sonuçlar SCG öğrenme yöntemi için ikili görüntünün olduğu gibi kullanıldığı öznitelik elde etme yöntemi  $R = 0,9249$  olarak elde edilmiştir. LM yöntemi için satır-sütun toplamı yönteminde öznitelik sayısı (32) düşük olmasına rağmen  $R = 0,9128$  olarak elde edilmiştir.

**Çizelge 6.2 :** Projeksiyon-fark yöntemi için regresyon modelleri test sonuçları

|                                 |     | YSA Öğrenme Yöntemi |        |                   |               |                   |        |
|---------------------------------|-----|---------------------|--------|-------------------|---------------|-------------------|--------|
|                                 |     | LM<br>Tüm Sistem    |        | SCG<br>Tüm Sistem |               | OSS<br>Tüm Sistem |        |
| Öznitelik Yöntemi               | ÖVS | MSE                 | R      | MSE               | R             | MSE               | R      |
| İkili Görüntü<br>(Tüm Görüntü)  | 256 | 0,5748              | 0,9106 | <b>0,4833</b>     | <b>0,9249</b> | 0,6109            | 0,9039 |
| İkili Görüntü<br>(Daire İçi)    | 193 | 0,5638              | 0,9124 | 0,4922            | 0,9235        | 0,6195            | 0,9023 |
| Biaslı Görüntü<br>(Tüm Görüntü) | 256 | 0,5858              | 0,9094 | 0,4901            | 0,9238        | 0,6557            | 0,8958 |
| Biaslı Görüntü<br>(Daire İçi)   | 193 | 0,5667              | 0,9125 | 0,4946            | 0,9231        | 0,5850            | 0,9081 |
| Satır Toplam                    | 16  | 1,0726              | 0,8240 | 1,4256            | 0,7558        | 1,5215            | 0,7375 |
| Satır Onluk                     | 16  | 0,8171              | 0,8692 | 1,1839            | 0,8032        | 1,3340            | 0,7745 |
| Sütun Toplam                    | 16  | 1,1913              | 0,8022 | 1,5002            | 0,7422        | 1,5493            | 0,7323 |
| Sütun Onluk                     | 16  | 1,0846              | 0,8218 | 1,2954            | 0,7826        | 1,3501            | 0,7719 |
| Satır-Sütun Toplam              | 32  | 0,5574              | 0,9128 | 0,7469            | 0,8811        | 0,8218            | 0,8683 |
| Satır-Sütun Onluk               | 32  | 0,5796              | 0,9092 | 0,7841            | 0,8744        | 0,8718            | 0,8596 |

Çizelge 6.3'te ideal yanma rengine uzaklık eşikleme yöntemi için elde edilen öznitelikler ile  $\lambda$  eşleştirmesi için LM, SCG ve OSS YSA öğrenme yöntemlerinin test sonuçları verilmiştir. İdeal yanma rengine uzaklık yöntemi için eşik değer araştırması 20-200 aralığında eşit uzaklıktaki 10 değer için yapılmıştır.

**Çizelge 6.3 :** Yanma noktasına uzaklık yöntemi için modellerin test sonuçları

|                                |     | YSA Öğrenme Yöntemi |        |                   |               |                   |        |
|--------------------------------|-----|---------------------|--------|-------------------|---------------|-------------------|--------|
|                                |     | LM<br>Tüm Sistem    |        | SCG<br>Tüm Sistem |               | OSS<br>Tüm Sistem |        |
| Öznitelik Yöntemi              | ÖVS | MSE                 | R      | MSE               | R             | MSE               | R      |
| İkili Görüntü<br>(Tüm Görüntü) | 256 | 0,4641              | 0,9288 | 0,4066            | 0,9373        | 0,4572            | 0,9291 |
| İkili Görüntü<br>(Daire İçi)   | 193 | 0,4730              | 0,9270 | 0,4320            | 0,9332        | 0,4979            | 0,9223 |
| Biaslı Görüntü (Tüm)           | 256 | 0,4664              | 0,9279 | <b>0,3946</b>     | <b>0,9391</b> | 0,5212            | 0,9180 |
| Biaslı Görüntü<br>(Daire İçi)  | 193 | 0,4868              | 0,9256 | 0,4050            | 0,9375        | 0,4194            | 0,9351 |
| Satır Toplam                   | 16  | 1,0522              | 0,8277 | 1,3309            | 0,7756        | 1,4449            | 0,7529 |
| Satır Onluk                    | 16  | 0,7540              | 0,8800 | 1,0117            | 0,8349        | 1,0977            | 0,8194 |
| Sütun Toplam                   | 16  | 0,9289              | 0,8497 | 1,2213            | 0,7963        | 1,2698            | 0,7872 |
| Sütun Onluk                    | 16  | 0,8200              | 0,8687 | 1,0776            | 0,8231        | 1,1348            | 0,8126 |
| Satır-Sütun Toplam             | 32  | 0,4610              | 0,9285 | 0,6525            | 0,8971        | 0,7388            | 0,8825 |
| Satır-Sütun Onluk              | 32  | 0,4451              | 0,9310 | 0,6313            | 0,9006        | 0,7221            | 0,8852 |

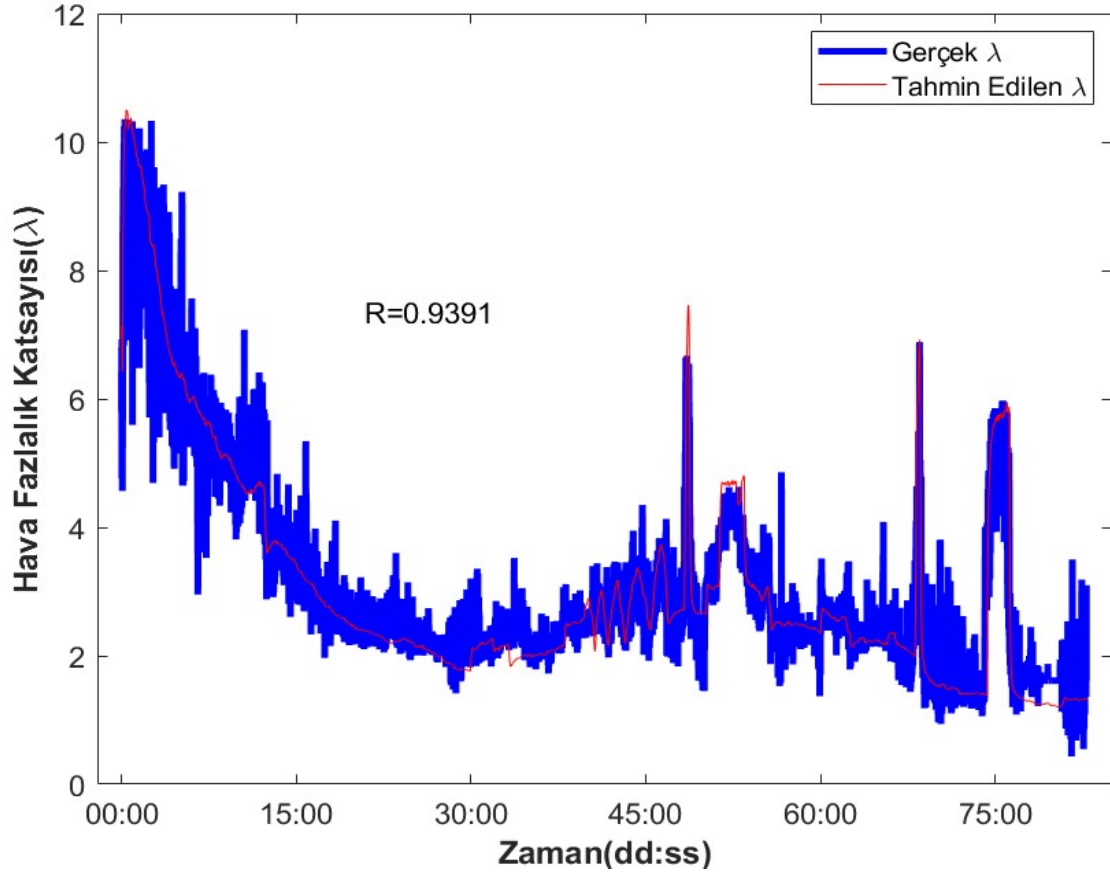
Çizelge 6.3'te görüldüğü gibi en iyi sonuçlar SCG öğrenme yöntemi için biaslı görüntünün kullanıldığı öznitelik elde etme yöntemi  $R = 0,9391$  olarak elde edilmiştir. LM yöntemi için satır-sütun onluk yönteminde öznitelik sayısı (32) düşük olmasına rağmen  $R = 0,9310$  olarak elde edilmiştir.

### 6.1.2 İdeal yanma rengi yaklaşımlarının birlikte değerlendirilmesi

RGB renk uzayında ideal yanma rengi (noktası) yaklaşımıyla oluşturulan 3 eşikleme yöntemi için elde edilen öznitelikler kısaca yorumlanacaktır. Sıfırın çarpmadaki yok etme etkisinden dolayı YSA girişine ikili görüntü yerine biaslı (1-2) görüntüsü verilir 0-1 ikili görüntüsünü ile kıyaslanmak istenmiştir. Sonuçta her ne kadar biaslı görüntü için ideal yanma noktasına uzaklık yaklaşımı için en iyi sonuç ( $R = 9391$ ) elde edilmiştir. Fakat ikili görüntü içinde çok benzer bir sonuç ( $R = 0,9373$ ) elde edilmiştir. Bunu destekleyen bir diğer sonuç birçok öznitelik çıkarma yöntemi için en iyi sonuç ikili görüntüde alınmasıdır. Dolayısıyla biaslı görüntüye gerek olmadığı söylenebilir. Yani sıfırın çarpmadaki yok etme etkisi YSA modeli tarafında tolare edilmiştir denilebilir. Alev görüntüsü olmayan bölgelerin elenmesi yaklaşımına dayanarak özniteliğin çıkarıldığı diare içindeki ızgaraların alınması yaklaşımı kısmen olsada doğruluğu azaltmıştır ( $R = 0,9351$ ). Satır ve sütun toplamı, öznitelik çıkarma yöntemlerinde öznitelik sayısı az olup (16) kısmi konum bilgisi korunmaktadır. Bu yaklaşımla öznitelik sayısı kısmi korunmasına rağmen başarımlar istenilen seviyede değildir. Satır ve sütun onluk öznitelik yaklaşımlarında konum bilgisi tamamen korunarak öznitelik sayısı düşürülmüştür. Fakat YSA'nın onluk değerlerden konum bilgisini çıkaramadığı söylenebilir. Çünkü elde edilen sonuçlar istenilen seviyede değildir. Satır ve sütun özniteliklerinin birlikte kullanıldığı satır-sütun toplam ve satır-sütun onluk öznitelik yöntemlerinde elde edilen başarımlar sırasıyla  $R = 0,9128$  ve  $R = 0,9310$  olarak bulunmuştur. Buradan öznitelik sayısı artınca (32) YSA'nın kısmi konum bilgisi (toplam öznitelik yöntemi) ve tam konum bilgisi (onluk öznitelik yöntemi) daha iyi öğrendiği söylenebilir. Sınırlı sistem kaynakları düşünüldüğünde ideal yanma noktasına uzaklık eşikleme yöntemi ve satır-sütun onluk öznitelik yönteminin az sayıdaki giriş sayısı (32) ve en yüksek başarıma yakın ( $R = 0,9310$ ) sonuç vermesinden dolayı seçilebilir. Her üç yöntem için 2400 YSA modelinden üç YSA öğrenme modeli için en iyi sonuçlar Çizelge 6.4'te verilmiştir. Modellerin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 1 nolu klasörün içerisinde yer almaktadır. En iyi sonuçların alındığı YSA öğrenme modeli için modelin tahmin ettiği ve BGA'dan ölçülen gerçek değerler Şekil 6.1'de verilmiştir. Burada modelin tahmin ettiği değerler 10 kez oluşturulup ortalaması alınan değerlerdir.

Çizelge 6.4 : Üç yöntem için kıyaslamalı sonuçlar

|                  |                              |                |            |            | Tüm Sistem    |               | Test          |               |
|------------------|------------------------------|----------------|------------|------------|---------------|---------------|---------------|---------------|
| Yöntem           |                              | Eşik Değeri    | ÖVS        | Öğr.       | MSE           | R             | MSE           | R             |
| Projeksiyon Oran | İkili Görüntü (Tüm Görüntü)  | 1,040          | 256        | LM         | 0,5292        | 0,9180        | 0,8620        | 0,8647        |
|                  | İkili Görüntü (Tüm Görüntü)  | 1,032          | 256        | SCG        | 0,4564        | 0,9293        | 0,6285        | 0,9041        |
|                  | Biaslı Görüntü (Daire İçi)   | 1,04           | 193        | OSS        | 0,5498        | 0,9140        | 0,6954        | 0,8942        |
| Projeksiyon Fark | Satır-Sütun Toplam           | 4,50           | 32         | LM         | 0,5574        | 0,9128        | 0,6762        | 0,8916        |
|                  | İkili Görüntü (Tüm Görüntü)  | 4,50           | 256        | SCG        | 0,4833        | 0,9249        | 0,6631        | 0,8948        |
|                  | Biaslı Görüntü (Daire İçi)   | 5,00           | 193        | OSS        | 0,5850        | 0,9081        | 0,7208        | 0,8888        |
| Uzaklık          | Satır-Sütun Onluk            | 140,00         | 32         | LM         | 0,4451        | 0,9310        | 0,5503        | 0,9137        |
|                  | Biaslı Görüntü (Tüm Görüntü) | <b>160,000</b> | <b>256</b> | <b>SCG</b> | <b>0,3946</b> | <b>0,9391</b> | <b>0,5454</b> | <b>0,9142</b> |
|                  | Biaslı Görüntü (Daire İçi)   | 140,00         | 193        | OSS        | 0,4194        | 0,9351        | 0,5574        | 0,9118        |



**Şekil 6.1** : İdeal yanma noktasına uzaklık yöntemi için gerçek ve tahmin edilen  $\lambda$

### 6.1.3 İdeal yanma bölgesi görüntüsüyle modelleme

Bu deneysel çalışmada alev görüntülerinin tekil kanalları (R, G, B, Gr1, Gr2, Gr3, Gr4 ve H), ikili kanalları (R-G, R-B ve G-B) ile R-G-B üçlü kanalı kullanılarak Bölüm 4'te 4.2 başlığında anlatılan teknikle çıkarılan öznitelikler ile  $\lambda$  eşleştirmesi sonuçları verilip değerlendirilecektir. Bu çalışma, bağımsız renk kanalı çalışması [20] optimize edilerek geliştirilen çalışmadır. Tüm kanallar için YSA'nın gizli katmanı için 2-16'ya kadar çift sayıda 8 adet gizli nöron ile gerçekleştirilmiştir. Öğrenme yöntemi olarak LM, SCG ve OSS öğrenme yöntemleri kullanılmıştır. Bir önceki başlıkta RGB renk uzayında yoğunluk değeri kullanılarak herbir ızgara için tekil öznitelik elde edilirken bu yöntemde her bir görüntü kanalı için diğerinden bağımsız ilgili renk kanalı için oluşturulan ideal yanma modeline benzerlik olasılığı kullanılmıştır. Bir önceki başlıkta yoğunluk ortalaması alınırken bu yöntemde hesaplama piksel bazında olup ideal yanmaya benzeyen piksel sayısının çokluğuna göre ızgaranın ideal yanma olup olmamasına karar verilir. Öznitelik elde edilirken bir önceki başlıktaki gibi ikili görüntü (0-1), biaslı görüntü (1-2), satır toplamı, sütun toplamı, ikili satırın onluk karşılığı, ikili sütunun onluk karşılığı, satır-sütun toplamı ve ikili satır-sütun onluk karşılığı öznitelik vektörleri olarak alınmıştır. Her renk kanal(lar)ı için bu öznitelikler hesaplanmıştır. Toplamda 768 adet YSA regresyon modeli için  $\lambda$ -öznitelik eşleştirmesi yapılmıştır. Modellerin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 2 nolu klasörün içerisinde yer almaktadır. Sonuçlar verilirken satır ve sütunun tekil kullanımı için model sonuçları verilmeyecektir. Çizelge 6.5'te ikili görüntü için üç farklı YSA öğrenme modeli ve ilgili kanallar için tüm sistem R ve MSE değerleri verilmiştir. Çizelge 6.5'te görüldüğü gibi en yüksek başarımlı SCG öğrenme yöntemi için Gr2 renk kanalı için kullanılarak bulunmuştur. İkili renk kanallarında en yüksek başarımlı R-B renk kanalları için bulunmuş olsada R-G ve G-B renk kanalları içinde her üç YSA öğrenme yöntemi için hemen hemen aynı sonucu vermiştir. Çizelge 6.6'da biaslı görüntü için  $\lambda$  tahmini sonuçları verilmiştir.

Çizelge 6.5 : İkili görüntü için  $\lambda$  tahmini

|             |     | YSA Öğrenme Yöntemi |          |                   |               |                   |          |
|-------------|-----|---------------------|----------|-------------------|---------------|-------------------|----------|
|             |     | LM<br>Tüm Sistem    |          | SCG<br>Tüm Sistem |               | OSS<br>Tüm Sistem |          |
| Renk Kanalı | ÖVS | MSE                 | <i>R</i> | MSE               | <i>R</i>      | MSE               | <i>R</i> |
| R           | 256 | 0,5194              | 0,9193   | 0,4973            | 0,9226        | 0,7367            | 0,8816   |
| G           | 256 | 0,5109              | 0,9211   | 0,5198            | 0,9190        | 0,7425            | 0,8811   |
| B           | 256 | 0,5187              | 0,9198   | 0,5335            | 0,9166        | 0,5677            | 0,9106   |
| Gr1         | 256 | 0,5288              | 0,9177   | 0,4893            | 0,9239        | 0,6250            | 0,9013   |
| Gr2         | 256 | 0,5660              | 0,9127   | <b>0,4445</b>     | <b>0,9311</b> | 0,6328            | 0,9003   |
| Gr3         | 256 | 0,5475              | 0,9148   | 0,4538            | 0,9297        | 0,6188            | 0,9025   |
| Gr4         | 256 | 0,5296              | 0,9183   | 0,4818            | 0,9251        | 0,6670            | 0,8945   |
| H           | 256 | 0,5040              | 0,9218   | 0,4533            | 0,9297        | 0,5761            | 0,9096   |
| G-B         | 512 | 0,5657              | 0,9118   | 0,4947            | 0,9231        | 0,6388            | 0,8991   |
| R-B         | 512 | 0,5482              | 0,9156   | 0,4877            | 0,9242        | 0,6489            | 0,8977   |
| R-G         | 512 | 0,5550              | 0,9135   | 0,4894            | 0,9240        | 0,6398            | 0,8990   |
| R-G-B       | 768 | 0,5626              | 0,9124   | 0,4682            | 0,9274        | 0,5532            | 0,9139   |

Çizelge 6.6 : Biaslı görüntü için  $\lambda$  tahmini

|             |     | YSA Öğrenme Yöntemi |          |                   |               |                   |          |
|-------------|-----|---------------------|----------|-------------------|---------------|-------------------|----------|
|             |     | LM<br>Tüm Sistem    |          | SCG<br>Tüm Sistem |               | OSS<br>Tüm Sistem |          |
| Renk Kanalı | ÖVS | MSE                 | <i>R</i> | MSE               | <i>R</i>      | MSE               | <i>R</i> |
| R           | 256 | 0,4941              | 0,9241   | 0,4729            | 0,9266        | 0,5379            | 0,9160   |
| G           | 256 | 0,5665              | 0,9122   | 0,4640            | 0,9280        | 0,6291            | 0,9004   |
| B           | 256 | 0,5074              | 0,9213   | 0,4847            | 0,9247        | 0,7651            | 0,8773   |
| Gr1         | 256 | 0,4939              | 0,9241   | 0,4743            | 0,9263        | 0,5674            | 0,9110   |
| Gr2         | 256 | 0,5284              | 0,9179   | 0,4726            | 0,9266        | 0,6217            | 0,9021   |
| Gr3         | 256 | 0,5274              | 0,9188   | 0,4908            | 0,9237        | 0,6146            | 0,9031   |
| Gr4         | 256 | 0,5172              | 0,9204   | 0,4646            | 0,9280        | 0,6153            | 0,9032   |
| H           | 256 | 0,5401              | 0,9157   | 0,4646            | 0,9279        | 0,6295            | 0,9006   |
| G-B         | 512 | 0,5204              | 0,9199   | 0,4575            | 0,9291        | 0,7506            | 0,8795   |
| R-B         | 512 | 0,4824              | 0,9255   | <b>0,4500</b>     | <b>0,9303</b> | 0,6537            | 0,8961   |
| R-G         | 512 | 0,5534              | 0,9141   | 0,4990            | 0,9224        | 0,7322            | 0,8825   |
| R-G-B       | 768 | 0,5251              | 0,9184   | 0,4724            | 0,9268        | 0,6726            | 0,8922   |

Çizelge 6.6'da görüldüğü gibi en yüksek başarımlar SCG öğrenme yöntemi için R-B renk kanalları için kullanılarak  $R = 0,9303$  olarak bulunmuştur. Tekil görüntü için Gr4 ve G renk kanalları için  $R = 0,9280$  olarak bulunmuştur. Çizelge 6.7'de satır-sütun toplamı öznelilik çıkarma yaklaşımı için  $\lambda$  tahmini sonuçları verilmiştir. Çizelge 6.7'de görüldüğü gibi en yüksek başarımlar LM öğrenme yöntemi için R-G-B renk kanalları için kullanılarak  $R =$

0,9286 olarak bulunmuştur. Tekil görüntü için G renk kanalı için  $R = 0,8997$  olarak bulunmuştur. İkili görüntü için R-G kanallarında  $R = 0,9280$  olarak bulunmuştur. Bu yöntemde her üç YSA öğrenme modeli için aynı renk kanallarında en yüksek başarıyı vermiştir. Çizelge 6.8’de 7’de satır-sütun onluk öznelilik çıkarma yaklaşımı için  $\lambda$  tahmini sonuçları verilmiştir.

**Çizelge 6.7 :** Satır-sütun toplamı metodu için  $\lambda$  tahmini

|             |     | YSA Öğrenme Yöntemi |               |                   |        |                   |        |
|-------------|-----|---------------------|---------------|-------------------|--------|-------------------|--------|
|             |     | LM<br>Tüm Sistem    |               | SCG<br>Tüm Sistem |        | OSS<br>Tüm Sistem |        |
| Renk Kanalı | ÖVS | MSE                 | R             | MSE               | R      | MSE               | R      |
| R           | 256 | 0,9359              | 0,8485        | 1,4135            | 0,7587 | 1,4864            | 0,7443 |
| G           | 256 | 0,6370              | 0,8997        | 0,8924            | 0,8560 | 0,9485            | 0,8461 |
| B           | 256 | 1,2030              | 0,8001        | 1,7285            | 0,6940 | 1,8135            | 0,6753 |
| Gr1         | 256 | 0,7379              | 0,8827        | 1,0160            | 0,8337 | 1,2202            | 0,7966 |
| Gr2         | 256 | 0,8260              | 0,8677        | 1,1540            | 0,8087 | 1,1639            | 0,8071 |
| Gr3         | 256 | 0,8256              | 0,8680        | 1,1557            | 0,8082 | 1,2986            | 0,7819 |
| Gr4         | 256 | 0,8659              | 0,8608        | 1,3519            | 0,7704 | 1,3429            | 0,7731 |
| H           | 256 | 0,9291              | 0,8497        | 1,4185            | 0,7574 | 1,4787            | 0,7459 |
| G-B         | 512 | 0,5884              | 0,9078        | 0,9150            | 0,8519 | 1,1171            | 0,8153 |
| R-B         | 512 | 0,7502              | 0,8809        | 1,0840            | 0,8219 | 1,2027            | 0,7990 |
| R-G         | 512 | 0,4659              | 0,9280        | 0,6888            | 0,8909 | 0,8545            | 0,8622 |
| R-G-B       | 768 | <b>0,4617</b>       | <b>0,9286</b> | 0,6569            | 0,8962 | 0,7801            | 0,8755 |

**Çizelge 6.8 :** Satır-sütun onluk metodu için  $\lambda$  tahmini

|             |     | YSA Öğrenme Yöntemi |               |                   |        |                   |        |
|-------------|-----|---------------------|---------------|-------------------|--------|-------------------|--------|
|             |     | LM<br>Tüm Sistem    |               | SCG<br>Tüm Sistem |        | OSS<br>Tüm Sistem |        |
| Renk Kanalı | ÖVS | MSE                 | R             | MSE               | R      | MSE               | R      |
| R           | 32  | 1,2063              | 0,7993        | 1,7498            | 0,6896 | 1,9032            | 0,6505 |
| G           | 32  | 0,6779              | 0,8929        | 0,8519            | 0,8631 | 0,9940            | 0,8380 |
| B           | 32  | 1,5651              | 0,7284        | 2,1637            | 0,5925 | 2,2710            | 0,5602 |
| Gr1         | 32  | 0,7778              | 0,8759        | 0,9985            | 0,8374 | 1,1465            | 0,8101 |
| Gr2         | 32  | 0,7470              | 0,8812        | 1,0056            | 0,8360 | 1,1216            | 0,8148 |
| Gr3         | 32  | 0,8107              | 0,8704        | 1,1059            | 0,8177 | 1,1541            | 0,8088 |
| Gr4         | 32  | 0,8584              | 0,8621        | 1,1573            | 0,8083 | 1,2484            | 0,7902 |
| H           | 32  | 0,6654              | 0,8949        | 0,8052            | 0,8712 | 0,9808            | 0,8404 |
| G-B         | 64  | 0,6331              | 0,9007        | 0,9050            | 0,8540 | 1,0985            | 0,8189 |
| R-B         | 64  | 0,9304              | 0,8501        | 1,3488            | 0,7719 | 1,5272            | 0,7365 |
| R-G         | 64  | 0,5042              | 0,9216        | 0,7982            | 0,8720 | 0,7879            | 0,8742 |
| R-G-B       | 96  | <b>0,4997</b>       | <b>0,9229</b> | 0,6941            | 0,8900 | 0,7998            | 0,8714 |

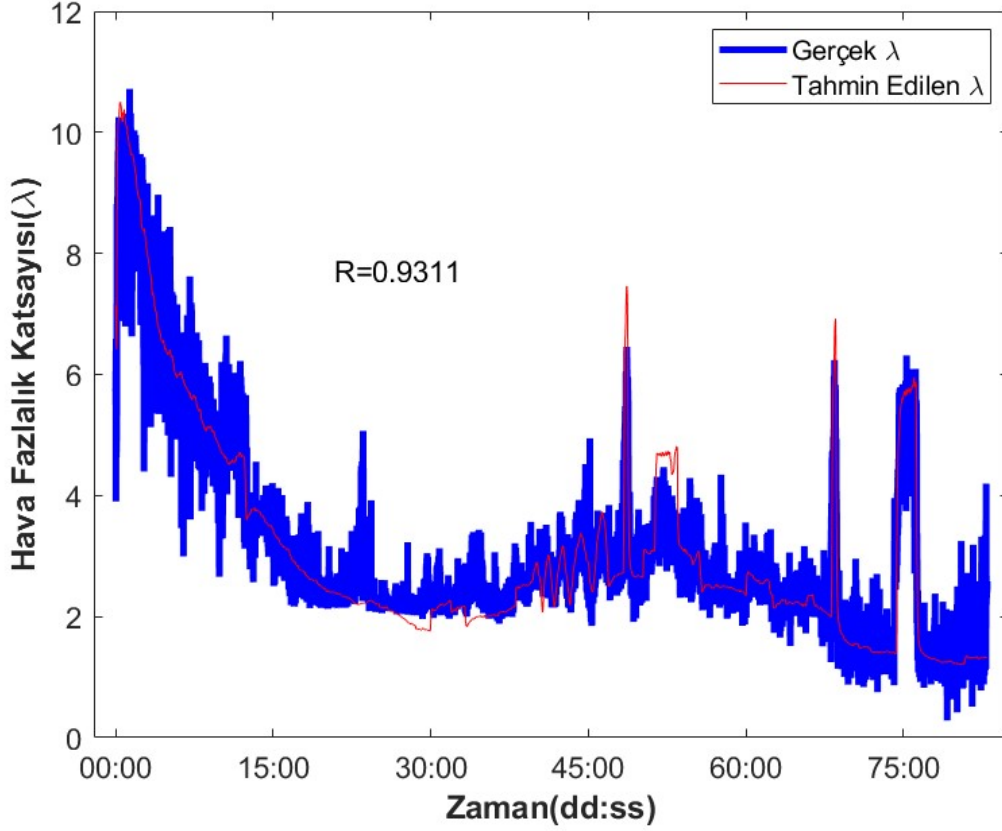
Çizelge 6.8’de görüldüğü gibi en yüksek başarımlı LM öğrenme yöntemi için R-G-B renk kanalları için kullanılarak  $R = 0,9229$  olarak bulunmuştur. Tekil görüntü için H renk kanalı için  $R = 0,8949$  olarak bulunmuştur. İkili görüntü için R-G kanallarında  $R = 0,9216$  olarak bulunmuştur.

#### 6.1.4 İdeal yanma bölgesi yöntemlerinin birlikte kıyaslanması

İdeal yanma bölgesi yöntemlerinde en yüksek başarımlı ikili görüntü öznelik elde etme yaklaşımı için Gr2 renk kanalı için SCG öğrenme yöntemiyle  $R = 0,9311$  olarak elde edilmiştir. En iyi model için gerçek ve tahmin edilen  $\lambda$ ’nın grafiksel olarak gösterimi Şekil 6.2’de verilmiştir. Öznelikler çıkarma yaklaşımları için en yüksek başarımlı elde edildiği renk kanalı ve YSA öğrenme yöntemi için R ve MSE değerleri Çizelge 6.9’da verilmiştir. Satır-sütun toplamı öznelik yöntemi için R-G-B renk kanalları için öznelik sayısı en yüksek modelin neredeyse 3’te bir kadar olmasına rağmen  $R = 0,9286$  olarak bulunmuştur. Bağımsız renk kanalı yaklaşımında genel olarak yöntemin başarımlı eşik değerine göre değişebildiği söylenebilir. Bu yüzden eşik değerinin istatistiksel olarak belirlenebildiği veya eşik değerine ihtiyaç olmayan modelleme yaklaşımlarına ihtiyaç olduğu söylenebilir. Bundan sonraki 4 yöntemde bunu başarmak için 4 farklı teknikle ideal yanmanın piksel bazında modellenmesi yaklaşımları ele alınacaktır. Bu 4 farklı yaklaşımın temelinde GD yer almaktadır.

Çizelge 6.9 : Öznelik yöntemleri için en iyi  $\lambda$  tahmini sonuçları

| Öznelik Yöntemi    | Renk Kanalı | ÖVS | Öğr. Yöntemi | Tüm Sistem |        | Test   |        |
|--------------------|-------------|-----|--------------|------------|--------|--------|--------|
|                    |             |     |              | MSE        | R      | MSE    | R      |
| İkili Görüntü      | Gr2         | 256 | SCG          | 0,4445     | 0,9311 | 0,6389 | 0,9013 |
| Biaslı Görüntü     | R-B         | 512 | SCG          | 0,4500     | 0,9303 | 0,6630 | 0,8986 |
| Satır Toplam       | R-G         | 32  | LM           | 0,7248     | 0,8851 | 0,8565 | 0,8655 |
| Satır Onluk        | R-G-B       | 48  | LM           | 0,9354     | 0,8486 | 1,2024 | 0,8074 |
| Sütun Toplam       | R-G-B       | 48  | LM           | 0,6236     | 0,9022 | 0,7543 | 0,8794 |
| Sütun Onluk        | R-G-B       | 48  | LM           | 0,7285     | 0,8842 | 0,9360 | 0,8470 |
| Satır-Sütun Toplam | R-G-B       | 96  | LM           | 0,4617     | 0,9286 | 0,7151 | 0,8857 |
| Satır-Sütun Onluk  | R-G-B       | 96  | LM           | 0,4997     | 0,9229 | 0,7831 | 0,8735 |



Şekil 6.2 : İkili görüntü yöntemi için gerçek ve tahmin edilen  $\lambda$

### 6.1.5 Ayrık benzerlik toplamı

Bu deneysel çalışmada, Bölüm 4'te 4.3.1 başlığında ifade edilen ayrık benzerlik olasılıkları yaklaşımı kullanılarak elde edilen özniteliklerin  $\lambda$  tahmini üzerindeki etkisi incelenmektedir. Bu yaklaşım kullanılarak renk kanallarından elde edilen öznitelikler bağımsız olarak veya birleştirilerek  $\lambda$ 'nın tahmininde kullanılmıştır. Elde edilen tahmin sonuçları Çizelge 6.10'da verilmektedir. Sonuçlar incelendiğinde bağımsız kanalların (R, G, B ve Gr2) tahmin doğruluklarının düşük olduğu görülmektedir. Tekil kanallarda G kanalı (LM kullanıldığında) R, G ve Gr2 kanallarından daha iyi tahminler sağlamıştır. Kanalların ikili kullanımında en iyi sonuç R ve G ile elde edilmiştir. Maksimum tahmin doğruluğu R, G ve B kanallarının SCG yöntemiyle birlikte kullanıldığında elde edilmiştir.

**Çizelge 6.10 : Ayrık benzerlik toplamı yaklaşımı  $\lambda$  tahmini sonuçları**

| Kanal        | ÖVS        | Öğr.       | Tüm Sistem    |               | Eğitim        |               | Test          |               |
|--------------|------------|------------|---------------|---------------|---------------|---------------|---------------|---------------|
|              |            |            | MSE           | R             | MSE           | R             | MSE           | R             |
| R            | 256        | SCG        | 0,5482        | 0,9143        | 0,4994        | 0,9221        | 0,6679        | 0,8955        |
| G            | 256        | SCG        | 0,3492        | 0,9463        | 0,2992        | 0,9541        | 0,4840        | 0,9254        |
| B            | 256        | SCG        | 0,5398        | 0,9153        | 0,4845        | 0,9249        | 0,6798        | 0,8913        |
| Gr2          | 256        | SCG        | 0,4134        | 0,9361        | 0,3649        | 0,9440        | 0,5223        | 0,9191        |
| G-B          | 512        | SCG        | 0,3440        | 0,9471        | 0,2953        | 0,9549        | 0,4518        | 0,9295        |
| R-B          | 512        | SCG        | 0,3217        | 0,9505        | 0,2631        | 0,9599        | 0,4590        | 0,9285        |
| R-G          | 512        | SCG        | 0,3253        | 0,9501        | 0,2745        | 0,9580        | 0,4410        | 0,9322        |
| <b>R-G-B</b> | <b>768</b> | <b>SCG</b> | <b>0,2453</b> | <b>0,9626</b> | <b>0,1896</b> | <b>0,9710</b> | <b>0,3751</b> | <b>0,9425</b> |
| R-G-B-Gr2    | 1024       | SCG        | 0,2822        | 0,9568        | 0,2274        | 0,9649        | 0,4100        | 0,9373        |
| R            | 256        | LM         | 0,4052        | 0,9383        | 0,2705        | 0,9604        | 0,7336        | 0,8873        |
| G            | 256        | LM         | 0,3204        | 0,9519        | 0,2114        | 0,9691        | 0,5748        | 0,9119        |
| B            | 256        | LM         | 0,4589        | 0,9295        | 0,3145        | 0,9529        | 0,8108        | 0,8738        |
| Gr2          | 256        | LM         | 0,3714        | 0,9436        | 0,2577        | 0,9626        | 0,6529        | 0,8942        |
| G-B          | 512        | LM         | 0,3009        | 0,9543        | 0,1705        | 0,9747        | 0,6049        | 0,9077        |
| R-B          | 512        | LM         | 0,3491        | 0,9483        | 0,2114        | 0,9706        | 0,6759        | 0,8954        |
| <b>R-G</b>   | <b>512</b> | <b>LM</b>  | <b>0,2874</b> | <b>0,9578</b> | <b>0,1637</b> | <b>0,9774</b> | <b>0,5679</b> | <b>0,9128</b> |
| R-G-B        | 768        | LM         | 0,3316        | 0,9516        | 0,1860        | 0,9753        | 0,7017        | 0,8941        |
| R-G-B-Gr2    | 1024       | LM         | 0,3160        | 0,9537        | 0,1755        | 0,9768        | 0,6512        | 0,8995        |

### 6.1.6 Bağımsız olasılık çarpımı

Çoklu kanalların birbiriyle bağlantılı olduğu varsayımına dayanmaktadır. Piksel olasılıkları hesaplanırken Naviye-Bayes metoduyla hesaplanmaktadır. Çizelge 6.11’de bağımsız olasılık çarpımı yaklaşımıyla elde edilen özniteliklerden  $\lambda$  tahmin doğrulukları verilmektedir. En iyi tahmin sonuçları hem SCG hemde LM öğrenme yöntemlerinde R ve G kanalları için bulunmuştur. Önceki deneylerde de benzer sonuç elde edilmişti. Dolayısıyla bu iki kanalın  $\lambda$ ’nın tahmininde diğer ikili kanallardan daha anlamlı bilgi içerdiği düşünülebilir.

**Çizelge 6.11 : Bağımsız olasılık çarpımıyla  $\lambda$  tahmini sonuçları**

|            |            |            | Tüm Sistem    |               | Eğitim        |               | Test          |               |
|------------|------------|------------|---------------|---------------|---------------|---------------|---------------|---------------|
| Kanal      | ÖVS        | Öğr.       | MSE           | R             | MSE           | R             | MSE           | R             |
| G-B        | 256        | LM         | 0,6593        | 0,8975        | 0,5264        | 0,9209        | 1,0000        | 0,8407        |
| R-B        | 256        | LM         | 0,6477        | 0,8985        | 0,4835        | 0,9263        | 1,0361        | 0,8384        |
| <b>R-G</b> | <b>256</b> | <b>LM</b>  | <b>0,4965</b> | <b>0,9244</b> | <b>0,3543</b> | <b>0,9485</b> | <b>0,8341</b> | <b>0,8687</b> |
| R-G-B      | 256        | LM         | 0,7444        | 0,8837        | 0,5770        | 0,9136        | 1,1440        | 0,8161        |
| G-B        | 256        | SCG        | 0,8061        | 0,8702        | 0,7612        | 0,8780        | 0,9214        | 0,8503        |
| R-B        | 256        | SCG        | 1,0299        | 0,8305        | 0,9973        | 0,8357        | 1,0849        | 0,8214        |
| <b>R-G</b> | <b>256</b> | <b>SCG</b> | <b>0,7690</b> | <b>0,8772</b> | <b>0,7262</b> | <b>0,8847</b> | <b>0,8840</b> | <b>0,8577</b> |
| R-G-B      | 256        | SCG        | 1,2500        | 0,7905        | 1,2043        | 0,7958        | 1,3666        | 0,7788        |

### 6.1.7 Çok değişkenli dağılım

CDGD modeliyle elde edilen özneliklerin  $\lambda$  tahmin doğrulukları Çizelge 6.12’de verilmektedir. En iyi tahmin sonuçları hem SCG hemde LM öğrenme yöntemlerinde R ve G kanalları için bulunmuştur. Önceki deneysel çalışmada da ikili kanal için R ve G kanaldan en iyi sonuçlar elde edilmişti. Çizelgeden de görüleceği gibi üç kanalın birlikte kullanılması doğruluğu düşürmektedir.

**Çizelge 6.12 : Çok değişkenli dağılım  $\lambda$  tahmin sonuçları**

|            |            |            | Tüm Sistem    |               | Eğitim        |               | Test          |               |
|------------|------------|------------|---------------|---------------|---------------|---------------|---------------|---------------|
| Kanal      | ÖVS        | Öğr.       | MSE           | R             | MSE           | R             | MSE           | R             |
| G-B        | 256        | LM         | 0,6303        | 0,9015        | 0,4815        | 0,9258        | 0,9837        | 0,8499        |
| R-B        | 256        | LM         | 0,5367        | 0,9178        | 0,4015        | 0,9408        | 0,8592        | 0,8631        |
| <b>R-G</b> | <b>256</b> | <b>LM</b>  | <b>0,3074</b> | <b>0,9535</b> | <b>0,2009</b> | <b>0,9705</b> | <b>0,5780</b> | <b>0,9113</b> |
| R-G-B      | 256        | LM         | 0,5867        | 0,9095        | 0,4317        | 0,9357        | 0,9519        | 0,8483        |
| G-B        | 256        | SCG        | 0,7780        | 0,8756        | 0,7411        | 0,8815        | 0,8761        | 0,8637        |
| R-B        | 256        | SCG        | 0,5781        | 0,9094        | 0,5360        | 0,9157        | 0,6910        | 0,8923        |
| <b>R-G</b> | <b>256</b> | <b>SCG</b> | <b>0,3201</b> | <b>0,9509</b> | <b>0,2705</b> | <b>0,9589</b> | <b>0,4355</b> | <b>0,9317</b> |
| R-G-B      | 256        | SCG        | 0,9307        | 0,8480        | 0,8914        | 0,8550        | 1,0736        | 0,8317        |

### 6.1.8 Karışım modeli

Karışım modeli olarak GKM kullanılmıştır. GKM ile öznelik çıkarılırken renkli görüntünün 2’li ve 3’lü kanalı birlikte kullanarak öznelikler çıkarılmıştır. İlgili bir görüntünün ağırlığı tekrarlı olarak artırılmış diğer ikisi eşit alınmıştır. Bu işlem yani bir


modelin ağırlığının artırılarak diğer doğruluğun araştırılması işlemi R, G ve B görüntüleri için birbirinden bağımsız 3 adet GKM ile gerçekleştirilmiştir. Ayrıca farklı 3 adet GKM ile sadece iki bileşen için de uygun katsayı araştırması benzer olarak yapılmıştır. 2 adet bileşen tek kullanılarak elde edilen en iyi sonuçlar model sonuçlarının kıyaslandığı çizelge de verilecektir. GKM modeli ile yapılan deneysel çalışmalar sonucunda renkli görüntü için hangi tek kanalın veya hangi iki kanalın daha fazla bilgi içerdiği araştırılmıştır. Ayrıca diğer iki kanal eşitken 3. kanal iteratif olarak artırılarak doğruluğun nasıl değiştiği araştırılmıştır. Bu deneysel çalışma sonucunda renk bileşenlerinin birlikte kullanılması durumunda her birinin yanma süreci hakkında ne kadar bilgi içerdiği yorumlana bilmektedir. Artırmalı ağırlık araştırılmasında en yüksek başarımlı LM YSA öğrenme modeli için R ve G renk kanallarında  $w_G = 0.95$  ve  $w_R = 0.05$  ağırlıklarının  $R = 0,9517$  olarak bulunmuştur. Diğer 3 modelde olduğu gibi R ve G kanalları en yüksek başarımın elde edildiği 2'li bileşendir.

### 6.1.9 Çok görüntüyle modelleme yöntemlerinin birlikte değerlendirilmesi

Bu başlıkta iki farklı deneysel çalışma yapılmıştır. Birinci deneyde, tez kapsamında önerilen yöntemlerden (ayrık benzerlik toplamı, bağımsız olasılık çarpımı, çok değişkenli dağılım ve karışım modeli) en doğru tahmin sonucunu sağlayanı tespit etmektir. İkinci deneyde, birinci deneyde tespit edilen en iyi yöntemin literatürdeki diğer yöntemlerle kıyaslanmasını sağlamaktır. Birinci deneyde, aynı alev veri kümesi ve çalışma parametreleri kullanılarak 12 gizli hücreli bir YSA eğitilmiştir. Yöntemlerin  $\lambda$  tahmin sonuçları Çizelge 6.13'te verilmektedir. Sonuçlar değerlendirildiğinde en yüksek tahmin doğruluğunun R, G ve B kanallarının ayrık benzerlik toplamı yöntemiyle elde edildiği görülmüştür. Bu yöntemin  $\lambda$  tahmin sonucu Şekil 6.3'te grafiksel olarak gösterilmektedir. Modellerin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 3 nolu klasörün içerisinde yer almaktadır. İkinci deneysel çalışmada, önerilen yöntemler içerisinde en doğru  $\lambda$  tahminlerini veren ayrık benzerlik toplamı yöntemi literatürdeki yaklaşımlar ile birlikte değerlendirilmiştir (Çizelge 6.14). Tüm yöntemler aynı veri kümesinden öznelik çıkarmakta ve 12 gizli hücreli YSA ile eğitilmektedir. Ayrık benzerlik toplamı yönteminin en doğru eşleşmeyi sağladığı görülmektedir. Önerilen yaklaşımda en doğru sonuca SCG ile elde edilirken, diğer yöntemlerde LM ile elde edildiği görülmüştür. Bunda ÖVS'nin etkili olduğu söylenebilir. Küçük boyutlarda LM'nin daha iyi çalıştığı gözlemlenmiştir.

**Çizelge 6.13 : Modelleme yaklaşımlarının  $\lambda$  tahmin sonuçları**

| Kanal     | ÖVS  | Öğr. | Ayrık Benzerlik |               | Naive Bayes |          | ÇDGD   |          | GKM                  |        |          |
|-----------|------|------|-----------------|---------------|-------------|----------|--------|----------|----------------------|--------|----------|
|           |      |      | MSE             | <i>R</i>      | MSE         | <i>R</i> | MSE    | <i>R</i> | Ağr. $[w_R w_G w_B]$ | MSE    | <i>R</i> |
| R         | 256  | SCG  | 0,5482          | 0,9143        | -           | -        | -      | -        | -                    | -      | -        |
| G         | 256  | SCG  | 0,3492          | 0,9463        | -           | -        | -      | -        | -                    | -      | -        |
| B         | 256  | SCG  | 0,5398          | 0,9153        | -           | -        | -      | -        | -                    | -      | -        |
| Gr2       | 256  | SCG  | 0,4134          | 0,9361        | -           | -        | -      | -        | -                    | -      | -        |
| G-B       | 512  | SCG  | 0,3440          | 0,9471        | 0,8061      | 0,8702   | 0,7780 | 0,8756   | 0,95-0,05            | 0,3738 | 0,9424   |
| R-B       | 512  | SCG  | 0,3217          | 0,9505        | 1,0299      | 0,8305   | 0,5781 | 0,9094   | 0,55-0,45            | 0,4507 | 0,9301   |
| R-G       | 512  | SCG  | 0,3253          | 0,9501        | 0,7690      | 0,8772   | 0,3201 | 0,9509   | 0,25-0,75            | 0,3464 | 0,9468   |
| R-G-B     | 768  | SCG  | <b>0,2453</b>   | <b>0,9626</b> | 1,2500      | 0,7905   | 0,9307 | 0,8480   | 0,025-0,95-0,025     | 0,3514 | 0,9460   |
| R-G-B-Gr2 | 1024 | SCG  | 0,2822          | 0,9568        | -           | -        | -      | -        | -                    | -      | -        |
| R         | 256  | LM   | 0,4052          | 0,9383        | -           | -        | -      | -        | -                    | -      | -        |
| G         | 256  | LM   | 0,3204          | 0,9519        | -           | -        | -      | -        | -                    | -      | -        |
| B         | 256  | LM   | 0,4589          | 0,9295        | -           | -        | -      | -        | -                    | -      | -        |
| Gr2       | 256  | LM   | 0,3714          | 0,9436        | -           | -        | -      | -        | -                    | -      | -        |
| G-B       | 512  | LM   | 0,3009          | 0,9543        | 0,6593      | 0,8975   | 0,6303 | 0,9015   | 0,95-0,05            | 0,3319 | 0,9498   |
| R-B       | 512  | LM   | 0,3491          | 0,9483        | 0,6477      | 0,8985   | 0,5367 | 0,9178   | 0,95-0,05            | 0,4062 | 0,9394   |
| R-G       | 512  | LM   | 0,2874          | 0,9578        | 0,4965      | 0,9244   | 0,3074 | 0,9535   | 0,05-0,95            | 0,3180 | 0,9517   |
| R-G-B     | 768  | LM   | 0,3316          | 0,9516        | 0,7444      | 0,8837   | 0,5867 | 0,9095   | 0,075-0,85-0,075     | 0,3275 | 0,9507   |
| R-G-B-Gr2 | 1024 | LM   | 0,3160          | 0,9537        | -           | -        | -      | -        | -                    | -      | -        |



**Şekil 6.3 : Ayrık benzerlik toplamı yöntemi için gerçek ve tahmin edilen  $\lambda$**

**Çizelge 6.14** : Literatürdeki yaklaşımların  $\lambda$  tahmin sonuçları ile kıyaslanması

|  |  |     |        | Tüm Sistem |        | Eğitim |        | Test   |        |
|--|--|-----|--------|------------|--------|--------|--------|--------|--------|
|  | Yöntem   | ÖVS | Öğr.   | MSE        | R      | MSE    | R      | MSE    | R      |
| Geliştirilen   | Ayrık Benzerlik Toplamı (RGB)                            | 768 | SCG    | 0,2453     | 0,9626 | 0,1896 | 0,9710 | 0,3751 | 0,9425 |
|  | Ayrık Benzerlik Toplamı (RG)                             | 512 | LM     | 0,2874     | 0,9578 | 0,1637 | 0,9774 | 0,5679 | 0,9128 |
| Diğerleri  | H-Hist (0-85,230) [13]                                   | 86  | SCG    | 1,1417     | 0,8109 | 1,1387 | 0,8112 | 1,1247 | 0,8090 |
|  | H-Hist (0-255) [13]                                      | 255 | SCG    | 1,1990     | 0,8003 | 1,1843 | 0,8035 | 1,2314 | 0,7964 |
|  | GLCM [9]   | 64  | SCG    | 0,8793     | 0,8587 | 0,8826 | 0,8577 | 0,8540 | 0,8616 |
|  | B-Hist (64) [9]  | 64  | SCG    | 1,4079     | 0,7608 | 1,4043 | 0,7610 | 1,4524 | 0,7562 |
|  | B-Hist (255) [9]   | 255 | SCG    | 1,3375     | 0,7743 | 1,3304 | 0,7758 | 1,3635 | 0,7678 |
|  | TBA [6]  | 2   | SCG    | 1,7196     | 0,6968 | 1,7252 | 0,6983 | 1,7514 | 0,6850 |
|  | RES-<br>$\  \cdot \ _F, \  \cdot \ _\infty$ [6]          | 4   | SCG    | 2,1871     | 0,5843 | 2,1981 | 0,5833 | 2,1436 | 0,5886 |
|  | $\mu$ (RES) [58, 111]                                    | 1   | SCG    | 2,7974     | 0,4037 | 2,7924 | 0,4032 | 2,8539 | 0,4023 |
|  | $\mu, \sigma, \gamma_s, \gamma_k$ [42]                   | 4   | SCG    | 1,9012     | 0,6568 | 1,8929 | 0,6570 | 1,9394 | 0,6569 |
|  | $\mu, \sigma$ ve $F$ [43]                                | 3   | SCG    | 1,5085     | 0,7407 | 1,5264 | 0,7381 | 1,4584 | 0,7433 |
|  | $\mu, \sigma, \gamma_s, \gamma_k$ ve $F$ [42]            | 5   | SCG    | 1,5542     | 0,7315 | 1,5520 | 0,7323 | 1,5322 | 0,7293 |
|  | $\mu, \sigma, \gamma_s, \gamma_k$ ve $\  \cdot \ $ [112] | 5   | SCG    | 1,3966     | 0,7629 | 1,3993 | 0,7620 | 1,3835 | 0,7699 |
|  | H-Hist (0-85,230) [13]                                   | 86  | LM     | 0,3951     | 0,9391 | 0,3539 | 0,9456 | 0,5099 | 0,9216 |
|  | H-Hist (0-255) [13]                                      | 255 | LM     | 0,4479     | 0,9307 | 0,3958 | 0,9394 | 0,5882 | 0,9082 |
|  | GLCM [9]   | 64  | LM     | 0,5624     | 0,9174 | 0,4059 | 0,9372 | 1,3880 | 0,8721 |
|  | B-Hist (64) [9]  | 64  | LM     | 0,7474     | 0,8811 | 0,7146 | 0,8865 | 0,8433 | 0,8653 |
|  | B-Hist (255) [9]   | 255 | LM     | 0,7216     | 0,8855 | 0,6786 | 0,8931 | 0,8437 | 0,8664 |
|  | TBA [6]  | 2   | LM     | 1,6464     | 0,7128 | 1,6363 | 0,7145 | 1,6840 | 0,7114 |
|  | RES-<br>$\  \cdot \ _F, \  \cdot \ _\infty$ [6]          | 4   | LM     | 1,4558     | 0,7510 | 1,4408 | 0,7534 | 1,5476 | 0,7428 |
|  | $\mu$ (RES) [58, 111]                                    | 1   | LM     | 2,7666     | 0,4149 | 2,7914 | 0,4152 | 2,7159 | 0,4052 |
| $\mu, \sigma, \gamma_s, \gamma_k$ [42]                   | 4  | LM  | 1,1056 | 0,8181     | 1,1044 | 0,8193 | 1,1293 | 0,8147 |        |
| $\mu, \sigma$ ve $F$ [43]                                | 3  | LM  | 1,0663 | 0,8252     | 1,0729 | 0,8250 | 1,0452 | 0,8281 |        |
| $\mu, \sigma, \gamma_s, \gamma_k$ ve $F$ [42]            | 5  | LM  | 0,9822 | 0,8404     | 0,9654 | 0,8428 | 1,0097 | 0,8368 |        |
| $\mu, \sigma, \gamma_s, \gamma_k$ ve $\  \cdot \ $ [112] | 5  | LM  | 0,9422 | 0,8475     | 0,9232 | 0,8520 | 1,0552 | 0,8277 |        |

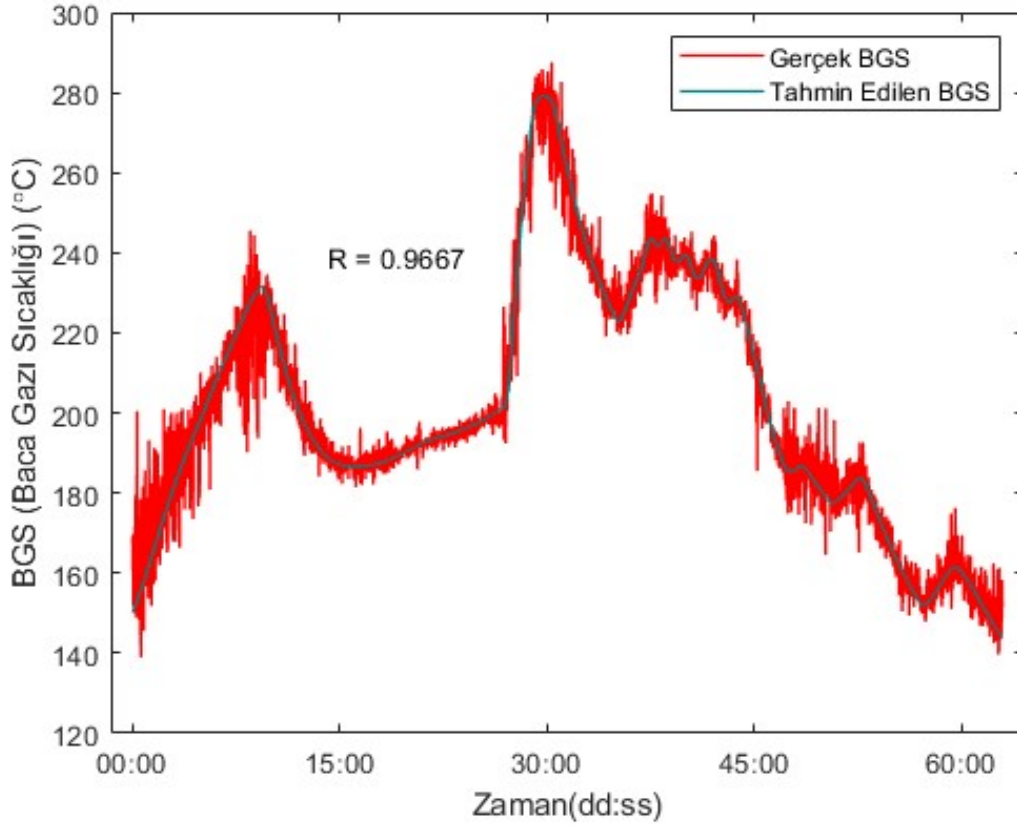
## 6.2 Uzamsal Yoğunluk Dağılımıyla BGS Tahmin Sonuçları

Bu deneyde, alev görüntüsü ile BGS arasındaki ilişki araştırılmıştır. BGA'dan elde edilen BGS değeri regresyon modelinin eğitilmesinde referans sıcaklık verisi olarak alınmıştır. Alev görüntüleri gri seviye görüntüye çevrilerek uzamsal yoğunluk dağılımı yöntemiyle öznetelikler elde edilmiştir. Bu özneteliklerin eğitiminde altı farklı DVR modeli kullanılmıştır. Çizelge 6.15'te özneteliklerin farklı DVR modellerindeki BGS tahmin başarımları verilmiştir [21].

Yapılan deneysel çalışmalar neticesinde elde edilen sonuçlar BGS ile alev görüntüsü arasında yüksek bir ilişki olduğunu ortaya koymuştur. En yüksek tahmin doğruluğu her üç özneteliğin birlikte kullanılması ve kübik DVR modelinin seçimiyle elde edilmiştir. İlgili DVR modeli için BGS ve alev görüntüsü arasında  $R = 0.9667$  korelasyon bulunmuş ve  $RMSE = 8,1210$  olmuştur. En iyi sonuçların elde edildiği kübik DVR modeli için gerçek ve DVR modeliyle tahmin edilen BGS grafiksel olarak Şekil 6.4'de verilmiştir.

**Çizelge 6.15 :** Uzamsal yoğunluk dağılımıyla BGS'nin tahmin için DVR modelleri başarımları

|                   |                | DVR Yöntemi   |               |            |         |                  |         |            |         |                |         |            |         |
|-------------------|----------------|---------------|---------------|------------|---------|------------------|---------|------------|---------|----------------|---------|------------|---------|
|                   |                | Kübik Gauss   |               | İnce Gauss |         | İkinci Dereceden |         | Orta Gauss |         | Doğrusal Gauss |         | Kaba Gauss |         |
|                   |                | R             | RMSE          | R          | RMSE    | R                | RMSE    | R          | RMSE    | R              | RMSE    | R          | RMSE    |
| Öznetelik Yöntemi | Hist-Xtop      | 0,9471        | 10,2549       | 0,9308     | 11,6131 | 0,9296           | 11,6536 | 0,8054     | 18,7364 | 0,7759         | 19,9672 | 0,7360     | 21,7168 |
|                   | Hist-Xtop-Ytop | <b>0,9667</b> | <b>8,1210</b> | 0,9638     | 8,4938  | 0,9579           | 9,0929  | 0,8577     | 16,3873 | 0,8396         | 17,1482 | 0,7635     | 20,8029 |
|                   | Hist-Ytop      | 0,9296        | 11,8481       | 0,9166     | 12,7463 | 0,9292           | 11,6799 | 0,8267     | 18,3374 | 0,8311         | 17,5901 | 0,6724     | 24,3849 |
|                   | Xtop           | 0,8783        | 15,7788       | 0,8974     | 13,9832 | 0,8741           | 15,3440 | 0,7785     | 19,8253 | 0,7386         | 21,3147 | 0,7201     | 22,2235 |
|                   | Xtop-Ytop      | 0,9358        | 11,3818       | 0,9493     | 10,0752 | 0,9328           | 11,3877 | 0,8335     | 17,5243 | 0,7958         | 19,1257 | 0,7603     | 20,9651 |
|                   | Ytop           | 0,8357        | 19,7944       | 0,8660     | 16,0909 | 0,8807           | 14,9741 | 0,7793     | 20,1937 | 0,7458         | 21,0355 | 0,6942     | 24,4423 |
|                   | Hist           | 0,8128        | 19,5330       | 0,7039     | 22,4471 | 0,8372           | 17,3024 | 0,5805     | 25,9180 | 0,6418         | 24,3690 | 0,4607     | 28,7412 |



**Şekil 6.4 :** Kübik DVR kullanılarak BGS tahmini modelinin tahmin ettiği baca gazı sıcaklığı

BGS tahmininde son deneysel çalışmada önerilen öznitelik çıkarma yöntemi ile literatürdeki diğer öznitelik çıkarma yöntemleri aynı veri seti için 6 çeşit DVR modeliyle gerçekleştirilmiştir. Burada hedeflenen sadece öznitelik çıkarma yöntemlerinin performansını kıyaslamaktır. Diğer yöntemlerin sonuçları verilirken 6 çeşit DVR modelinden sadece en iyi DVR modeli için sonuç verilecektir. Çizelge 6.16’da önerilen öznitelik elde etme yöntemi ve diğer yöntemlerin sonuçları verilmiştir.

**Çizelge 6.16 :** Önerilen öznitelik elde etme yöntemi ve diğer yöntemlerin kıyaslanması

| Öznitelik Yöntemi                 |  | Regresyon Modeli     | R             | RMSE          |
|-----------------------------------|--|----------------------|---------------|---------------|
| Hist-Xtop- Ytop<br>(Geliştirilen) |  | Kübik DVR            | <b>0,9667</b> | <b>8,1210</b> |
| Diğerleri                         | $\mu, \sigma, \gamma_s, \gamma_k$ [42] | Kübik DVR            | 0,8188        | 114,4578      |
|                                   | H-Hist(0 – 255) [13]                   | Doğrusal DVR         | 0,7465        | 132,0836      |
|                                   | H-Hist(0 – 85) [13]                    | Doğrusal DVR         | 0,7429        | 132,8853      |
|                                   | H-Hist(30 – 65) [13]                   | İnce Gauss DVR       | 0,5896        | 162,2839      |
|                                   | $\mu$ [58, 111]                        | İkinci Dereceden DVR | 0,3888        | 187,6765      |


Çizelge 6.16'dan da görüldüğü gibi önerilen öznitelik elde etme yöntemi diğer yöntemlere göre daha başarılı olmuştur. Çizelge 6.15 ve 6.16 birlikte değerlendirildiğinde uzamsal yoğunluk dağılımıyla elde edilen özniteliklerinin yanma süreci hakkında bilgi edinilmesinde etkin olduğu söylenebilir. Modellerin daha ayrıntılı sonuçları Ek D. CD'sinde 4 nolu klasörün içerisinde yer almaktadır.

### 6.2.1 Sonuçlar ve değerlendirme

Bu deneysel çalışmayla alev görüntüsünün uzamsal yoğunluk dağılımı ile BGS arasındaki ilişki incelenmiştir. Deneysel çalışmada BGS tahmini yüksek olup kapalı çevrim yanma kontrol sistemlerinde kullanılacak bir modeldir. Gri seviye alev görüntüsünün öznitelikleri ile BGS arasında ilişki ortaya konulurken kübik DVR modeli en yüksek başarıyı vermiştir. CCD kameralar yanma süreçlerinde emisyon kontrolünde ve yanmanın izlenip kontrol edilmesi için zaten kullanıldığı için önerilen yöntem bu sistemlere BGS tahmini bileşenini eklemeyi mümkün hale getirmektedir. Böylece yüksek BGS'den kaynaklanan verim düşümünün önüne geçilip kazan verimi arttıracak tedbirler alınabilir. Ayrıca düşük sıcaklıkta ortaya çıkan sülfirik asit ( $H_2SO_4$ ) oluşumunun önüne geçilerek kazan ekipmanlarında korozyona sebep olmayacak şekilde ayarlama işlemlerinin yapılmasına imkân verir. Gelecekte farklı kapasitedeki kazanlar ile gerçekleştirilecek çalışmalarda alev görüntüsü ile BGS arasındaki ilişkinin kazanın kapasitesi değiştiğinde nasıl olacağı araştırılabilir.

### 6.3 Kümülatif Uzamsal Yoğunluk Dağılımı ile $NO_x$ Emisyonunun Tahmini

Bu deneysel çalışmada uzamsal yoğunluk dağılımıyla BGS'nin tahmin edilmesi çalışmasındaki verilerin aynısı kullanılmıştır. Gerçekleştirilen sistem ile BGA'dan ölçülen  $NO_x$  değeri, gri seviye alev görüntüsü kullanılarak YSA regresyon modeli ile tahmin edilmiştir. Şekil 6.5'de  $NO_x$  emisyonu için YSA modeli ile tahmin edilen ve BGA'dan ölçülen değerler verilmiştir. YSA regresyon modeli  $NO_x$  emisyonunu  $R=0,9522$  doğrulukla bulmuştur. Önerilen öznitelik elde etme yönteminin performansının daha iyi belirlenmesi için aynı veri seti ve aynı YSA mimarisıyla literatürdeki  $NO_x$  emisyonu için sunulan diğer öznitelik çıkarma yöntemlerinin sonuçları Çizelge 6.17'de karşılaştırılmalı olarak verilmiştir. Sonuçlar kıyaslanırken LM, SCG, BFG (BFGS Quasi-Newton), ve CGF (Fletcher-Powell Conjugate Gradient) YSA öğrenme modellerinin hem önerilen öznitelik elde etme yöntemi için hem de literatürde sunulan diğer yöntemler için sonuçları verilmiştir.



Şekil 6.5 : YSA modeli için gerçek ve tahmin edilen  $NO_x$  değeri

Çizelge 6.17 : Kümülatif uzamsal yoğunluk dağılımı ile  $NO_x$  emisyonunun tahmin için YSA regresyon modeli sonuçları

|           | Öznitelik        | YSA Öğrenme | RMSE     | R      |
|-----------|------------------|-------------|----------|--------|
| Önerilen  | XKtop-YKtop      | LM          | 59,5667  | 0,9522 |
|           | XKtop-YKtop      | BFG         | 99,8960  | 0,8630 |
|           | XKtop-YKtop      | CGF         | 94,0720  | 0,8796 |
|           | XKtop-YKtop      | SCG         | 95,9419  | 0,8744 |
| Diğerleri | Hist (0-85)[13]  | LM          | 91,5813  | 0,8866 |
|           | Hist (30-65)[13] | LM          | 121,5446 | 0,7892 |
|           | Hist (0-85)[13]  | BFG         | 121,9160 | 0,7875 |
|           | Hist (30-65)[13] | BFG         | 143,5067 | 0,6871 |
|           | Hist (0-85)[13]  | CGF         | 120,7416 | 0,7891 |
|           | Hist (30-65)[13] | CGF         | 145,9047 | 0,6726 |
|           | Hist (0-85)[13]  | SCG         | 116,8106 | 0,8056 |
|           | Hist (30-65)[13] | SCG         | 142,7049 | 0,6918 |
|           | $\mu$ [58]       | LM          | 176,640  | 0,451  |
|           | $\mu$ [58]       | BFG         | 177,8769 | 0,4384 |
|           | $\mu$ [58]       | CGF         | 178,6680 | 0,4309 |
|           | $\mu$ [58]       | SCG         | 178,1875 | 0,4353 |


Çizelge 6.17’de görüldüğü gibi deneysel çalışmalarda farklı YSA öğrenme yöntemleri ile tekrarlanmıştır. YSA regresyon modeli sonuçları değerlendirildiğinde LM öğrenme yöntemi fazla bellek ihtiyacı dezavantajına rağmen daha iyi sonuç vermiştir. BFG, CGF ve SCG öğrenme yöntemlerinin daha az bellek ihtiyacı olmakta ve daha hızlı icra edilmiştir. Fakat bu yöntemlerde model doğruluğu LM yöntemine göre düşük kalmaktadır. [13] nolu çalışmada  $NO_x$  emisyonu ve H histogramının [30-65] çubukları arasında ilişki olduğu bildirilmesine rağmen yapılan deneysel çalışma da ilgili histogramın [0-85] çubukları ve  $NO_x$  emisyonu arasında daha yüksek ilişki bulunmuştur. Çizelge 6.17’de verilen [58] nolu çalışmanın deney kazanına 16 adet kamera monte edilerek görüntü alınmıştır. Bu çalışmadaki veri seti tek kamera ile alınan verileri içermektedir. İlgili çalışmadaki öznitelik elde etme yöntemi tek kamera için bu çalışmadaki veriler ile yapılarak sonuçları sunulmuştur.

### 6.3.1 Sonuçlar ve değerlendirme

YSA regresyon modeli ile gri seviye alev görüntüsünün kümülatif uzamsal yoğunluk dağılımı kullanarak zor bir problem olan kömür kazanında alev görüntüsünden  $NO_x$  emisyonun tahmin edilmiştir. Literatürde bildirilen diğer yöntemlerden daha başarılı sonuçlar elde edilmiştir. Bu deney düzeneği kullanılarak alev görüntüsünden farklı öznitelik çıkarma yöntemleri ve farklı regresyon yöntemleri ile tekrar denenip geliştirilmeye açıktır. Deneysel çalışmalar sonucunda elde edilen ve literatürde sunulan diğer yöntemler genel olarak değerlendirildiğinde CCD kamera ile yakalanan alev görüntüsünün işlenmesi suretiyle  $NO_x$  emisyonu tahmini hem öznitelik elde etme yöntemleri hem de öğrenme yöntemleri için geliştirilmeye açık olduğu söylenebilir.

## 6.4 Görüntü Normları ile BGS Tahmini

Bu deneysel çalışmada BGS ve alev görüntüsü arasındaki ilişki incelenmiştir. Bu deney çalışmasında deney-3 verileri kullanılarak gerçekleştirilmiştir. Bu deneysel çalışma makale olarak sunulmuştur [22]. Tezde verilen sonuçlar YSA modellerinin on kez koşuturulup ortalaması alınan değerler olduğu için makaledeki sonuçlarla kısmi farklılıklar oluşmuştur. Öznitelik çıkarma aşamasında alev görüntüsünün değişik normlarının değişik pencere boyutlarındaki başarımları ele alınmıştır. Şekil 6.6’da deney boyunca (a) BGS ( $^{\circ}C$ )- $O_2$  (%) konsantrasyonu, (b)  $SO_2$  ( $mg/kwh$ )- $NO_x$  ( $mg/kwh$ ) ve (c)  $CO_2$  ( $mg/kwh$ )- $CO$  ( $mg/kwh$ ) emisyon grafikleri verilmiştir.



**Şekil 6.6 :** Deney boyunca (a) BGS ( $^{\circ}C$ )- $O_2$  (%) konsantrasyonu, (b)  $SO_2$  ( $mg/kwh$ )-  $NO_x$  ( $mg/kwh$ ) ve (c)  $CO_2$  ( $mg/kwh$ )- $CO$  ( $mg/kwh$ ) emisyon grafikleri

Deney boyunca Şekil 6.6'daki grafiklerinden de görüldüğü gibi yanma gerçekleştikten bir süre sonra veri alınmaya başlanmış ve yanmanın ilk 4 dakikasından sonra sistem anca kararlı rejime gelmiştir. Bu veriler sıcaklık değişim aralığını geniş tutmak açısından deneye dahil edilmiştir. Elde edilen BGA verileri referans alınarak alev görüntülerinden özellikler çıkarılmıştır. Bu veriler YSA regresyon modelini eğitmede kullanılmıştır. Alev görüntüsü ele alınırken 3 şey incelenmiştir. Birincisi öznitelik çıkarma aşamasında yanma işlemini daha iyi ifade etmek için Şekil 4.1'de verilen 6 adet alev görüntüsünden (R-G, R-G-B, Gr1, Gr2, Gr3 ve B) hangisinin kullanılacağına karar vermek. İkincisi optimum pencere boyutuna karar verme ve sonucusu en iyi öznitelik çıkarma yöntemine karar vermek. Modellerin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 6 nolu klasörün içerisinde yer almaktadır. Çizelge 6.18'de yerel pencere boyutu ve öznitelik yönteminin BGS tahminine etkisi verilmiştir. Öğrenme aşamasında gizli katmandaki optimum nöron sayısı araştırılmıştır. Çizelge 6.19'da ayrıntılı görüleceği gibi en iyi sonuçlar alev görüntüsünün R, G ve B bileşenlerinin birlikte kullanıldığı modelde LM YSA öğrenme modelinde 8 gizli nörona sahip modelde alınmıştır. Bu yüzden Çizelge 6.18'de alev görüntüsünün değişik normlarının değişik pencere boyutundaki başarımları R, G ve B görüntü kanalları için LM yöntemindeki BGS tahmin sonucu verilmiştir. Çizelge 6.18'de görüldüğü gibi BGS ve alev görüntüsü arasındaki en yüksek ilişki 6x6 pencere boyutu için öznitelik çıkarma yöntemi olarak spektral norm kullanıldığında elde edilmiştir. Çizelge 6.19'da öznitelik yöntemi olarak spektral norm alındığında 6x6 pencere boyutu için Şekil 4.1'de verilen alev görüntülerinden hangisi veya hangilerinin en anlamlı bilgi içerdiği araştırılmıştır.

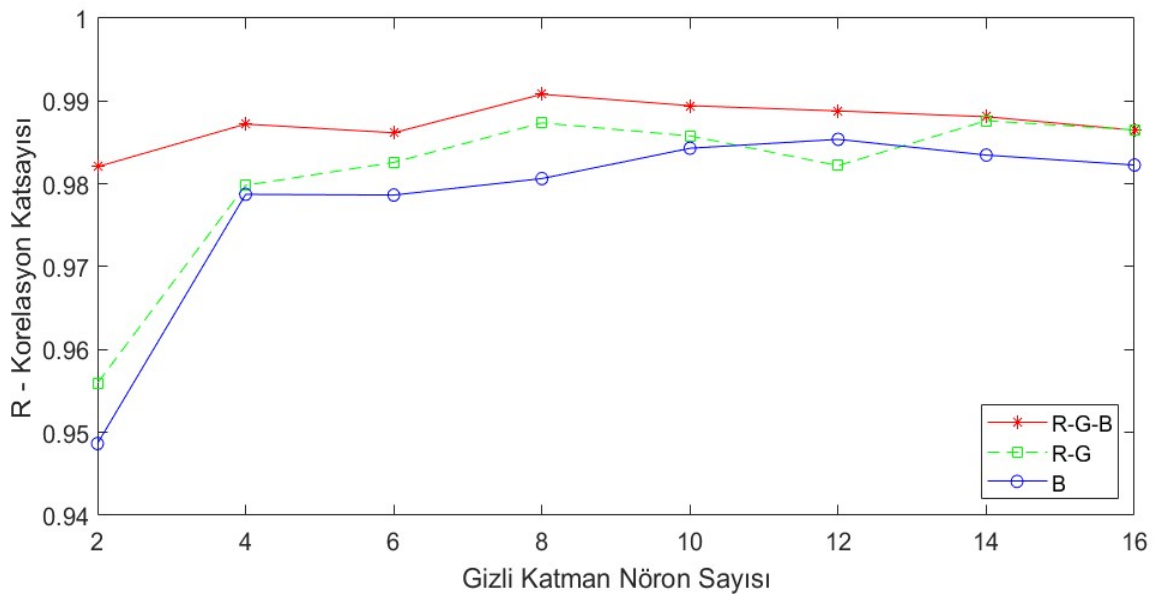
**Çizelge 6.18 :** Yerel pencere boyutu ve öznitelik yönteminin (normlarının) BGS tahminine etkisi

|                      |              | Spektral Norm |                      | Frobinous Norm |               | Sonsuzluk Normu |               | Norm-1  |               |
|----------------------|--------------|---------------|----------------------|----------------|---------------|-----------------|---------------|---------|---------------|
|                      |              | RMSE          | <i>R</i>             | RMSE           | <i>R</i>      | RMSE            | <i>R</i>      | RMSE    | <i>R</i>      |
| Yerel Pencere Sayısı | <b>1x1</b>   | 45,2902       | <i>0,4971</i>        | 42,6124        | <i>0,5753</i> | 44,2960         | <i>0,5300</i> | 45,5653 | <i>0,4884</i> |
|                      | <b>2x2</b>   | 20,8241       | <i>0,9168</i>        | 20,9905        | <i>0,9152</i> | 31,1307         | <i>0,8029</i> | 29,4990 | <i>0,8250</i> |
|                      | <b>3x3</b>   | 10,7778       | <i>0,9783</i>        | 11,5252        | <i>0,9750</i> | 15,6404         | <i>0,9540</i> | 17,0663 | <i>0,9450</i> |
|                      | <b>4x4</b>   | 9,1044        | <i>0,9847</i>        | 8,5169         | <i>0,9865</i> | 11,9220         | <i>0,9735</i> | 10,6283 | <i>0,9790</i> |
|                      | <b>5x5</b>   | 7,2717        | <i>0,9902</i>        | 7,7068         | <i>0,9891</i> | 11,2818         | <i>0,9758</i> | 10,2658 | <i>0,9802</i> |
|                      | <b>6x6</b>   | <b>7,0323</b> | <b><i>0,9908</i></b> | 8,7580         | <i>0,9855</i> | 10,6826         | <i>0,9785</i> | 10,2187 | <i>0,9803</i> |
|                      | <b>7x7</b>   | 8,5430        | <i>0,9863</i>        | 9,1162         | <i>0,9851</i> | 10,0098         | <i>0,9811</i> | 9,2556  | <i>0,9841</i> |
|                      | <b>8x8</b>   | 9,5964        | <i>0,9828</i>        | 8,4887         | <i>0,9866</i> | 11,8143         | <i>0,9747</i> | 10,0218 | <i>0,9816</i> |
|                      | <b>9x9</b>   | 9,8057        | <i>0,9821</i>        | 9,9546         | <i>0,9821</i> | 10,9276         | <i>0,9788</i> | 11,5733 | <i>0,9753</i> |
|                      | <b>10x10</b> | 10,8711       | <i>0,9773</i>        | 10,2206        | <i>0,9807</i> | 12,9839         | <i>0,9622</i> | 13,4338 | <i>0,9596</i> |
|                      | <b>11x11</b> | 11,5374       | <i>0,9718</i>        | 11,1040        | <i>0,9748</i> | 13,0065         | <i>0,9659</i> | 11,6080 | <i>0,9751</i> |
|                      | <b>12x12</b> | 14,7584       | <i>0,9461</i>        | 12,6145        | <i>0,9603</i> | 15,6258         | <i>0,9454</i> | 13,1338 | <i>0,9648</i> |
|                      | <b>13x13</b> | 14,1638       | <i>0,9540</i>        | 11,5119        | <i>0,9755</i> | 16,6883         | <i>0,9357</i> | 13,7338 | <i>0,9627</i> |
|                      | <b>14x14</b> | 14,3106       | <i>0,9572</i>        | 21,3300        | <i>0,8948</i> | 18,6365         | <i>0,9218</i> | 14,1190 | <i>0,9592</i> |
|                      | <b>15x15</b> | 16,2850       | <i>0,9305</i>        | 16,8512        | <i>0,9418</i> | 14,8915         | <i>0,9580</i> | 16,5730 | <i>0,9455</i> |
|                      | <b>16x16</b> | 14,2999       | <i>0,9585</i>        | 17,5693        | <i>0,9310</i> | 16,6858         | <i>0,9319</i> | 15,2015 | <i>0,9488</i> |

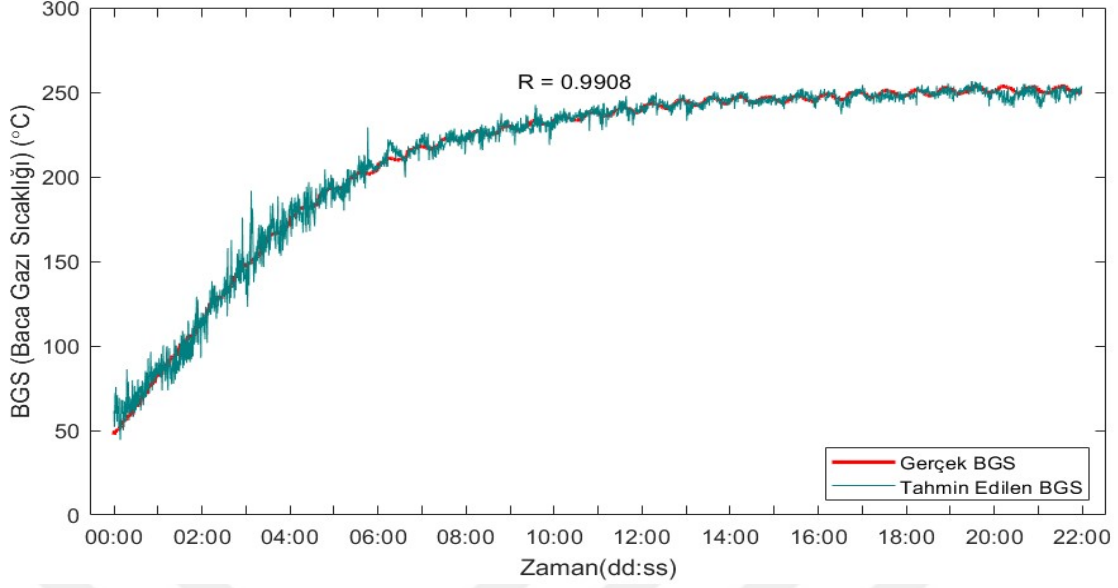
Çizelge 6.18’de görüldüğü gibi BGS ve alev görüntüsü arasındaki en yüksek ilişki R, G ve B görüntüsünün birlikte kullanıldığı öznitelik çıkarma yönteminde ve 6x6 pencere boyutu için elde edilmiştir. YSA regresyon modelinde gizli katmandaki nöron sayısı seçimli olduğu için optimum gizli katman nöron sayısı araştırılması yapılmıştır. Şekil 6.7’de R-G-B, R-G ve B görüntüleri için spektral norm öznitelik elde etme yöntemi ve pencere sayısı 6x6 iken değişik gizli katman nöron sayısının BGS tahmini modelinin başarımına olan etkisi grafiksel olarak verilmiştir. Şekil 6.7’de görüldüğü gibi en iyi sonuçların alındığı R, G ve B görüntüleri için alınmıştır. Bu modelde öznitelik elde etme yöntemi olarak spektral norm kullanılmıştır. Pencere sayısı 6x6 olduğu durum için ideal gizli katman sayısı 8 olmaktadır. R ve G görüntüleri ve B görüntüsü için ideal gizli katman nöron sayısı 14 olmaktadır. İdeal nöron sayısı ÖV’lerin yapısı ve YSA’nin öğrenme başarımına göre problemde problemde değişken olabilmektedir. Önerilen ideal YSA regresyon modeli için BGA tarafından ölçülen gerçek ve YSA regresyon modeliyle tahmin edilen BGS değerleri grafiksel olarak Şekil 6.8’da verilmiştir.

Çizelge 6.19 : Renk kanalları ve farklı pencere sayısı için BGS tahmini başarımlar

|                      |       | Renk Kanalı için R Değeri (Tüm Model) |               |        |        |        |        |
|----------------------|-------|---------------------------------------|---------------|--------|--------|--------|--------|
|                      |       | RGB                                   | RG            | B      | Gr1    | Gr2    | Gr3    |
| Yerel Pencere Sayısı | 1x1   | 0,4971                                | 0,4889        | 0,2844 | 0,3223 | 0,3240 | 0,3352 |
|                      | 2x2   | 0,9168                                | 0,7953        | 0,6794 | 0,6329 | 0,6368 | 0,6251 |
|                      | 3x3   | 0,9783                                | 0,9556        | 0,9475 | 0,9364 | 0,9364 | 0,9280 |
|                      | 4x4   | 0,9847                                | 0,9819        | 0,9735 | 0,9742 | 0,9698 | 0,9730 |
|                      | 5x5   | 0,9902                                | 0,9839        | 0,9794 | 0,9822 | 0,9812 | 0,9798 |
|                      | 6x6   | <b>0,9908</b>                         | <b>0,9874</b> | 0,9806 | 0,9797 | 0,9827 | 0,9837 |
|                      | 7x7   | 0,9863                                | 0,9849        | 0,9823 | 0,9840 | 0,9814 | 0,9823 |
|                      | 8x8   | 0,9828                                | 0,9806        | 0,9786 | 0,9792 | 0,9819 | 0,9800 |
|                      | 9x9   | 0,9821                                | 0,9829        | 0,9822 | 0,9827 | 0,9849 | 0,9769 |
|                      | 10x10 | 0,9773                                | 0,9781        | 0,9859 | 0,9799 | 0,9815 | 0,9793 |
|                      | 11x11 | 0,9718                                | 0,9620        | 0,9777 | 0,9801 | 0,9784 | 0,9774 |
|                      | 12x12 | 0,9461                                | 0,9651        | 0,9809 | 0,9825 | 0,9783 | 0,9807 |
|                      | 13x13 | 0,9540                                | 0,9718        | 0,9759 | 0,9721 | 0,9726 | 0,9686 |
|                      | 14x14 | 0,9572                                | 0,9352        | 0,9737 | 0,9682 | 0,9690 | 0,9755 |
|                      | 15x15 | 0,9305                                | 0,9496        | 0,9668 | 0,9646 | 0,9720 | 0,9665 |
|                      | 16x16 | 0,9585                                | 0,9540        | 0,9359 | 0,9645 | 0,9103 | 0,9637 |



Şekil 6.7 : Gizli katman nöron sayısının modelin başarımına olan etkisi



**Şekil 6.8 :** YSA modeli için gerçek ve modelin tahmin ettiği BGS

BGS tahmininde son deneysel araştırmada önerilen öznelik çıkarma yapısı ile literatürdeki diğer öznelik çıkarma yöntemleri aynı veri seti ve YSA regresyon modeli için test edilmiştir. Gizli katman nöron sayısı 2-16 arasında çift sayılar için alınmıştır. Tablodaki veriler ilgili yöntem için en iyi başarımın alındığı sonuçlardır. Tüm modeller 10 kez koşturularak ortalamaları alınmıştır. Elde edilen sonuçlar Çizelge 6.20’de verilmiştir. En iyi sonuçlar LM öğrenme yöntemi için alınmıştır. R-G-B renk kanallarında gizli katman nöron sayısı 8, R-G ve B kanallarında 14 olmaktadır. R-G-B ve R-G kanallarında ideal ızgara sayısı  $6 \times 6$  iken B kanalında  $8 \times 8$  olmaktadır. Literatür kıyaslaması ile hedeflenen literatüre geçen çalışmalardaki başarım ile geliştirilen modeldeki başarımı kıyaslamak değil sadece öznelik çıkarma yöntemlerinin performansını kıyaslamaktır. Geliştirilen spektral norm ile öznelik çıkarma ve alev görüntüsünü pencerelere bölme yaklaşımı diğer önerilen öznelik çıkarma yöntemlerinden daha iyi sonuç vermiştir. [58] nolu çalışmada 16 adet kameranın görüntüsü birleştirilerek çalışma yapılmış bu deneysel çalışmada tek kamera kullanılmıştır. [58] çalışmadaki başarım düşüklüğü bu sebepten olabilir.

**Çizelge 6.20 : Önerilen yöntemin mevcut yöntemlerle karşılaştırılması**

|           | Yöntem   | Kanal | Boyutu  | Tüm Sitem |        | Eğitim  |        | Test    |        |
|-----------|--|-------|---------|-----------|--------|---------|--------|---------|--------|
|           |  |       |         | RMSE      | R      | RMSE    | R      | RMSE    | R      |
| Önerilen  | $\ k\ _s$  | R-G-B | 6x6     | 7,0323    | 0,9908 | 5,4342  | 0,9945 | 9,9916  | 0,9813 |
|           | $\ k\ _s$  | R-G   | 6x6     | 8,1554    | 0,9876 | 6,1551  | 0,9928 | 11,6626 | 0,9751 |
|           | $\ k\ _s$  | B     | 8x8     | 8,5495    | 0,9868 | 6,7099  | 0,9919 | 12,1287 | 0,9735 |
| Diğerleri | Piksel [65]                                      | Gr3   | 480x480 | 9,7422    | 0,9822 | 0,2237  | 1,0000 | 18,1629 | 0,9382 |
|           | Hist[9]  | B     | 1x1     | 13,9171   | 0,9638 | 13,2098 | 0,9674 | 15,6610 | 0,9537 |
|           | $\mu, \sigma, \gamma_s, \gamma_k$<br>ve $F$ [42] | Gr2   | 1x1     | 15,5965   | 0,9543 | 15,1532 | 0,9567 | 16,9455 | 0,9454 |
|           | $\mu, \sigma, \gamma_s,$<br>$\gamma_k$ [42]      | Gr1   | 1x1     | 17,9370   | 0,9391 | 17,5988 | 0,9410 | 18,8849 | 0,9332 |
|           | $\mu, \sigma$ ve $F$ [43]                        | Gr1   | 1x1     | 23,1677   | 0,8957 | 22,9088 | 0,8984 | 24,0708 | 0,8888 |
|           | $\mu$ [45]                                       | Gr2   | 1x1     | 49,3900   | 0,3260 | 49,2953 | 0,3294 | 49,7669 | 0,3321 |
|           | $\mu$ [58, 111]                                  | Gr1   | 1x1     | 49,4180   | 0,3253 | 49,5974 | 0,3270 | 49,2485 | 0,3283 |

#### 6.4.1 Sonuçlar ve değerlendirme

Bu deneysel çalışma sonucunda elde edilen BGS tahmini başarıyı yüksek olup yanma kontrol sistemlerinde sistemin beslenmesinde kullanılabilir. Farklı kapasitedeki kömür kazanları ile yapılacak çalışmalarda alev formu ile BGS arasındaki ilişkiyle kazanın kapasitesinden nasıl etkilendiği araştırılabilir. Elde edilen deneysel sonuçlar alev görüntüsü ile BGS'nin tahmin edilebileceğini göstermektedir. Alev görüntüsü ile BGS tahmini çalışması incelediğimiz kadarıyla daha önce hiç çalışılmamış olup ilk kez tarafımızca incelenmiştir.

#### 6.5 Evrişimsel Sinir Ağları ile BGS Tahmini

Bu deneysel çalışma görüntü momentleri ile BGS'nin tahmin edilmesi deneyindeki veri seti için gri görüntü, RGB renkli görüntüsü, RGB renkli görüntüsünün ikili bileşenleri ile hem ön eğitilmiş derin ağlar hemde yeni oluşturulan ESA'lar ile BGS tahmini yapılmıştır. Tüm deneylerde veri setinin %70'i eğitim, %15'i doğrulama ve %15'i test işlemi için kullanılmıştır. Tekil kanal görüntüsü, renkli RGB görüntüsü ile RGB görüntüsünün ikili

bileşenleri için geliştirilen ESA'nın katmanları Çizelge 6.21'de verilmiştir. Tekil kanal görüntüsü için 18 diğerleri için 21 katmanlı bir ESA oluşturulmuştur.

**Çizelge 6.21 : Geliştirilen ESA mimarisi**

|                  | <b>Tekil Kanal Görüntü</b> | <b>RGB-RG-GB-RG</b>  |
|------------------|----------------------------|----------------------|
| <b>Katman No</b> | <b>Açıklama</b>            | <b>Açıklama</b>      |
| 1                | Görüntü Girişi             | Görüntü Girişi       |
| 2                | Evrişim                    | Konvolusyon          |
| 3                | Yığın Normalizasyonu       | Yığın Normalizasyonu |
| 4                | ReLU                       | ReLU                 |
| 5                | Ortalama Havuzlama         | Ortalama Havuzlama   |
| 6                | Evrişim                    | Konvolusyon          |
| 7                | Yığın Normalizasyonu       | Yığın Normalizasyonu |
| 8                | ReLU                       | ReLU                 |
| 9                | Ortalama Havuzlama         | Konvolusyon          |
| 10               | Evrişim                    | Yığın Normalizasyonu |
| 11               | Yığın Normalizasyonu       | ReLU                 |
| 12               | ReLU                       | Ortalama Havuzlama   |
| 13               | Evrişim                    | Konvolusyon          |
| 14               | Yığın Normalizasyonu       | Yığın Normalizasyonu |
| 15               | ReLU                       | ReLU                 |
| 16               | Bırakma                    | Konvolusyon          |
| 17               | Tamamen Bağlı              | Yığın Normalizasyonu |
| 18               | Regresyon Çıkışı           | ReLU                 |
| 19               |                            | Çıkarma              |
| 20               |                            | Tamamen Bağlı        |
| 21               |                            | Regresyon Çıkışı     |

Çizelge 6.22'de 50-350 arasında 50'şer arttırımlı çözünürlük için geliştirilen tekil görüntü girişli ESA'nın R, G, B, Gr1, Gr2 ve Gr3 görüntüleri ile BGS tahmini başarımları verilmiştir. Çizelgedeki değer tüm model için R değeridir. Benzer şekilde Çizelge 6.23'te R-G, R-B, G-B ve R-G-B görüntü için geliştirilen ESA başarımları verilmiştir. Çizelge 6.23'te tüm model için RMSE ve R değerleri verilmiştir.

**Çizelge 6.22 : Geliştirilen ESA için tekil kanal başarımı**

|            |          | Renk Kanalı (Tüm Model için R Değeri) |        |               |        |        |        |        |        |
|------------|----------|---------------------------------------|--------|---------------|--------|--------|--------|--------|--------|
|            |          | R                                     | B      | G             | Gr1    | Gr2    | Gr3    | Gr4    | H      |
| Çözünürlük | 50 x50   | 0,9674                                | 0,9701 | 0,9712        | 0,9694 | 0,9687 | 0,9723 | 0,9697 | 0,9580 |
|            | 100 x100 | 0,9694                                | 0,9653 | 0,9650        | 0,9701 | 0,9717 | 0,9696 | 0,9654 | 0,9502 |
|            | 150 x150 | 0,9645                                | 0,9690 | 0,9653        | 0,9640 | 0,9665 | 0,9685 | 0,9682 | 0,9600 |
|            | 200 x200 | 0,9427                                | 0,9432 | 0,9275        | 0,9638 | 0,9459 | 0,9514 | 0,9613 | 0,9632 |
|            | 250 x250 | 0,9655                                | 0,9695 | 0,9681        | 0,9661 | 0,9692 | 0,9658 | 0,9652 | 0,9630 |
|            | 300 x300 | 0,9701                                | 0,9725 | 0,9677        | 0,9678 | 0,9730 | 0,9689 | 0,9719 | 0,9719 |
|            | 350 x350 | 0,9718                                | 0,9701 | <b>0,9745</b> | 0,9704 | 0,9694 | 0,9704 | 0,9703 | 0,9741 |

Çizelge 6.23’de görüldüğü gibi tekil kanal kullanımında çözünürlüğün artırılması az miktarda başarımı arttırmıştır. En yüksek başarımlı model için G kanalı için bulunmuştur. En yüksek başarımlı model için  $R = 0,9745$  olarak bulunmuştur.

**Çizelge 6.23 : Geliştirilen ESA için çoklu kanal başarımı**

|            |          | Renk Kanalları |        |                |               |         |        |         |        |
|------------|----------|----------------|--------|----------------|---------------|---------|--------|---------|--------|
|            |          | R-G-B          |        | R-G            |               | R-B     |        | G-B     |        |
|            |          | RMSE           | R      | RMSE           | R             | RMSE    | R      | RMSE    | R      |
| Çözünürlük | 50 x50   | 12,2485        | 0,9723 | 11,1575        | 0,9779        | 10,9350 | 0,9789 | 10,9745 | 0,9788 |
|            | 100 x100 | 14,4151        | 0,9623 | 11,4207        | 0,9763        | 11,7435 | 0,9745 | 11,2576 | 0,9776 |
|            | 150 x150 | 14,0918        | 0,9629 | 11,6106        | 0,9760        | 12,9709 | 0,9705 | 12,6667 | 0,9700 |
|            | 200 x200 | 12,6604        | 0,9703 | 10,9011        | 0,9781        | 11,2177 | 0,9769 | 11,3081 | 0,9764 |
|            | 250 x250 | 11,9807        | 0,9734 | 10,8449        | 0,9784        | 11,5122 | 0,9761 | 11,4116 | 0,9766 |
|            | 300 x300 | 12,2029        | 0,9724 | 11,0394        | 0,9777        | 10,6920 | 0,9789 | 11,1688 | 0,9770 |
|            | 350 x350 | 12,5863        | 0,9705 | <b>10,4390</b> | <b>0,9805</b> | 10,6007 | 0,9794 | 11,4168 | 0,9766 |

Çizelge 6.23’de görüldüğü gibi çoklu kanal kullanımında en yüksek başarımlı model için 350x350 çözünürlük için R-G kanalları için bulunmuştur. En yüksek başarımlı model için  $R = 0,9805$  olarak bulunmuştur.

Tekil kanal görüntüleri kullanarak ön eğitilmiş digitsNet [113] ESA’sı kullanılarak transfer öğrenme yaklaşımı ile alev görüntüsü ve BGS tahmini yapılmıştır. DigitsNet 28x28x1 girişli, 15 katmanlı bir ESA olup eğitim işlemi yapılırken hem tüm katman ağırlıkları güncellenerek hemde 1-12 arasındaki katmanların ağırlıkları sabit tutularak eğitim işlemi yapılmıştır. Çizelge 6.24’te ilgili iki ESA için BGS tahmin sonuçları verilmiştir.

**Çizelge 6.24** : DigitsNet ESA'sı için tekil kanal başarımı

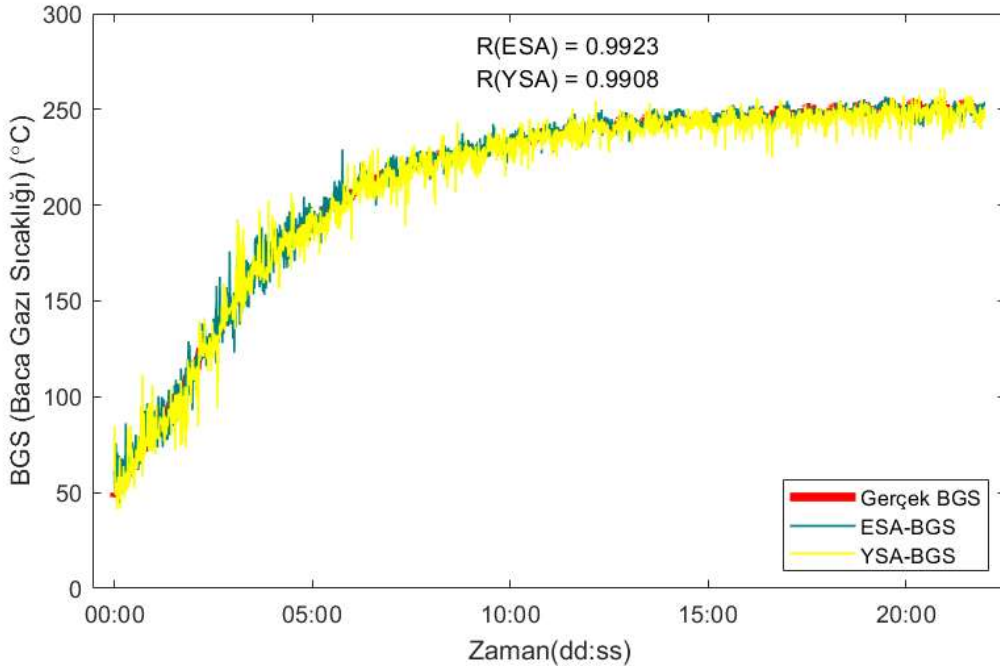
|             |            | DigitsNet      |                      |         |               | DigitsNet (1-12 Katman Sabit) |               |         |               |
|-------------|------------|----------------|----------------------|---------|---------------|-------------------------------|---------------|---------|---------------|
|             |            | Tüm Sistem     |                      | Test    |               | Tüm Sistem                    |               | Test    |               |
|             |            | RMSE           | <i>R</i>             | RMSE    | <i>R</i>      | RMSE                          | <i>R</i>      | RMSE    | <i>R</i>      |
| Renk Kanalı | <b>R</b>   | 13,9650        | <i>0,9637</i>        | 14,6895 | <i>0,9566</i> | 18,8607                       | <i>0,9329</i> | 21,1059 | <i>0,9077</i> |
|             | <b>B</b>   | 13,7868        | <i>0,9649</i>        | 14,2845 | <i>0,9626</i> | 19,0823                       | <i>0,9316</i> | 21,4879 | <i>0,9006</i> |
|             | <b>G</b>   | 13,9444        | <i>0,9641</i>        | 14,7494 | <i>0,9627</i> | 20,3660                       | <i>0,9217</i> | 23,3952 | <i>0,8945</i> |
|             | <b>Gr1</b> | 13,7067        | <i>0,9652</i>        | 13,7467 | <i>0,9643</i> | 19,3422                       | <i>0,9292</i> | 21,9426 | <i>0,9170</i> |
|             | <b>Gr2</b> | 13,4135        | <i>0,9664</i>        | 13,5234 | <i>0,9676</i> | 19,7002                       | <i>0,9263</i> | 22,7878 | <i>0,9067</i> |
|             | <b>Gr3</b> | 13,9356        | <i>0,9641</i>        | 14,3756 | <i>0,9613</i> | 19,3399                       | <i>0,9293</i> | 22,0794 | <i>0,9092</i> |
|             | <b>Gr4</b> | <b>12,9078</b> | <b><i>0,9691</i></b> | 12,7091 | <i>0,9686</i> | 19,1713                       | <i>0,9305</i> | 21,7651 | <i>0,9085</i> |
|             | <b>H</b>   | 16,4182        | <i>0,9495</i>        | 17,3452 | <i>0,9417</i> | 23,3009                       | <i>0,8951</i> | 26,3762 | <i>0,8597</i> |

Çizelge 6.24'te görüldüğü gibi katman ağırlıklarının sabit tutulması model başarımını düşürmüştür. En yüksek başarımlar Gr4 renk kanalı için  $R = 0,9691$  olarak bulunmuş fakat bütün renk kanalları için hemen hemen aynı sonuç bulunmuştur. Bu durum ESA girişinin çok küçük çözünürlükte olmasından olabilir.

Çizelge 6.25'te RGB renk kanalları ile ön eğitilmiş ağırlıklar kullanılarak gerçekleştirilen deneysel çalışma sonucu verilmiştir. Googlenet ve Alexnet için öznelik çıkarılan katman ağırlıkları sabit tutularak ayrıca sonuç verilmiştir. Googlenet'in iki farklı veri seti ile eğitilmiş versiyonu bulunmaktadır. Her ikisi için sonuçlar ayrı ayrı verilmiştir. Çizelge 6.25'te görüldüğü gibi katman ağırlıklarının sabit tutulduğu tüm modelleri için katman ağırlıklarının sabit tutulması model başarımını düşürmüştür. Resnet18 ESA'sı en yüksek başarımların elde edildiği modeldir. İlgili model için  $R = 0,9923$  olarak bulunmuştur. Resnet18 ESA'sı ve spektral norm ile eğitilen YSA modelleri için tahmin edilen BGS ve BGA ile ölçülen BGS değerleri grafiksel olarak Şekil 6.9'da verilmiştir.

**Çizelge 6.25** : Ön eğitilmiş ESA'lar için BGS tahmin sonuçları

| Ön Eğitilmiş ESA                       | Tüm Sistem    |               | Eğitim        |               | Test           |               |
|--|---------------|---------------|---------------|---------------|----------------|---------------|
|  | MSE           | R             | MSE           | R             | MSE            | R             |
| Googlenet ImageNet                     | 7,9643        | 0,9891        | 6,5026        | 0,9930        | 10,7618        | 0,9769        |
| Googlenet ImageNet (1-10 Katman Sabit) | 8,6140        | 0,9865        | 7,0596        | 0,9911        | 11,7098        | 0,9717        |
| Googlenet Place365                     | 7,7388        | 0,9890        | 7,1249        | 0,9908        | 8,7331         | 0,9844        |
| Googlenet Place365 (1-10 Katman Sabit) | 8,7267        | 0,9874        | 8,1284        | 0,9893        | 10,1442        | 0,9805        |
| Alexnet                                | 8,6175        | 0,9885        | 8,0541        | 0,9901        | 10,0108        | 0,9846        |
| Alexnet (1-12 Katman Sabit)            | 10,4944       | 0,9855        | 9,0845        | 0,9905        | 13,0741        | 0,9753        |
| Shufflenet                             | 9,4075        | 0,9837        | 6,8887        | 0,9913        | 13,0786        | 0,9670        |
| Resnet18                               | <b>6,9210</b> | <b>0,9923</b> | <b>4,7598</b> | <b>0,9971</b> | <b>10,1197</b> | <b>0,9794</b> |
| Resnet50                               | 7,4457        | 0,9898        | 4,1472        | 0,9970        | 11,5199        | 0,9671        |
| Resnet101                              | 6,7782        | 0,9916        | 4,3354        | 0,9967        | 10,2035        | 0,9811        |



**Şekil 6.9** : Resnet18 (ESA) ve YSA modelleri için gerçek ve tahmin edilen BGS

### 6.5.1 Sonuçlar ve değerlendirme

BGS tahmini için ön eğitilmiş ESA'lar içinde Resnet18 modeli en yüksek başarıyı vermiştir. YSA ile eğitilen model için  $R = 0,9903$ , Resnet18 modeli için  $R = 0,9923$  olarak bulunmuştur. Ön eğitilmiş tekil kanal ESA'sı ve geliştirilen tekil kanal ve çoklu kanal

ESA modelleri YSA modellerinden daha düşük başarımları vermiştir. Resnet18 ve YSA modelleri kıyaslandığında her ne kadar ESA modeli biraz daha iyi sonuç verse de ESA'ların genel problemleri bu çalışma için de geçerlidir. ESA'lar hem eğitimleri uzun olmaktadır. Modelin veri setini, aşırı öğrenmemesi için eğitim veri setinin çok büyük olması gerekmektedir. Ayrıca hesaplama maliyetleri YSA'lardan çok daha yüksek olmaktadır. Bu sebeplerden dolayı BGS tahmini için YSA modelinin ESA modelinden daha uygun olduğu söylenebilir. ESA modelleri için ayrıntılı sonuçlar Ek D. CD'sinde 7 nolu klasörün içerisinde yer almaktadır.

## 6.6 Görüntü Momentleri ile $\lambda$ Tahmini

Bu çalışmada deney 2 verileri kullanılarak yapılmıştır. BGS tahmini çalışmasında sıcaklık tahmini için RGB renkli alev görüntüsü ve R-G iki renk bileşenin yeterli olabileceği gösterilmiştir. Benzer olarak ideal yanmanın modellenmesi çalışmasında elde edilen sonuçlar değerlendirildiğinde  $\lambda$  tahmini için gri seviye görüntüsünün yetersiz olduğu, RGB veya RG kanallarının bileşenlerinin birlikte kullanılması durumunda sistem performansının olumlu etkileneceği gösterilmiştir. Bu sonuçlar değerlendirilerek bu çalışmada  $\lambda$  tahmini yapılırken renkli alev görüntüsünün R-G-B ve R-G bileşenlerinden öznelikler elde edilip bu öznelikler birleştirilmesi suretiyle YSA regresyon modeli girişleri elde edilmiştir. Bu çalışmada deney-2 verilerinin tümü kullanılmıştır. YSA regresyon modeline ilaveten zaman serisi YSA regresyon modeli için yapılan bir deney sonucu verilmiştir.

### 6.6.1 YSA regresyon modeli ile $\lambda$ tahmini

Bu deneysel çalışmada renkli alev görüntüsünün ilk iki momenti olan ortalama ve standart sapma öznelik elde etme yöntemi olarak alınıp  $\lambda$  tahmini için ideal bir YSA regresyon modeli araştırılması yapılmıştır. Diğer iki moment olan basıklık ve çarpıklık sistem performansını olumsuz etkilediği için kullanılmamıştır. Bu kapsamda alev görüntüsünün farklı çözünürlüklerinden (200x200, 400x400, 600x600, 800x800, 1000x1000 ve 1160x1160) hangisinin yeterli olduğu araştırılmıştır. Ayrıca öznelik elde etme yönteminde optimum yerel pencere sayısının (1x1, 2x2, 3x3, 4x4, 5x5, 6x6, 7x7, 8x8, 9x9, 10x10, 11x11, 12x12, 13x13, 14x14, 15x15 ve 16x16) ne olduğu ve YSA regresyon modeli için ideal öğrenme yöntemi (LM, SCG ve OSS) ile gizli katmandaki ideal nöron sayısının ne olduğu araştırılmıştır.

R-G ve R-G-B renk kanallarının her biri için optimum yerel pencere sayısı, en iyi YSA katsayılarını güncelleme yöntemi ve gizli katmandaki optimum nöron sayısı araştırması yapılırken olabilecek tüm kombinasyonlar için 2304 adet (6 (çözünürlük mertebesi)  $\times$  3 (öğrenme yöntemi)  $\times$  8 (gizli katmandaki nöron sayısı)  $\times$  16 (yerel pencere sayısı)) YSA regresyon modeli için sonuç alınmıştır. Tüm model sonuçlarını vermek yerine en iyi sonuçların alındığı parametreler sabit tutularak diğer parametreler için modelin tüm sistem performans kriterlerinden R ve MSE ile sonuçlar verilecektir. Tüm modellerin tüm sistem, eğitim, doğrulama, test ve ortalama tahmin sonuçları Ek D. CD'sinde 8 nolu klasörün içerisinde yer almaktadır. R-G ve R-G-B renk bileşenleri için LM, SCG ve OSS öğrenme yöntemleriyle oluşturulan tüm modeller değerlendirildiğinde; en iyi tüm sistem, en iyi test ve en kötü tüm sistem sonuçlarının alındığı model parametreleri ve model başarımları Çizelge 6.26'da verilmiştir.

**Çizelge 6.26 :** İlgili YSA öğrenme modeli için en kötü tüm sistem, en iyi tüm sistem ve test sonuçlarının alındığı model başarımları

|                    |         |                      |                  |              |                | Tüm Sistem Performansı |               | Test Performansı |               |
|--------------------|---------|----------------------|------------------|--------------|----------------|------------------------|---------------|------------------|---------------|
|                    | Görüntü | Yerel Pencere Sayısı | Çöz.             | Nöron Sayısı | YSA Öğr. Yönt. | MSE                    | R             | MSE              | R             |
| En İyi Tüm Sistem  | R-G-B   | <b>6x6</b>           | <b>800x800</b>   | <b>16</b>    | <b>LM</b>      | <b>0,1044</b>          | <b>0,9844</b> | <b>0,2393</b>    | <b>0,9650</b> |
|                    | R-G-B   | 10x10                | 800x800          | 14           | SCG            | 0,1207                 | 0,9818        | 0,1932           | 0,9702        |
|                    | R-G-B   | 13x13                | 400x400          | 14           | OSS            | 0,2240                 | 0,9658        | 0,2976           | 0,9533        |
|                    | R-G     | <b>6x6</b>           | <b>200x200</b>   | <b>16</b>    | <b>LM</b>      | <b>0,1275</b>          | <b>0,9809</b> | <b>0,2511</b>    | <b>0,9626</b> |
|                    | R-G     | 12x12                | 1100x1100        | 12           | SCG            | 0,1546                 | 0,9766        | 0,2548           | 0,9616        |
|                    | R-G     | 13x13                | 600x600          | 14           | OSS            | 0,2193                 | 0,9666        | 0,3074           | 0,9528        |
| En İyi Test        | R-G-B   | <b>4x4</b>           | <b>600x600</b>   | <b>16</b>    | <b>LM</b>      | <b>0,1085</b>          | <b>0,9837</b> | <b>0,1887</b>    | <b>0,9707</b> |
|                    | R-G-B   | 11x11                | 1000x1000        | 14           | SCG            | 0,1269                 | 0,9808        | 0,1973           | 0,9708        |
|                    | R-G-B   | 11x11                | 800x800          | 14           | OSS            | 0,2254                 | 0,9656        | 0,2791           | 0,9572        |
|                    | R-G     | <b>5x5</b>           | <b>200x200</b>   | <b>16</b>    | <b>LM</b>      | <b>0,1441</b>          | <b>0,9783</b> | <b>0,2450</b>    | <b>0,9648</b> |
|                    | R-G     | 11x11                | 1100x1100        | 14           | SCG            | 0,1697                 | 0,9743        | 0,2454           | 0,9631        |
|                    | R-G     | 12x12                | 1100x1100        | 16           | OSS            | 0,2264                 | 0,9655        | 0,3108           | 0,9530        |
| En Kötü Tüm Sistem | R-G-B   | 1x1                  | 200x200          | 2            | LM             | 1,2544                 | 0,7902        | 1,2925           | 0,7878        |
|                    | R-G-B   | 1x1                  | 1000x1000        | 2            | SCG            | 1,7254                 | 0,6942        | 1,7330           | 0,6943        |
|                    | R-G-B   | <b>15x15</b>         | <b>1100x1100</b> | <b>4</b>     | <b>OSS</b>     | <b>2,7576</b>          | <b>0,2007</b> | <b>2,8290</b>    | <b>0,1997</b> |
|                    | R-G     | 1x1                  | 400x400          | 2            | LM             | 1,5410                 | 0,7339        | 1,5333           | 0,7268        |
|                    | R-G     | 1x1                  | 1100x1100        | 2            | SCG            | 2,0429                 | 0,6217        | 2,0188           | 0,6182        |
|                    | R-G     | <b>13x13</b>         | <b>1000x1000</b> | <b>4</b>     | <b>OSS</b>     | <b>2,3985</b>          | <b>0,3137</b> | <b>2,4565</b>    | <b>0,3134</b> |

Çizelge 6.26'da görüldüğü gibi en iyi sonuçlar R, G ve B renk kanallarında 800x800 çözünürlük için gizli katmada 16 adet nöron kullanıldığı LM öğrenme modeli için 6x6 pencere boyutunda elde edilmiştir. En yüksek tüm model başarımları R, G ve B renk kanalları

için  $R = 0,9844$ , R ve G renk kanalları için  $R = 0,9809$  olarak bulunmuştur. En iyi test başarımı R, G ve B renk kanalları için  $R = 0,9707$ , R-G renk kanalları için  $R = 0,9648$  olarak bulunmuştur. En kötü test performans tüm modeller için OSS öğrenme yönteminde bulunmuştur. En iyi test performansında LM ve SCG öğrenme yöntemlerinin pencere boyutu dikkat çekicidir. LM yöntemi küçük pencere boyutu için iyi test sonucu verirken SCG yöntemi büyük pencere boyutunda iyi sonuç vermiştir. Bu durum sonraki bölümde ayrıntılı tartışılıp ideal pencere boyutunun belirlenmesi için değerlendirilmiştir. En iyi sonuçlar LM öğrenme modeli ve 6x6'lık yerel pencerelerde elde edildiği için bu modelin farklı çözünürlükteki ve farklı gizli katman nöron sayısı için sistem performansı Çizelge 6.27'de verilmiştir.

**Çizelge 6.27** : Farklı çözünürlük ve farklı gizli katman nöron sayısında  $\lambda$  tahmini için YSA regresyon modeli performans sonuçları

|                           |    | Çözünürlük |         |         |               |           |           |
|---------------------------|----|------------|---------|---------|---------------|-----------|-----------|
|                           |    | 200x200    | 400x400 | 600x600 | 800x800       | 1000x1000 | 1160x1160 |
|                           |    | R          | R       | R       | R             | R         | R         |
| Gizli Katman Nöron Sayısı | 2  | 0,9566     | 0,9579  | 0,9599  | 0,9539        | 0,9582    | 0,9552    |
|                           | 4  | 0,9709     | 0,9703  | 0,9665  | 0,9718        | 0,9682    | 0,9692    |
|                           | 6  | 0,9741     | 0,9773  | 0,9742  | 0,9750        | 0,9772    | 0,9781    |
|                           | 8  | 0,9783     | 0,9755  | 0,9784  | 0,9780        | 0,9752    | 0,9774    |
|                           | 10 | 0,9755     | 0,9803  | 0,9817  | 0,9794        | 0,9772    | 0,9787    |
|                           | 12 | 0,9813     | 0,9752  | 0,9781  | 0,9787        | 0,9812    | 0,9796    |
|                           | 14 | 0,9813     | 0,9772  | 0,9810  | 0,9808        | 0,9782    | 0,9810    |
|                           | 16 | 0,9807     | 0,9794  | 0,9812  | <b>0,9844</b> | 0,9832    | 0,9812    |

Çizelge 2.27'den de görüldüğü gibi çok yüksek çözünürlüğe gerek kalmadan model doğruluğu en yüksek seviyeye çıkmıştır. En yüksek başarımlar her ne kadar en büyük değer olan 16 gizli nöron modelde elde edilmiş gibi olsada 14 gizli katman için model başarımı  $R = 0,9826$  olarak bulunmuştur. Yani 0,0016 kadarlık çok küçük bir fark bulunmaktadır. Çizelge 2.28'de LM öğrenme modeli için gizli katman nöron sayısı 16 iken farklı yerel pencere boyutları ve farklı çözünürlükler için YSA regresyon modeli için başarımlar sonuçları verilmiştir.

**Çizelge 6.28** : Farklı çözünürlük ve farklı yerel pencere boyutunda  $\lambda$  tahmini için YSA regresyon modeli performans sonuçları

|                      |       | Çözünürlük |         |         |               |           |           |
|----------------------|-------|------------|---------|---------|---------------|-----------|-----------|
|                      |       | 200x200    | 400x400 | 600x600 | 800x800       | 1000x1000 | 1200x1200 |
|                      |       | R          | R       | R       | R             | R         | R         |
| Yerel Pencere Sayısı | 1x1   | 0,8926     | 0,8918  | 0,8888  | 0,8932        | 0,8922    | 0,8911    |
|                      | 2x2   | 0,9545     | 0,9566  | 0,9545  | 0,9566        | 0,9557    | 0,9544    |
|                      | 3x3   | 0,9736     | 0,9732  | 0,9774  | 0,9756        | 0,9762    | 0,9763    |
|                      | 4x4   | 0,9811     | 0,9805  | 0,9837  | 0,9778        | 0,9820    | 0,9797    |
|                      | 5x5   | 0,9806     | 0,9803  | 0,9795  | 0,9788        | 0,9810    | 0,9830    |
|                      | 6x6   | 0,9807     | 0,9794  | 0,9812  | <b>0,9844</b> | 0,9832    | 0,9812    |
|                      | 7x7   | 0,9787     | 0,9793  | 0,9814  | 0,9762        | 0,9778    | 0,9791    |
|                      | 8x8   | 0,9774     | 0,9750  | 0,9760  | 0,9740        | 0,9767    | 0,9748    |
|                      | 9x9   | 0,9784     | 0,9777  | 0,9788  | 0,9775        | 0,9818    | 0,9760    |
|                      | 10x10 | 0,9733     | 0,9768  | 0,9754  | 0,9738        | 0,9768    | 0,9693    |
|                      | 11x11 | 0,9698     | 0,9713  | 0,9723  | 0,9691        | 0,9721    | 0,9727    |
|                      | 12x12 | 0,9761     | 0,9783  | 0,9707  | 0,9731        | 0,9711    | 0,9731    |
|                      | 13x13 | 0,9781     | 0,9798  | 0,9777  | 0,9785        | 0,9811    | 0,9754    |
|                      | 14x14 | 0,9812     | 0,9781  | 0,9798  | 0,9796        | 0,9816    | 0,9796    |
|                      | 15x15 | 0,9803     | 0,9793  | 0,9821  | 0,9809        | 0,9813    | 0,9817    |
|                      | 16x16 | 0,9823     | 0,9813  | 0,9803  | 0,9832        | 0,9821    | 0,9802    |

### 6.6.2 Zaman serisi ysa ile $\lambda$ tahmini


NARX zaman serisi YSA modeli kullanarak yapılan  $\lambda$  tahmini çalışmasında hemen hemen her türlü öznelik elde etme yönteminde yüksek doğruluk bulunmuştur. Çizelge 6.29'da görüldüğü gibi  $R = 0,99$  ile alev görüntüsü ile  $\lambda$  arasında korelasyon bulunmuştur. Bu durum dikkat çekici bulunup ayrıntılı incelenmiştir. Sistem çıkışı sistem girişine dahil edildiğinden dolayı uygun  $\lambda$  tahminin de kullanılıp kullanılmayacağı araştırılmıştır. Çünkü başlangıç parametreleri önemli olmakta dahası sistem uygun başlangıç parametreleri ile başlatılsa bile kümülatif hatanın sistemi nasıl etkileyeceği önemli olmaktadır. Çizelge 6.29'da verilen NARX modeli uygunluğu incelemesinde sistem girişine verilen geçmişteki  $p$  ( $p = 2$ ) adet kadar çıkışın %100 doğru olması durumunda (BGA'nın  $\lambda$  ölçüm verisi) sistem girişine dahil edildiğinde ve geçmiş  $p$  adet çıkışın NARX modelinin tahmin ettiği  $\lambda$  değerlerinden alınması durumunda (en başta olmayan ilk  $p$  adet veri gene BGA'nın ölçtüğü veri alınacak) model başarımının nasıl değiştiği araştırılmıştır. Bu iki durum deney-2 verileri

kullanılarak test edilmiştir. Şekil 6.10'da ölçüm verileri giriş veriler (a) ve model tahmin sonuçları giriş veriler (b) gerçekleştirilen regresyon grafikleri verilmiştir.

**Çizelge 6.29** : Farklı öznelik elde etme yöntemleri için NARX model ile  $\lambda$  tahmini sonuçları


| Öznelik Elde Etme Yöntemi | Tüm Sistem Performansı (R) |
|---------------------------|----------------------------|
| $\mu, \sigma$             | 0.9999                     |
| Gr2-GLCM (8)              | 0.9999                     |
| Gr2-GLCM (8)              | 0.9926                     |
| B-GLCM (16)               | 0.9967                     |
| H-Hist                    | 0.9988                     |
| Xtop                      | 0.9989                     |

Şekil 6.10'da görüldüğü gibi ölçüm verileri giriş veriler (a)  $R = 0.9926$  ve model tahmin sonuçları giriş veriler (b)  $R = 0.9894$  olarak bulunmuştur. R değerindeki bu düşüm dikkat çekici bulunarak daha büyük veri boyutu için nasıl değiştiği araştırılmıştır. Bunun için deney 1-8 verileri için tek kamera verileri birleştirilerek yeniden test edilmiştir. Gerçekleştirilen bu test işleminin sonucunda Şekil 6.11'de ölçüm verileri giriş veriler (a) ve model tahmin sonuçları giriş veriler (b) gerçekleştirilen regresyon grafikleri verilmiştir.



**Şekil 6.10** : Deney-2 verileri için ölçüm verileri giriş veriler (a) ve model tahmin sonuçları giriş veriler (b) gerçekleştirilen NARX regresyon grafikleri

Şekil 6.11'den de görüldüğü gibi NARX modelinde sistem çıkışı, sistem girişine dahil edildiğinden dolayı sistem çıkışında çok küçük oranlarda hata olsa bile zamanla kümülatif hatanın artmasına sebep olacaktır. İlk başlarda tahmin işlemi çok başarılı olsa bile zamanla kümülatif hata artacağından dolayı sistem kararsız davranmaya başlayacaktır. Dolayısıyla NARX modeli yüksek başarıma rağmen  $\lambda$  tahmini için uygun bir regresyon modeli değildir.



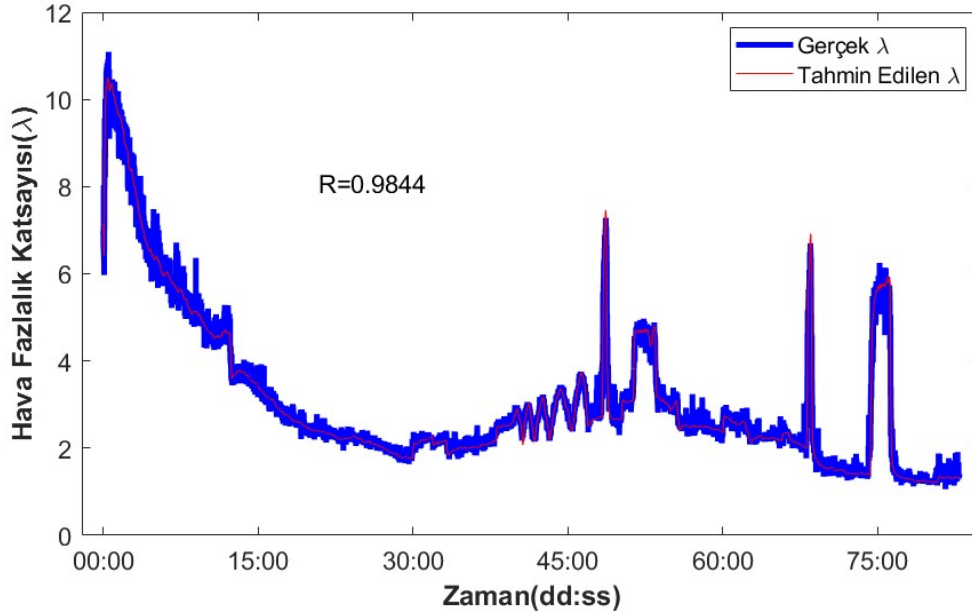
**Şekil 6.11 :** Tüm deney verileri için ölçüm verileri giriş verilerle (a) ve model tahmin sonuçları giriş verilerle (b) gerçekleştirilen NARX regresyon grafikleri

Zaman serisi YSA'nın bir diğer çeşidi olan DGÇ (doğrusal olmayan giriş-çıkış) YSA modelindeki sadece belli bir zaman önceki girişin şu anki çıkışı tahmin etmek için modele verilmesi yaklaşımına dayanmaktadır. Bu yaklaşım normal YSA modeliyle benzer sonuçlar verdiği için ayrıca ele alınmamıştır.

### 6.6.3 Sonuçlar ve değerlendirme

Bu tez çalışması son uygulaması olarak deney kazanı olan otomatik yüklemeli bir kömür kazanında tahmin edilen  $\lambda$  değerine göre fan devrinin kontrol edilerek yanma optimizasyonu gerçekleştiren bir uygulama tasarlanması hedeflenmiştir. Dolayısıyla renkli alev görüntüsünün ilk iki momentini kullanarak elde edilen öznelikler ile gerçekleştirilen YSA regresyon modelinin sonuçları tatmin edici seviyededir. Şekil 6.12'de ilgili model için tahmin edilen  $\lambda$  ve BGA'nın ölçtüğü  $\lambda$  değeri aynı grafikte gösterilmiştir. Öznelik elde etme yaklaşımları içerisinde en yüksek başarımla renkli alev görüntüsünün ilk iki momenti olan ortalama ve standart sapma kullanılarak elde edilmiştir. Bundan dolayı son bölümde anlatılacak gerçek zamanlı uygulamada öznelik yöntemi bu yöntem kullanılmıştır. En iyi model YSA mimarisini oluşturulurken izlenen yöntemin aynısı literatürde benzer çalışmalar içinde tekrarlanmıştır. Yani gizli katman nöron sayısı 2-16 arasında değiştirilerek ve üç YSA öğrenme modeli için sonuç alınarak en yüksek sonucun alındığı model başarımları verilmiştir. Geliştirilen öznelik elde etme yöntemleri ile literatürde önerilen diğer öznelik elde etme yönteminin sonuçları Çizelge 6.30'da verilmiştir. Buradaki maksat öznelik elde etme yöntemlerinin performanslarını kıyaslamaktır. YSA öğrenme modeli olarak iki model için (SCG ve LM) için ayrı sonuçlar verilecektir. Çizelgedeki sonuçlardan

da görüldüğü gibi önerilen öznitelik elde etme yönteminin yanma sürecini temsil etmekteki üstünlüğü açıktır. Yerel pencerelere bölme işlemi ve her bir renk bileşeninden ayrı ayrı öznitelikler elde etme yaklaşımı diğer yöntemlere göre üstün bir performans göstermesinin ana sebebi olarak değerlendirilmiştir. Çizelge 6.30'da verilen tüm sonuçlar modellerin on kez koşturularak ortalaması alınan değerlerdir. Literatürdeki en yakın çalışmadaki başarımlar  $R = 0,9188$  iken önerilen yöntem için  $R = 0,9844$  olmaktadır.



**Şekil 6.12** : YSA modeli için tahmin edilen  $\lambda$  ve BGA'nın ölçtüğü  $\lambda$

Görüntü momentleri ile sunulan yöntemler ile literatürde sunulan diğer yöntemler için zaman kıyaslaması Çizelge 6.31'de verilmiştir. Bunun için AMD Ryzen 5 3550H işlemcili, 16 gb bellekli donanıma sahip kişisel bilgisayar ile test işlemi yapılmıştır. Bilgisayarla her türlü iletişim kesilerek başka hiçbir uygulama çalıştırılmadan test işlemi yapılmıştır. Zaman kıyaslaması için deney-2 verilerinin hepsi kullanılmıştır. Öznitelik çıkarma için 9956 görüntünün hepsi için öznitelikler çıkarılmıştır. Öznitelikler için verilen zaman değeri tek bir görüntü için öznitelik elde etmek için harcanan süredir. Önerilen yöntemler için  $4 \times 4$ 'lük ızgaralar için verilmiştir. Önerilen yöntemler ve diğer yöntemler için görüntüler  $600 \times 600$  çözünürlüğe dönüştürülerek alınmıştır. Yeniden boyutlandırma için harcanan süre tablodaki verilere eklenmemiştir. YSA eğitimi için deney-2 görüntülerinin hepsi (9956) sadece eğitim için kullanılmıştır. LM ve SCG yöntemleri için 10 kez eğitim işlemi yapılarak ortalama değerler verilmiştir. Tahmin işlemi için eğitim modellerinin hepsi tüm verilerle tahmin işlemi yapılarak tek görüntü için ortalama tahmin süresi verilmiştir.

**Çizelge 6.30 : Önerilen öznitelik elde yönteminin mevcut yöntemlerle karşılaştırılması**

|   |   |     |                | Tüm Sitem Performansı |               | Test Performansı |        |
|---|---|-----|----------------|-----------------------|---------------|------------------|--------|
|   | Yöntem  | ÖVS | YSA Öğr. Yönt. | MSE                   | R             | MSE              | R      |
| Önerilen                                      | $\mu, \sigma$ (6x6x3)                         | 108 | LM             | 0,1044                | <b>0,9844</b> | 0,2393           | 0,9650 |
|   | $\mu, \sigma$ (4x4x3)                         | 48  | LM             | 0,1085                | 0,9837        | 0,1887           | 0,9707 |
|   | $\mu, \sigma$ (10x10x3)                       | 300 | SCG            | 0,1207                | 0,9818        | 0,1932           | 0,9702 |
| Diğerleri                                     | GLCM [9]                                      | 64  | LM             | 0,4380                | 0,9322        | 0,5107           | 0,9188 |
|   | B-Hist (64) [9]                               | 64  | LM             | 0,7078                | 0,8877        | 0,7835           | 0,8740 |
|   | B-Hist (256) [9]                              | 255 | LM             | 0,6825                | 0,8921        | 0,8060           | 0,8724 |
|   | $\mu$ (RES) [58, 111]                         | 1   | LM             | 2,6393                | 0,4584        | 2,5789           | 0,4608 |
|   | $\mu, \sigma, \gamma_s, \gamma_k$ [42]        | 4   | LM             | 0,9085                | 0,8534        | 0,9774           | 0,8398 |
|   | $\mu, \sigma$ ve F [43]                       | 3   | LM             | 1,0421                | 0,8296        | 1,0675           | 0,8262 |
|   | $\mu, \sigma, \gamma_s, \gamma_k$ ve F [42]   | 5   | LM             | 0,9073                | 0,8535        | 0,9580           | 0,8419 |
|   | $\mu, \sigma, \gamma_s, \gamma_k$ ve    [112] | 5   | LM             | 0,9007                | 0,8548        | 0,9949           | 0,8398 |
|   | GLCM [9]                                      | 64  | SCG            | 0,8504                | 0,8632        | 0,8297           | 0,8595 |
|   | B-Hist (64) [9]                               | 64  | SCG            | 1,3990                | 0,7622        | 1,4177           | 0,7602 |
|   | B-Hist (256) [9]                              | 255 | SCG            | 1,3565                | 0,7707        | 1,3621           | 0,7663 |
|   | $\mu$ (RES) [58, 111]                         | 1   | SCG            | 1,4115                | 0,7599        | 1,4565           | 0,7581 |
|   | $\mu, \sigma, \gamma_s, \gamma_k$ [42]        | 4   | SCG            | 1,8715                | 0,6629        | 1,9003           | 0,6555 |
|   | $\mu, \sigma$ ve F [43]                       | 3   | SCG            | 1,4115                | 0,7599        | 1,4565           | 0,7581 |
|   | $\mu, \sigma, \gamma_s, \gamma_k$ ve F [42]   | 5   | SCG            | 1,5212                | 0,7381        | 1,5428           | 0,7345 |
| $\mu, \sigma, \gamma_s, \gamma_k$ ve    [112] | 5   | SCG | 1,3674         | 0,7690                | 1,3498        | 0,7773           |        |

Çizelge 6.31’de görüldüğü gibi önerilen öznitelik elde etme yönteminin hesaplama maliyeti yüksek değildir. Literatürde bildirilen en iyi yöntem olan GLCM yönteminden daha kısa sürede öznitelik çıkarılmaktadır. Aynı şekilde YSA tahmin modelinin sonuç üretme süresi açısından da literatürdeki en iyi iki yöntemden daha kısa sürede tahmin işlemi yapılmıştır. Diğer yöntemlerin sistem gerçekleşme performansları çok düşüktür. Bunun temel sebebi parametre sayısının azlığıdır. Bu her ne kadar sistemin gerçekleşme zamanına olumlu etki yapsada sistem performansı düşüktür.

**Çizelge 6.31 : Sunulan yöntemler ve diğer yöntemler için zaman (sn) kıyaslaması**

|           | Yöntem   | Öznitelik Çıkarma | YSA Eğitim   |                |            | Tahmin     |
|-----------|--|-------------------|--------------|----------------|------------|------------|
|           |  |                   | LM           | SCG            | OSS        |            |
| Önerilen  | $\mu, \sigma$ (R-G-B)                            | 0,00622191        | 13,56171290  | 0,4844703<br>1 | 1,11205570 | 0,02918261 |
|           | $\mu, \sigma$ (R-G)                              | 0,00381593        | 5,67081398   | 0,3435599<br>9 | 0,79020591 | 0,02274770 |
| Diğerleri | GLCM   | 0,36460816        | 9,60034891   | 0,3438752<br>3 | 0,95427815 | 0,02203943 |
|           | B-Hist   | 0,00057961        | 152,84934588 | 1,3126225<br>8 | 2,30222008 | 0,07653221 |
|           | $\mu$ (RES)<br>[58, 111]                         | 0,00000014        | 0,07546576   | 0,0559851<br>1 | 0,19020431 | 0,01003966 |
|           | $\mu, \sigma, \gamma_s, \gamma_k$ [42]           | 0,00000193        | 0,24381007   | 0,1829528<br>6 | 0,62791227 | 0,01042496 |
|           | $\mu, \sigma$ ve F [43]                          | 0,00000040        | 0,14266761   | 0,1944216<br>7 | 0,38133825 | 0,01147738 |
|           | $\mu, \sigma, \gamma_s, \gamma_k$ ve F<br>[42]   | 0,00000209        | 0,37684776   | 0,2238204<br>6 | 0,37442745 | 0,01135567 |
|           | $\mu, \sigma, \gamma_s, \gamma_k$<br>ve    [112] | 0,00000299        | 0,43534186   | 0,1579613<br>6 | 0,35415223 | 0,01135612 |

### 6.7 Evrişimsel Sinir Ağları ile $\lambda$ Tahmini

Bu deneysel çalışma görüntü momentleri ile BGS'nin tahmin edilmesi deneyindeki veri seti için gri görüntü, RGB renkli görüntüsü, RGB renkli görüntüsünün ikili bileşenleri ile hem ön eğitilmiş ESA'lar hemde yeni oluşturulan ESA'lar ile  $\lambda$  tahmini yapılmıştır. Tüm deneylerde veri setinin %70'i eğitim, %15'i doğrulama ve %15'i test işlemi için kullanılmıştır. Tekil kanal görüntüsü, renkli RGB görüntüsü ile RGB görüntüsünün ikili bileşenleri için geliştirilen ESA'nın katmanları daha önce BGS tahmini için Çizelge 6.21'de verilen modellerle aynıdır.

Çizelge 6.32'de 50-350 arasında 50'şer arttırımlı çözünürlük için geliştirilen tekil görüntü girişli ESA'nın R, G, B, Gr1, Gr2 ve Gr3 görüntüleri ile  $\lambda$  tahmini başarımları verilmiştir. Çizelgedeki başarımların değeri tüm model için R korelasyon katsayısıdır. Benzer şekilde Çizelge 6.33'te R-G, R-B, G-B ve R-G-B görüntü için geliştirilen ESA başarımları verilmiştir. Çizelge 6.33'te tüm model için MSE ve R değerleri verilmiştir.

**Çizelge 6.32 :** Geliştirilen ESA için tekil kanal başarımı

|            |         | Renk Kanalı (Tüm Model için R Değeri) |        |        |               |        |        |        |        |
|------------|---------|---------------------------------------|--------|--------|---------------|--------|--------|--------|--------|
|            |         | R                                     | B      | G      | Gr1           | Gr2    | Gr3    | Gr4    | H      |
| Çözünürlük | 50x50   | 0,9610                                | 0,9642 | 0,9649 | <b>0,9694</b> | 0,9668 | 0,9626 | 0,9674 | 0,9490 |
|            | 100x100 | 0,8693                                | 0,8934 | 0,8750 | 0,8943        | 0,8810 | 0,8749 | 0,8953 | 0,8410 |
|            | 150x150 | 0,8858                                | 0,9003 | 0,8916 | 0,9094        | 0,9015 | 0,8941 | 0,9032 | 0,8676 |
|            | 200x200 | 0,9099                                | 0,9176 | 0,9104 | 0,9190        | 0,9165 | 0,9132 | 0,9227 | 0,8951 |
|            | 250x250 | 0,9204                                | 0,9251 | 0,9238 | 0,9310        | 0,9265 | 0,9246 | 0,9318 | 0,9052 |
|            | 300x300 | 0,9359                                | 0,9345 | 0,9359 | 0,9418        | 0,9391 | 0,9377 | 0,9430 | 0,9228 |
|            | 350x350 | 0,9408                                | 0,9397 | 0,9440 | 0,9497        | 0,9437 | 0,9438 | 0,9501 | 0,9219 |

Çizelge 6.33'te görüldüğü gibi tekil kanal kullanımında çözünürlüğün arttırılması başarımı düşürmüştür. En yüksek başarımlı model için R = 0,9694 olarak bulunmuştur.

**Çizelge 6.33 :** Geliştirilen ESA için çoklu kanal başarımı

|            |          | Renk Kanalları |               |        |        |        |        |        |        |
|------------|----------|----------------|---------------|--------|--------|--------|--------|--------|--------|
|            |          | R-G-B          |               | R-G    |        | R-B    |        | G-B    |        |
|            |          | MSE            | R             | MSE    | R      | MSE    | R      | MSE    | R      |
| Çözünürlük | 50 x50   | 0,2269         | 0,9662        | 0,2331 | 0,9648 | 0,2151 | 0,9676 | 0,2081 | 0,9687 |
|            | 100 x100 | 0,2798         | 0,9579        | 0,3158 | 0,9518 | 0,2785 | 0,9577 | 0,2848 | 0,9566 |
|            | 150 x150 | 0,2456         | 0,9632        | 0,2563 | 0,9611 | 0,2415 | 0,9638 | 0,2365 | 0,9644 |
|            | 200 x200 | <b>0,2004</b>  | <b>0,9704</b> | 0,2295 | 0,9658 | 0,2094 | 0,9685 | 0,2187 | 0,9671 |
|            | 250 x250 | 0,2125         | 0,9679        | 0,2329 | 0,9662 | 0,2188 | 0,9675 | 0,2026 | 0,9699 |
|            | 300 x300 | 0,2121         | 0,9691        | 0,3982 | 0,9385 | 0,2030 | 0,9702 | 0,5840 | 0,9055 |
|            | 350 x350 | 2,2540         | 0,6469        | 3,5323 | 0,2948 | 0,2537 | 0,9631 | 1,8498 | 0,7048 |

Çizelge 6.33'de görüldüğü gibi çoklu kanal kullanımında en yüksek başarımlı model için R = 0,9704 olarak bulunmuştur. İkili bileşenlerden R-B kanalları için benzer olarak 300x300 çözünürlük için R = 0,9702 olarak bulunmuştur.

Tekil kanal görüntüleri kullanarak ön eğitilmiş digitsNet ESA'sını kullanarak transfer öğrenme yaklaşımıyla alev görüntüsü-λ tahmini yapılmıştır. DigitsNet'le eğitim işlemi yapılırken hem tüm katman ağırlıkları güncellenerek hemde 1-12 arasındaki katmanların

ağırlıkları sabit tutularak eğitim işlemi yapılmıştır. Çizelge 6.34'te ilgili iki ESA için  $\lambda$  tahmin sonuçları verilmiştir.

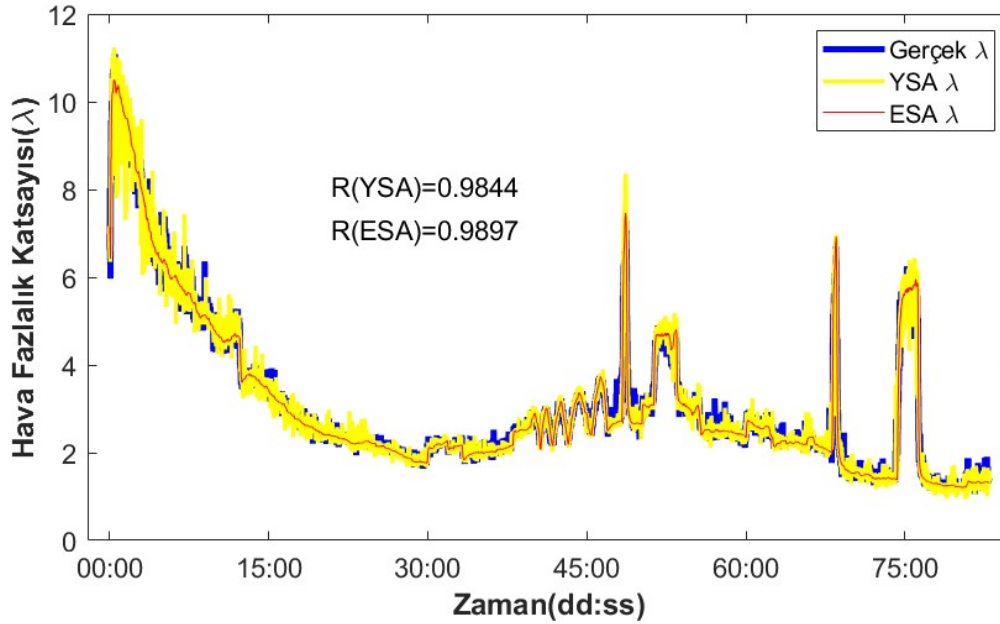
**Çizelge 6.34 : DigitsNet ESA'sı için tekil kanal başarımı**

|             |     | DigitsNet     |               |        |        | DigitsNet (1-12 Katman Sabit) |        |        |        |
|-------------|-----|---------------|---------------|--------|--------|-------------------------------|--------|--------|--------|
|             |     | Tüm Sistem    |               | Test   |        | Tüm Sistem                    |        | Test   |        |
|             |     | MSE           | R             | MSE    | R      | MSE                           | R      | MSE    | R      |
| Renk Kanalı | R   | 0,2077        | 0,9685        | 0,3053 | 0,9519 | 0,5115                        | 0,9205 | 0,6496 | 0,8901 |
|             | B   | 0,2281        | 0,9655        | 0,2807 | 0,9578 | 0,4281                        | 0,9340 | 0,5220 | 0,9195 |
|             | G   | 0,2191        | 0,9670        | 0,3232 | 0,9520 | 0,4620                        | 0,9291 | 0,5822 | 0,9094 |
|             | Gr1 | <b>0,1837</b> | <b>0,9734</b> | 0,2608 | 0,9612 | 0,3918                        | 0,9404 | 0,4844 | 0,9293 |
|             | Gr2 | 0,2070        | 0,9703        | 0,2832 | 0,9594 | 0,4290                        | 0,9338 | 0,5091 | 0,9130 |
|             | Gr3 | 0,2098        | 0,9681        | 0,3155 | 0,9498 | 0,4582                        | 0,9292 | 0,5920 | 0,9024 |
|             | Gr4 | 0,1943        | 0,9708        | 0,2626 | 0,9617 | 0,3682                        | 0,9439 | 0,4119 | 0,9306 |
|             | H   | 0,2766        | 0,9582        | 0,4035 | 0,9397 | 0,8162                        | 0,8697 | 1,0018 | 0,8355 |

Çizelge 6.34'te görüldüğü gibi BGS tahmininde olduğu gibi  $\lambda$  tahmininde de katman ağırlıklarının sabit tutulması model başarımını düşürmüştür. En yüksek başarımlı Gr1 renk kanalı için  $R = 0,9734$  olarak bulunmuştur. Çizelge 6.35'de R-G-B renk kanalları ile ön eğitilmiş ağlar kullanılarak gerçekleştirilen deneysel çalışma sonucu verilmiştir. Googlenet ve Alexnet için katman ağırlıkları sabit tutularak ayrıca sonuç verilmiştir. Googlenet'in iki farklı veri seti ile eğitilmiş versiyonu için ayrı ayrı sonuçlar verilmiştir. Çizelge 6.35'te görüldüğü gibi katman ağırlıklarının sabit tutulduğu tüm modelleri için model başarımı düşmüştür. Bu durum ilgili mimarilerin sınıflandırma problemi için tasarlanmış olmasından kaynaklanabilir. Esasında googlenet'in Place365 ile eğitilmiş ESA'sının yüksek doğruluk vermesi beklenirken daha düşük doğruluk vermiştir. Resnet101 ESA'sı en yüksek başarımın elde edildiği modeldir. İlgili model için  $R = 0,9897$  olarak bulunmuştur. Resnet101 ESA'sı ve görüntü momentleri ile oluşturulan YSA için tahmin edilen  $\lambda$  ve BGA ile ölçülen gerçek  $\lambda$  değerleri grafiksel olarak Şekil 6.13'te verilmiştir.

Çizelge 6.35 : Ön eğitilmiş ESA'lar için  $\lambda$  tahmini sonuçları

| Ön Eğitilmiş ESA                       | Tüm Sistem    |               | Eğitim |        | Test   |        |
|--|---------------|---------------|--------|--------|--------|--------|
|  | MSE           | $R$           | MSE    | $R$    | MSE    | $R$    |
| Googlenet ImageNet                     | 0,1213        | 0,9823        | 0,0904 | 0,9869 | 0,1881 | 0,9719 |
| Googlenet-ImageNet (1-10 Katman Sabit) | 0,0921        | 0,9863        | 0,0497 | 0,9927 | 0,1900 | 0,9716 |
| Googlenet Place365                     | 0,1881        | 0,9718        | 0,1571 | 0,9766 | 0,2670 | 0,9618 |
| Googlenet-Place365 (1-10 Katman Sabit) | 0,2077        | 0,9689        | 0,1818 | 0,9730 | 0,2743 | 0,9606 |
| Alexnet                                | 0,4843        | 0,9865        | 0,4216 | 0,9937 | 0,5895 | 0,9742 |
| Alexnet (1-12 Katman Sabit)            | 1,0743        | 0,9829        | 0,9872 | 0,9923 | 1,2146 | 0,9662 |
| Shufflenet                             | 0,3214        | 0,9524        | 0,1512 | 0,9781 | 0,6928 | 0,8893 |
| Resnet18                               | 0,1129        | 0,9845        | 0,0311 | 0,9968 | 0,3026 | 0,9595 |
| Resnet50                               | 0,0890        | 0,9871        | 0,0325 | 0,9960 | 0,1978 | 0,9685 |
| Resnet101                              | <b>0,0723</b> | <b>0,9897</b> | 0,0317 | 0,9964 | 0,1649 | 0,9781 |



Şekil 6.13 : Resnet101 modeli ve YSA için tahmin edilen ve gerçek  $\lambda$

### 6.7.1 Sonuçlar ve değerlendirme

$\lambda$  tahmini için ön eğitilmiş ESA'lar içinde Resnet101 modeli en yüksek başarıyı vermiştir. YSA ile eğitilen model için  $R = 0,9844$ , Resnet101 modeli için  $R = 0,9997$  olarak bulunmuştur. Googlenet ESA'sının test sonuçları ilginçtir. Çünkü parametre sayısı Resnet101 ESA'sından 6,37 kat daha küçük olmasına rağmen tüm sistem test doğruluğu  $R = 0,9719$  olarak bulunmuştur. Resnet ESA'sında tüm sistem test doğruluğu  $R = 0,9781$  olarak bulunmuştur. Son uygulamada bu yüzden Googlenet ESA'sının kullanılmasına karar

verilmiştir. Çünkü hesaplama maliyeti Resnet101'e göre çok daha düşük olmasına rağmen yakın doğrulukta sistem gerçekleşmiştir. ESA modellerinin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 9 nolu klasörün içerisinde yer almaktadır. YSA ve ESA modeli  $\lambda$  tahmini için kıyaslandığında her ne kadar ESA modeli biraz daha iyi sonuç versede ESA'ların genel problemleri bu çalışma için de geçerlidir. ESA'lar hem eğitimleri uzun olmakta, hemde modelin veri setini aşırı öğrenmemesi için veri setinin çok büyük olması gerekmektedir. Ayrıca hesaplama maliyetleri YSA'lardan çok daha yüksektir. Çoğu problem için eğitim aşamasında pahalı donanımlara sahip cihazlar gerektirmektedir. Bu sebeplerden dolayı BGS tahmini için YSA modelinin ESA modelinden daha uygun olduğu söylenebilir.

## 6.8 Endüstriyel Kamera ve Web Kamerası Kıyaslaması

Bu deney çalışması kapsamında deney 8-a kapsamında elde edilen veriler kullanılmıştır. Yanma işlemi kazanın sol tarafından normal web kamerası ile arka tarafı ise endüstriyel basler kamera ile aynı anda görüntülenmiştir. Basler kamera ile 1624x1234 çözünürlükte, web kamerası ile 640x480 çözünürlükte görüntü alınmıştır. Web kamerası için geliştirilen yazılım vasıtasıyla görüntü alınmıştır. Basler kamera için üreticinin sağladığı program vasıtasıyla görüntü alınmıştır. Referans veriler, tüm deneylerde olduğu gibi BGA cihazıyla alınmıştır. BGA cihazı verileri üreticinin sağladığı program vasıtasıyla alınmıştır. Bu üç veri matlab ortamında geliştirilen program yardımıyla senkronize edilmiştir

Öznitelik çıkarılırken temel olarak şu adımlar izlenmiştir; ROI'nin seçilmesi, görüntünün dairesel maske ile maskelenmesi, istenilen çözünürlüğü yeniden boyutlandırılması, yatay ve dikeyde ızgaralara bölme ve ilgili ızgara için öznitelik çıkarılmasıdır. Şekil 6.14'te endüstriyel ve web kameraları için (a-d) dikdörtgen ROI seçimi, (b-e) dairesel maske ve (c-f) dairesel ROI seçme işlemi için maskeleme işlemi verilmiştir. Web kamerası için dikdörtgen ROI 550x480 ve endüstriyel kamera için 1160x1012 olarak alınmıştır. Çizelge 6.36'da endüstriyel ve web kameraları için çözünürlük seviyeleri verilmiştir. Bu deney ile iki şey test edilmiştir. Birincisi aynı çözünürlükte (Çizelge 6.36 web kamera çözünürlükleri) her iki kamera tipi için benzer alev görüntüsü formunda, iki web kamerası için başarımın araştırılmasıdır. İkincisi çözünürlükten bağımsız yani endüstriyel kamera için yüksek seviye çözünürlük dahil (Çizelge 6.36 endüstriyel kamera çözünürlükleri) iki kamera için başarımın nasıl değiştiğinin araştırılmasıdır. Öznitelik çıkarma yöntemi olarak ızgaraların ortalama ve standart sapması kullanılmıştır.


Görüntü momentleri çalışmasında R-G-B ve R-G görüntü kanalları ile SCG ve LM YSA öğrenme yöntemleri için yakın sonuçlar elde edildiğinden bu çalışmada ilgili renk kanalları ve öğrenme yöntemlerinin hepsi için sonuç alınmıştır.

**Çizelge 6.36 :** Endüstriyel ve web kamera için çözünürlük seviyeleri

|             | <b>Çözünürlük</b> |         |         |         |          |           |
|-------------|-------------------|---------|---------|---------|----------|-----------|
| <b>End.</b> | 92x80             | 183x160 | 275x240 | 367x320 | 458x400  | 550x480   |
|             | 677x590           | 773x675 | 870x759 | 967x843 | 1063x928 | 1160x1012 |
| <b>Web</b>  | 92x80             | 183x160 | 275x240 | 367x320 | 458x400  | 550x480   |

Dairesel maske işleminde alev görüntüsü daire içinde kalacak şekilde daire çapı belirlenmiştir. Alev görüntüsü olmayan kısımlar dairenin dışı sıfır (0), dairenin içi bir (1) olacak şekilde alev görüntüsü ile çarpıldığında alev görüntüsü olmayan bileşenler maskelenmiş (sıfıra çekilmiş) olmaktadır. Şekil 6.14 (c ve f)'de filtrenin daha iyi görünmesi için alev dışı bileşenler beyaz (255, 255, 255) olarak gösterilmiştir. Bu değer uygulamada siyah (0, 0, 0) olmaktadır. Dairesel maskenin etkisinin görünmesi için öznitelik çıkarılırken hem dikdörtgensel ROI'nin içi olduğu gibi hemde maskelenmiş görüntü için ayrı ayrı sonuçlar alınmıştır. Bu işlem her iki kamera için tekrarlanmıştır. Izgara işlemi yapılırken 1-16 arasında yatayda ve düşeyde eşit sayıda ızgaraya bölünerek 16 adet farklı ızgara için öznitelik elde edilmiştir. Bu işlem bütün çözünürlükler için yapılmıştır.

En uygun YSA regresyon modeli araştırılırken 2-16 arasındaki 8 adet çift sayıdaki gizli nöron sayısı alınmıştır. SCG ve LM YSA öğrenme modelleri için en uygun model araştırması yapılmıştır. SCG ve LM modelleri 3 kez koşturularak ortalaması alınmıştır. LM modelleri için görüntü momentleri için yapılan çalışmadaki sonuçlar değerlendirilerek ızgara sayısı için uygun parametre araştırması aralığı SCG öğrenme modeline göre daha sınırlı tutulmuştur. SCG öğrenme modelinde 1-16 arasındaki ızgaralar, LM öğrenme modelinde 1-10 arasındaki ızgaralar için uygun model araştırması yapılmıştır.



**Şekil 6.14 :** Kameralar için (a-d) dikdörtgenel ROI seçimi, (b-e) dairesel maske ve (c-f) ROI'nin maskeyle filtrelenip görüntünün ayrıştırılması

Her iki kamera türü için dikdörtgenel ROI ve dikdörtgenel ROI'nin dairesel maske ile maskelendiği görüntüler için ayrı ayrı sonuçlar alınmıştır. Bu işlem endüstriyel kameranın çevresindeki alev olmayan bileşenlerin siyah olmamasının sistemi nasıl etkilediğini araştırılmak için yapılmıştır. Web kamerasında alev dışı bölgeler siyah olmakta endüstriyel kamera için olmamaktadır. Bu durumun sistem doğruluğunu nasıl etkilediği görmek için her iki yöntemle sonuç alınmıştır. Ayrıca bu iki yöntemin sonuçları değerlendirilerek gerçek zamanlı uygulamada kullanılacak olan en ideal ROI seçme yöntemi hakkında fikir sahibi olunacaktır. Çizelge 6.37'de endüstriyel kamera ile web kamerası için dikdörtgenel ROI seçiminde R-G-B/R-G kanalları, LM/SCG YSA öğrenme modellerinin en iyi tüm sistem ve en iyi test sonuçlarının alındığı modeller için model başarımları verilmiştir. Çizelge 6.37'den de görüldüğü gibi en iyi test ve tüm sistem sonuçları R, G ve B kanallarının birlikte kullanılmasında elde edilmiştir. LM yöntemi SCG öğrenme yöntemine göre daha iyi sonuç vermiştir. Endüstriyel kamera  $R = 0,9806$  doğrulukla  $\lambda$  tahmin etmiştir. Web kamerasından alınan görüntülerde ise  $R = 0,9946$  olarak bulunmuştur. Her iki yöntem için  $9 \times 9$  yerel pencere için bu sonuçlar elde edilmiştir. Endüstriyel kameranın kısmen daha düşük sonuç vermesi görüntü alınan pencerenin islenmesinden kaynaklandığı olarak yorumlanmıştır. Çünkü endüstriyel kamera kazanın arkasında yani baca tarafında bulunmaktadır. Her iki yöntemde de en iyi test performansı daha düşük yerel pencere boyutu için elde edilmiştir.

Endüstriyel için 3x3 ve web kamerası için 6x6 yerel pencere boyutlarında sistem en iyi test performansı göstermiştir. Bu sonuç gerçek zamanlı sistemde LM yöntemi ve daha düşük boyutlu yerel pencere kullanılması sonucunu desteklemektedir.

**Çizelge 6.37** : Diktörtgensel ROI’de endüstriyel ve web kameraları için en iyi tüm sistem ve en iyi test modellerinin sonuçları

|                           |                |                      |           |              |                | Tüm Sistem Performansı |               | Test Performansı |          |
|---------------------------|----------------|----------------------|-----------|--------------|----------------|------------------------|---------------|------------------|----------|
|                           | Görüntü Kanalı | Yerel Pencere Sayısı | Çöz.      | Nöron Sayısı | YSA Öğr. Yönt. | MSE                    | <i>R</i>      | MSE              | <i>R</i> |
| Tüm Sistem Endüstriyel K. | R-G-B          | 9x9                  | 1063x928  | 4            | LM             | 0,0061                 | <b>0,9806</b> | 0,0140           | 0,9547   |
|                           | R-G-B          | 15x15                | 550x480   | 14           | SCG            | 0,0122                 | 0,9600        | 0,0178           | 0,9428   |
|                           | R-G            | 9x9                  | 1160x1012 | 6            | LM             | 0,0092                 | 0,9711        | 0,0207           | 0,9380   |
|                           | R-G            | 16x16                | 275x240   | 8            | SCG            | 0,0261                 | 0,9118        | 0,0339           | 0,8850   |
| Tüm Sistem Web K.         | R-G-B          | 9x9                  | 550x480   | 6            | LM             | 0,0017                 | <b>0,9946</b> | 0,0037           | 0,9879   |
|                           | R-G-B          | 14x14                | 550x480   | 6            | SCG            | 0,0039                 | 0,9874        | 0,0050           | 0,9837   |
|                           | R-G            | 7x7                  | 275x240   | 10           | LM             | 0,0018                 | 0,9942        | 0,0038           | 0,9882   |
|                           | R-G            | 13x13                | 458x400   | 16           | SCG            | 0,0040                 | 0,9871        | 0,0049           | 0,9842   |
| Test Endüstriyel K.       | R-G-B          | 3x3                  | 550x480   | 14           | LM             | 0,0082                 | <b>0,9732</b> | 0,0112           | 0,9652   |
|                           | R-G-B          | 15x15                | 550x480   | 14           | SCG            | 0,0122                 | 0,9600        | 0,0178           | 0,9428   |
|                           | R-G            | 8x8                  | 550x480   | 2            | LM             | 0,0134                 | 0,9566        | 0,0179           | 0,9431   |
|                           | R-G            | 16x16                | 275x240   | 8            | SCG            | 0,0261                 | 0,9118        | 0,0339           | 0,8850   |
| Test Web K.               | R-G-B          | 6x6                  | 367x320   | 4            | LM             | 0,0021                 | <b>0,9934</b> | 0,0029           | 0,9905   |
|                           | R-G-B          | 15x15                | 92x80     | 8            | SCG            | 0,0042                 | 0,9865        | 0,0049           | 0,9841   |
|                           | R-G            | 6x6                  | 275x240   | 10           | LM             | 0,0025                 | 0,9923        | 0,0032           | 0,9896   |
|                           | R-G            | 13x13                | 92x80     | 4            | SCG            | 0,0040                 | 0,9869        | 0,0046           | 0,9856   |

Çizelge 6.38’de endüstriyel kamera ile web kamerası için diktörtgensel ROI bölgesinin dairesel maske ile maskelendiği ROI için R-G-B/R-G kanalları, LM/SCG YSA öğrenme modellerinin en iyi tüm sistem ve en iyi test sonuçlarının alındığı modeller için model başarımları verilmiştir. Çizelge 6.38’den de görüldüğü gibi her iki kamera türü için en iyi tüm sistem sonuçları R, G ve B kanallarının birlikte kullanılmasında elde edilmiştir. Sadece web kamerası için en iyi test sonucu R ve G kanalları için bulunmuştur. Fakat R, G ve B kanalları başarımları R ve G kanallarına çok yakındır. LM yöntemi SCG öğrenme yöntemine göre daha iyi sonuç vermiştir. Endüstriyel kamera  $R = 0,9682$  doğrulukla  $\lambda$  tahmin etmiştir. Web kamerasından alınan görüntülerde ise  $R = 0,9947$  olarak bulunmuştur. Endüstriyel için ve web kamerası için 7x7 yerel pencere boyutlarında sistem

en iyi test performansı göstermiştir. Bu sonuç gerçek zamanlı sistemde LM yöntemi ve daha düşük boyutlu yerel pencere kullanılması sonucunu desteklemektedir.

**Çizelge 6.38 :** Dairesel maskelenmiş ROI’de endüstriyel ve web kameraları için en iyi tüm sistem ve en iyi test modellerinin sonuçları

|                           |                |                      |          |              |                | Tüm Sistem Performansı |               | Test Performansı |          |
|---------------------------|----------------|----------------------|----------|--------------|----------------|------------------------|---------------|------------------|----------|
|                           | Görüntü Kanalı | Yerel Pencere Sayısı | Çöz.     | Nöron Sayısı | YSA Öğr. Yönt. | MSE                    | <i>R</i>      | MSE              | <i>R</i> |
| Tüm Sistem Endüstriyel K. | R-G-B          | 3x3                  | 967x843  | 10           | LM             | 0,0097                 | <b>0,9682</b> | 0,0158           | 0,9462   |
|                           | R-G-B          | 8x8                  | 550x480  | 16           | SCG            | 0,0212                 | 0,9291        | 0,0268           | 0,9124   |
|                           | R-G            | 5x5                  | 773x675  | 8            | LM             | 0,0183                 | 0,9390        | 0,0283           | 0,9071   |
|                           | R-G            | 14x14                | 550x480  | 10           | SCG            | 0,0339                 | 0,8843        | 0,0427           | 0,8487   |
| Tüm Sistem Web K.         | R-G-B          | 10x10                | 458x400  | 4            | LM             | 0,0017                 | <b>0,9947</b> | 0,0034           | 0,9888   |
|                           | R-G-B          | 14x14                | 92x80    | 4            | SCG            | 0,0042                 | 0,9865        | 0,0049           | 0,9837   |
|                           | R-G            | 7x7                  | 458x400  | 6            | LM             | 0,0019                 | 0,9939        | 0,0044           | 0,9857   |
|                           | R-G            | 14x14                | 275x240  | 12           | SCG            | 0,0039                 | 0,9872        | 0,0042           | 0,9859   |
| Test Endüstriyel K.       | R-G-B          | 3x3                  | 1063x928 | 6            | LM             | 0,0101                 | <b>0,9667</b> | 0,0140           | 0,9552   |
|                           | R-G-B          | 11x11                | 1068x928 | 16           | SCG            | 0,0214                 | 0,9282        | 0,0244           | 0,9160   |
|                           | R-G            | 4x4                  | 870x759  | 6            | LM             | 0,0212                 | 0,9293        | 0,0273           | 0,9125   |
|                           | R-G            | 7x7                  | 275x240  | 14           | SCG            | 0,0372                 | 0,8715        | 0,0407           | 0,8594   |
| Test Web K.               | R-G-B          | 7x7                  | 92x80    | 4            | LM             | 0,0026                 | <b>0,9928</b> | 0,0035           | 0,9908   |
|                           | R-G-B          | 14x14                | 458x400  | 4            | SCG            | 0,0044                 | 0,9856        | 0,0046           | 0,9847   |
|                           | R-G            | 7x7                  | 183x160  | 6            | LM             | 0,0021                 | <b>0,9932</b> | 0,0032           | 0,9897   |
|                           | R-G            | 14x14                | 275x240  | 12           | SCG            | 0,0039                 | 0,9872        | 0,0042           | 0,9859   |

Çizelge 6.37 ve Çizelge 6.38 birlikte değerlendirildiğinde dairesel makeleme işleminin aynı deney düzeneği için sistem başarımına bir etkisi olmadığı söylenebilir. Çünkü web kamerası için diktörtgensel ROI seçiminde  $R = 0,9946$  ve maskelenmiş görüntü için  $R = 0,9947$  olarak bulunmuştur. Benze şekilde endüstriyel kamera için diktörtgensel ROI seçiminde  $R = 0,9806$  ve maskelenmiş görüntü için  $R = 0,9682$  olarak bulunmuştur. Hatta endüstriyel kamera için başarıım düşmüştür. Normalde sistem kararlılığı için alev olmayan bileşenlerin sisteme dahil edilmemesi lazımdır. Fakat elde edilen sonuçlar aynı deney düzeneği için bu durumun fazla önemli olmadığını göstermiştir. Fakat ROI seçiminde dairesel maske uygulanmış diktörtgensel ROI’i nin kullanılması açıkça sistem kararlılığını arttıran bir durumdur. Bu şekilde ortam ışığının ve gözetleme deliğinin renginin sisteme olan etkisi minimuma indirgenmiş olur.

Endüstriyel kamera için üst mertebe çözünürlük seviyelerinin uygulanması kısmende olsa sistem doğruluğuna olan etkisi artmıştır. En iyi tüm sistem performansı 9x9 yerel pencere ve LM yöntemi için 1063x928 çözünürlük için  $R = 0,9806$  olmaktadır. Aynı şekilde performansı 9x9 yerel pencere ve LM yöntemi için 550x480 çözünürlük için  $R = 0,9800$  olmaktadır. Yani yüksek çözünürlüğün etkisi çok düşüktür. Kaldı ki en iyi başarımlar web kamerası için alınmıştır. Dolayısıyla sistemi gerçekleştirmek için web kamerasının yeterli olduğu ve düşük çözünürlüğe sahip kamera ile sistemin gerçekleştirilebileceğini göstermektedir.

### 6.8.1 Sonuçlar ve değerlendirme

Bu deneysel çalışmada web kamera ve endüstriyel kamera ile iki tip ROI seçimi irdelenmiştir. Yapılan çalışmalar sonucunda ROI seçiminde aynı deney verileri için alev görüntüsü olmayan bileşenlerin sistem doğruluğunu etkilemediği gösterilmiştir. Fakat gerçek zamanlı bir sistemde alev görüntüsü olmayan bileşenlerin çıkarılması gerektiği sonucuna varılmıştır. Sistemi gerçekleştirmek için web kamerasının yeterli olduğu ve yüksek çözünürlüğe ihtiyaç olmadığı gösterilmiştir. Görüntü momentleri ile yapılan deneyde elde edilen verileri destekleyen sonuçlar elde edilmiştir. Sistemi gerçekleştirmek için R, G ve B renk bileşenlerinin hepsi ve LM yönteminin kullanılmasının daha iyi olduğunu desteklemektedir. LM yöntemi eğitim aşamasındaki yüksek bellek ve uzun hesaplama süresi dezavantajına rağmen daha düşük yerel pencere boyutu için daha iyi sonuç vermektedir. Yani öznelik sayısı az olmasına rağmen daha iyi sonuç vermektedir. Öznelik sayısının az olması gerçek zamanlı bir sistemde istenen bir durumdur. Bu deney yapılırken 7468 adet YSA modeli oluşturularak sonuç alınmıştır. İlgili modellerin tüm sistem, eğitim, doğrulama, test ve tahmin sonuçları Ek D. CD'sinde 10 nolu klasörün içerisinde yer almaktadır.

## 7. GERÇEK ZAMANLI FAN KONTROL UYGULAMASI

Bu tez çalışmasının son uygulaması olarak TÜBİTAK 117M121 nolu proje kapsamında MİMSAN A.Ş. firmasının sağladığı deney düzeneği yapılan son deney irdelenmiştir. Bu deneyde otomatik yüklemeli kömür kazanında alev görüntüsü ile  $\lambda$  tahmini yapılarak yanma sürecinin kontrol edilmesi hedeflenmiştir. Daha önce yapılan deneysel çalışmalar değerlendirilerek gerçek zamanlı uygulamanın donanım bileşenleri, öznitelik çıkarma yöntemi ve YSA regresyon modeli parametreleri bu bölümde tartışılacaktır.

### 7.1 Sistem Bileşenleri

Gerçek zamanlı kontrol işlemi için donanım bileşenleri, kameranın tipinin seçilmesi ve gömülü karta karar verilmesi olarak 2 başlıkta toplanabilir. Altıncı bölümde 6.8 başlığında tartışıldığı gibi sistemi gerçekleştirmek için web kamerası yeterli olmaktadır. Üçüncü bölümde 3.1.4 başlığında anlatılan sebeplerden dolayı gömülü bilgisayar olarak latte panda bilgisayarının kullanılması uygun görülmüştür. Hem sistem giriş çıkışı desteği hemde hesaplama maliyeti açısından uygun bir bilgisayar olmaktadır.

### 7.2 Regresyon Modeli Parametrelerinin Seçimi

Gerçek bir sistemde alev görüntüsü- $\lambda$  eşleştirmesi yapılırken kullanılacak renk bileşenleri, görüntünün çözünürlüğü, ROI'nin seçilmesi, ızgara sayısına karar verilmesi ve öznitelik yönteminin kararlaştırılması gerekmektedir. Bir önceki bölümde 6.6 başlığında ayrıntılı incelenen deneyde  $\lambda$  tahmini için en yüksek başarımın elde edildiği öznitelik elde etme yöntemi görüntü momentleri yöntemi olmuştur. Çizelge 7.1'de görüntü momentleri çalışması için en yüksek test başarımı sonuçlarının alındığı 5'tane modelin parametreleri ve başarım performansları verilmiştir. Nihai model seçilirken tüm sistem, doğrulama veya eğitim performansı yerine test sonuçları dikkate alınmıştır. Gerçek bir sistemde sistem eğitim kümesiyle eğitilir ve daha sonra önceden hiç görmediği verilerle tahmin işlemi yapar. Dolayısıyla test işleminde veri sistem tarafından daha önce görülmediği için sistemin test performansı nihai sisteme karar verilirken kullanmak daha uygun olmaktadır.

**Çizelge 7.1 : İlgili YSA öğrenme modeli için en iyi test sonuçlarına sahip 5 adet modelin parametreleri ve başarımları**


|       |                      |           |              |                | Tüm Sistem Performansı |        | Test Performansı |        |
|-------|----------------------|-----------|--------------|----------------|------------------------|--------|------------------|--------|
|       | Yerel Pencere Sayısı | Çöz.      | Nöron Sayısı | YSA Öğr. Yönt. | MSE                    | R      | MSE              | R      |
| R-G-B | 4x4                  | 600x600   | 16           | LM             | 0,1085                 | 0,9837 | 0,1887           | 0,9707 |
|       | 4x4                  | 1100x1100 | 14           | LM             | 0,1181                 | 0,9822 | 0,2005           | 0,9692 |
|       | 4x4                  | 400x400   | 16           | LM             | 0,1297                 | 0,9805 | 0,2094           | 0,9679 |
|       | 4x4                  | 1000x1000 | 16           | LM             | 0,1198                 | 0,9820 | 0,2157           | 0,9678 |
|       | 4x4                  | 1000x1000 | 14           | LM             | 0,1191                 | 0,9820 | 0,2107           | 0,9675 |
|       | 11x11                | 1000x1000 | 14           | SCG            | 0,1269                 | 0,9808 | 0,1973           | 0,9708 |
|       | 11x11                | 1100x1100 | 16           | SCG            | 0,1239                 | 0,9813 | 0,1954           | 0,9706 |
|       | 10x10                | 800x800   | 14           | SCG            | 0,1207                 | 0,9818 | 0,1932           | 0,9702 |
|       | 9x9                  | 200x200   | 12           | SCG            | 0,1367                 | 0,9793 | 0,2048           | 0,9701 |
|       | 9x9                  | 400x400   | 12           | SCG            | 0,1483                 | 0,9776 | 0,1984           | 0,9698 |
| R-G   | 5x5                  | 200x200   | 16           | LM             | 0,1441                 | 0,9783 | 0,2450           | 0,9648 |
|       | 5x5                  | 800x800   | 16           | LM             | 0,1300                 | 0,9805 | 0,2313           | 0,9647 |
|       | 4x4                  | 400x400   | 16           | LM             | 0,1515                 | 0,9771 | 0,2362           | 0,9643 |
|       | 4x4                  | 600x600   | 16           | LM             | 0,1501                 | 0,9773 | 0,2419           | 0,9642 |
|       | 4x4                  | 200x200   | 14           | LM             | 0,1492                 | 0,9774 | 0,2386           | 0,9642 |
|       | 11x11                | 1100x1100 | 14           | SCG            | 0,1697                 | 0,9743 | 0,2454           | 0,9631 |
|       | 15x15                | 1100x1100 | 16           | SCG            | 0,1616                 | 0,9755 | 0,2619           | 0,9617 |
|       | 12x12                | 1100x1100 | 12           | SCG            | 0,1546                 | 0,9766 | 0,2548           | 0,9616 |
|       | 10x10                | 600x600   | 14           | SCG            | 0,1964                 | 0,9702 | 0,2553           | 0,9615 |
|       | 12x12                | 200x200   | 12           | SCG            | 0,1687                 | 0,9745 | 0,2538           | 0,9614 |

Çizelge 7.1’de de görüldüğü gibi sistemi gerçekleştirmek için RGB renk uzayında tüm renk kanallarını kullanmak başarımlar açısından daha uygundur. LM yöntemi SCG yöntemine göre daha uzun zamanda eğitilmektedir. Fakat Çizelge 6.1’de de açıkça görüldüğü gibi LM yöntemi daha düşük ızgara boyutlarında en iyi sonucu verirken SCG yöntemi daha büyük ızgara sayılarında en iyi sonucu vermektedir. Eğitim aşamasındaki dezavantajına rağmen daha yüksek başarımlar vermesi ve bunu daha küçük sayıda öz nitelik sayısı yapmasından dolayı eğitim modeli olarak LM yöntemi seçilmiştir. R-G-B renk kanalları ve LM öğrenme yöntemi için tüm modellerde 4x4 ızgara boyutu en ideal sonuçların alındığı modeldir. Gerçek zamanlı sistemdeki ızgara boyutu olarak 4x4 sayısı yüksek ihtimalli aday sayıdır. Fakat son bir deneyle 5x5, 6x6 ve 7x7 ızgara boyutlarının tüm deney verileri için performansı araştırılmıştır. Görüntü boyutu en ideal model için her ne kadar 600x600 ( $R = 0,9837$ ) olsada 400x400’de en iyi modele yakın  $R = 0,9805$  sonuç alınmıştır. 400x400 daha uygun bir çözünürlük olmaktadır. Çünkü piyasadaki birçok web kamerası 640x480 çözünürlüğü

desteklenmektedir. Ayrıca 400x400 çözünürlük hesaplama maliyeti açısından 600x600 çözünürlükten daha iyi olmaktadır. Bu sebeplerden dolayı nihai sistemde kamera çözünürlüğü 400x400 olarak seçilmiştir. Gizli katman nörön sayısı en ideal modelde 16 olarak bulunmuştur. Bu değer parametre araştırmasında sınır değer olduğu için parametre aralığı genişletilerek tüm verilerle son bir deney daha yapılmıştır. ROI'nin seçilmesi için 4 farklı yaklaşım (dikdörtgen, daire şeklinde maskelenmiş dikdörtgen, daire içi zıgara seçimi ve renk kanllarının filtrelenmesi yaklaşımları) söz konusu olmaktadır. Bunlar ayrıntılı tartışılacaktır.

### 7.3 İlgilenilen Bölgenin Seçilmesi

Kazan üzerindeki gözetleme penceresinin kenar kısımlarında istenmeyen görüntü bileşenleri olabildiği için belirli bir bölgenin (ROI) seçimi gerçek zamanlı sistem için önemlidir. Daha önceki çalışmalarda tek deney verisi kullanıldığı için böyle bir bölge sınırlamasına ihtiyaç duyulmamıştır. Fakat genel bir sistemde bu durumun göz ardı edilmemesi gerekmektedir. ROI'nin seçilmesi için 4 farklı yaklaşım söz konusu olmaktadır. Birinci yöntem dikdörtgensel olarak ROI'nin (Şekil 7.1) seçilmesidir. Bu yöntemde 6.8 başlığında tartışıldığı alev olmayan bileşenler sisteme dahil edildiği için sistem kararlılığı açısından dezavantajlı bir yöntemdir.




(a)

(b)

**Şekil 7.1 :** Dikdörtgensel ROI'nin (a) web ve (b) endüstriyel kamerada seçimi

İkinci yöntem alevin bir daire içine düşecek şekilde sınırlarının belirlenmesi ve sadece daire içine düşen ızgaraların sisteme dahil edilmesi yaklaşımıdır. Şekil 7.2'de (a) 16x16'lık ızgara ve (b) 4x4'lük ızgara için sisteme dahil edilecek ızgarlar kırmızı ile


gösterilmiştir. Şekilden de görüldüğü gibi düşük ızgara (Şekil 7.2 (b)) sayılarında alev bölgesi büyük bir kısmı sisteme dahil edilmemektedir. Bu durum istenilmeyen bir durum olması sebebiyle bu yöntem açıkça dezavantajlı bir yöntemdir.



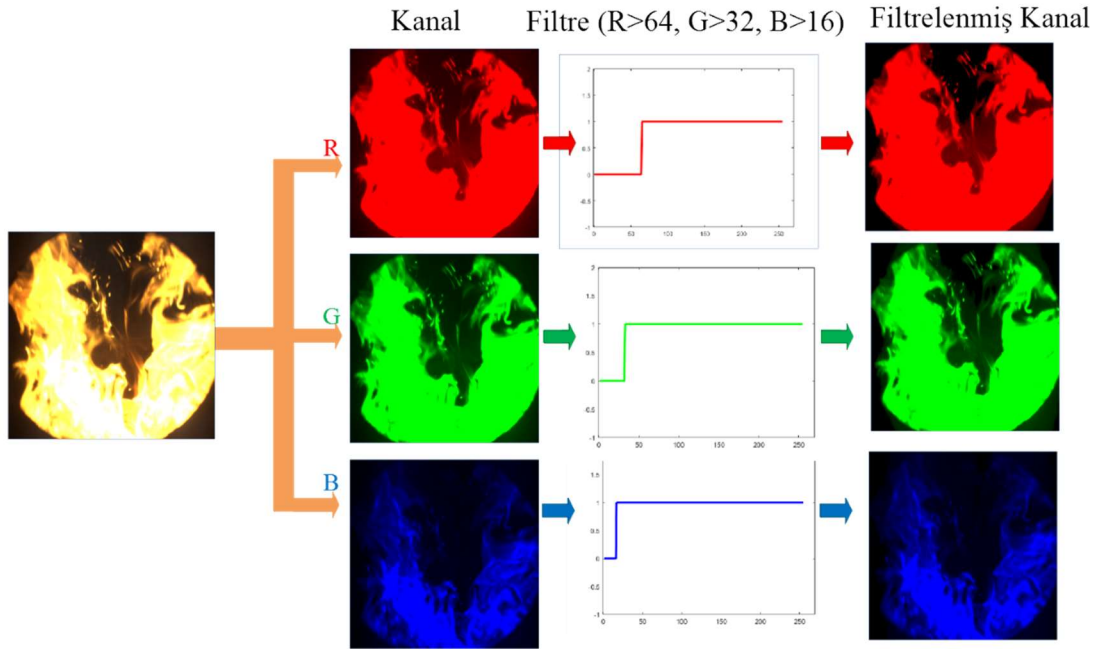
**Şekil 7.2 :** Daire içi ızgara ROI'nin (a) 16x16 ve (b) 4x4'lük ızgara için seçimi

Üçüncü yöntem, birinci yöntemdeki dikdörtgensel ROI'nin alev bölgesi tek kalacak şekilde dairesel bir maske maskelenmesidir. Şekil 7.3'te (a) dairesel maske ve (b) bunun örnek bir görüntüye uygulanışı verilmektedir. Bu yaklaşım 6.8 başlığındaki deneye uygulanmış ve başarılı sonuçlar almıştır. Alev görüntüsü olmayan bileşenler sisteme dahil edilmediği için ROI seçimi için kararlı olması beklenen bir yaklaşımdır. Gerçek zamanlı uygulama için aday bir yaklaşımdır.

Dördüncü yaklaşım, her bir renk bileşeni için yüksek geçirgen bir filtre uygulanmasıdır. Bu işlem için RGB renk uzayındaki R, G ve B bileşenlerinin her birine Şekil 7.4'deki gibi bir yüksek geçirgen filtre uygulanmaktadır. Bu şekilde alev dışındaki bileşenler elendiği için sistem kararlılığının artırılmasına olumlu katkı sunulması beklenir. Gerçek zamanlı uygulama için aday bir yaklaşımdır.



Şekil 7.3 : ROI'nin (a) dairesel maske ile (b) örnek bir görüntüye uygulanışı




Şekil 7.4 : Alev görüntüsün her bir bileşenin filtrelenmesi

ROI'nin seçilmesi için dairesel maskeleme ve renk bileşenlerinin yüksek geçirgen filtre ile filtrelenmesi yaklaşımlarından hangisinin daha uygun olacağını kestirmek güçtür. Yüksek geçirgenli filtre yaklaşımında alev bölgesi olmayan yerlerin karanlık olacağını varsaydığında bu ön kabulün olmadığı durumda yani beyaza yakın olduğu durumlarda alev dışındaki bileşenler sisteme giriş olarak etki etmektedir. Fakat kazan içi için aynı zamanda bir filtre görevi gördüğü için kesin olarak hangi yöntemin daha uygun olacağını kestirmek güçtür. Bu yüzden tüm deney verileri kullanılarak daha önce kesinleşen gerçek zamanlı sistem parametreleri ile üçüncü ve dördüncü ROI seçimi için doğruluğun nasıl değiştiği

araştırılmıştır. Bu işlem YSA regresyon modeli için LM yöntemi, DGÇ modeli ve googlenet ESA'sı için tekrarlanmıştır.

#### 7.4 Yerel Pencere Boyutu, Nöron Sayısı ve Regresyon Modeli Seçimi

Bu çalışmada deney 2-8 verileri kullanılarak maskelenmiş dikdörtgenel ROI ve yüksek geçiren filtre ile filtrelenmiş dikdörtgenel bölge ROI seçimi için doğruluğun nasıl değiştiği araştırılmıştır. Bu işlem nihai ROI seçme işlemine karar vermek ve regresyon modellerini kıyaslamak için yapılmıştır. Bu çalışma YSA regresyon modeli için LM yöntemi, DGÇ modeli ve googlenet ESA'sı için tekrarlanmıştır. Izgara sayısı  $4 \times 4$ ,  $5 \times 5$ ,  $6 \times 6$  ve  $7 \times 7$  çözünürlük  $400 \times 400$  olarak alınmıştır. Dairesel ROI seçilirken tüm deneyler için Şekil 7.5'te ROI seçimi için (a) diareysel maske, (b) maskenin şekli ve (c) örnek bir görüntüye uygulaması verilmiştir. Burada  $X_c$  dairenin çapı olmaktadır.  $X_c$ 'nin başlangıç ve bitiş noktası görüntünün içinde olmak zorundadır. Diğer boyutlar  $X_c$ 'ye göre hesaplanmaktadır.  $Y_c = X_c \times 0,8727$ ,  $X_u = (X_c - Y_c) \times 0,2429$  ve  $X_a = (X_c - Y_c) \times 0,7271$  olarak alınmaktadır.  $X_c$ 'de olduğu gibi  $X_u$  ve  $X_a$ 'nın sınırları görüntünün içinde olacak şekilde seçilmiştir.




Şekil 7.5 : ROI seçimi için (a) diareysel maske, (b) maskenin şekli ve (c) örnek bir görüntüye uygulaması

ROI seçimi için tüm kullanılan deney verileri Çizelge 7.2'de verilmiştir. Her deney için yalnız bir adet kamera görüntüsü kullanılmıştır. Ayrıca veri tabanını çoğaltmak için görüntü terse çevrilerek aynı lambda değeri için farklı bir görüntü oluşturulmuştur. Şekil 7.6'da bu işlem gösterilmiştir. Kömür beslemesi ve hava girişi kazanın altındadır. Kömürün yandığı bölge yani helezon dairesel olmaktadır. Bazen tek tarafta yanma olmakta diğer tarafta yanma olmamaktadır. Yanmanın hangi tarafta olduğu  $\lambda$  değişimi açısından önemli değildir. Dolayısıyla Şekil 7.6 için (a) ve (b) görüntüsü için  $\lambda$  değeri aynı olmaktadır.

Bu yüzden görüntünün tersi alınarak veri tabanı boyutu (75807 alev görüntüsü) 2 katına (151614 alev görüntüsü) çıkarılmıştır. Bu şekilde yanmanın başladığı tarafın, sistemi bozma etkisini azaltılması hedeflenmiştir. Öznitelik çıkarma aşamasında konuma bağlı öznitelik çıkarma yöntemi önerildiği için ters görüntü alınması işlemi (yanmanın olduğu taraf varyasyonu) sistem çıkışını etkileyebilecektir. Veri tabanını çoğaltma işlemiyle sistemin tutarlılığını artırması hedeflenmiştir.

**Çizelge 7.2 : Kullanılan deney verileri**

|        |   | Deney No |   |   |     |     |     |     |     |     |     |     |   |     |     |     |
|--------|---|----------|---|---|-----|-----|-----|-----|-----|-----|-----|-----|---|-----|-----|-----|
|        |   | 1        | 2 | 3 | 4-a | 4-b | 5-a | 5-b | 5-c | 6-a | 6-b | 6-c | 7 | 8-a | 8-b | 8-c |
| Kamera | 1 |          | ✓ |   |     |     |     |     |     |     |     |     |   |     |     |     |
|        | 2 |          |   | ✓ | ✓   | ✓   | ✓   | ✓   | ✓   | ✓   | ✓   | ✓   | ✓ | ✓   | ✓   | ✓   |



(a)

(b)

**Şekil 7.6 : Örnek bir görüntü için (a) orjinal (b) ters çevrilmiş görüntü**

Deney düzeneğinde görüntünün alındığı yer (yanma bölgesi) ve referans verilerin alındığı BGA cihazı arasında belli bir mesafe uzaklık bulunmaktadır. Normalde deney düzeneği zaman gecikmeli bir sistem değildir. Ölçüm noktaları arasında ortalama 1.5 saniyelik bir zaman farkı olabilmektedir. Fakat ölçüm değeri küçük değerlerle artıp azaldığı için bu gecikme regresyon modeli tarafında öğrenile bilmektedir. Ölçüm değerleri ara değer üretme işlemi ile çoğaltılmaktadır. Yani 0.5 saniyelik zaman farkı ile ara değer üretme işlemi yapılmaktadır. Kısaca deney düzeneği zaman gecikmeli bir sistem olmadığı için alev görüntüsü ve BGA ölçüm cihazı arasındaki uzaklık dikkate alınmamıştır. Normalde son deneyde YSA ve ESA regresyon modellerinin tüm deney verileriyle oluşturulup kıyaslanması hedeflenmiştir. Fakat öncelikle DGÇ regresyon modeli kullanılarak iki cihaz

arasındaki uzaklığın sistem doğruluğu üstündeki etkisinin görülmesi istenmiştir. Be şekilde nihai aday regresyon modeli sayısı belirlenmiş olacaktır.

DGÇ modelinde  $p$  adet önceki giriş anlık sistem girişine dahil edilerek sistem çıkışı hesaplanmaktadır. Yürütülen bu çalışmada 2'den 6'ya kadar olan girişin (anlık ve  $p - 1$  adet geçmiş giriş) sisteme dahil edilmesinin sistem performansını nasıl etkilediği araştırılmıştır. İlk olarak optimum ızgara boyutu ( $4 \times 4$ ,  $5 \times 5$ ,  $6 \times 6$  ve  $7 \times 7$ ), optimum gizli katman nöron sayısı (12, 14, 16, 18 ve 20) ve optimum geçmiş giriş sayısı (2, 3, 4, 5 ve 6) araştırması yapılmıştır. Bu şekilde DGÇ modeli için optimum yerel pencere sayısı, gizli katman nöron sayısı ve geçmiş giriş adeti oluşturulan modellerin performans kriterlerine göre seçilmiştir. Daha önce yapılan deneyler değerlendirilerek YSA öğrenme modeli için LM yöntemine karar kılınmıştır. LM yönteminin eğitimi uzun sürdüğü için 12 gizli nöron için tüm yerel pencere boyutları için sonuç alındı. En iyi sistem olan 3 gecikmeli sistem ( $R = 0,8687$ ) için 12-20 arasındaki gizli katman nöron sayısı için model 3 kez oluşturularak sonuç alındı. Fakat başarımların düşük ( $R = 0,8687$ ) çıkmıştır. En iyi test sonucunun alındığı model olan 6 gecikmeli giriş içinde benzer olarak 12-20 arasındaki gizli katman nöron sayısı için sonuç alındı fakat başarımların düşük ( $R = 0,8487$ ) çıkmıştır. Bunun muhtemel bir sebebi olarak DGÇ modelinde geçmiş girişler sisteme dahil edildiğinden giriş sayısının artması olasılığı değerlendirilmiştir. Daha önce yapılan deneylerde görülmüştü ki LM yöntemi düşük sayıdaki giriş sayısı için en iyi performansı göstermektedir. SCG yöntemi ise yüksek sayıdaki giriş sayısı için daha iyi sonuç vermektedir. Bu yüzden DGÇ modeline mahsus olmak üzere SCG öğrenme modeli içinde tüm parametreler için modeller 3 kez oluşturularak sonuç alınmıştır. Fakat başarımların artmamıştır. En yüksek başarımlar  $R = 0,8091$  olarak bulunmuştur.

ROI seçimi için aday iki yöntem (maskelenmiş ve filtrelenmiş görüntü) hem LM hemde SCG yöntemin için sonuç alınmıştır. Çizelge 7.3'te DGÇ öğrenme modeli için optimum gecikmeli giriş sayısı ve nöron sayısında model performans sonuçları verilmiştir. Çizelge 7.3'ten de görüldüğü gibi genel olarak DGÇ yöntemi kötü performans vermiştir. Anlık giriş ve önceki 2 giriş yani toplam 3 gecikmeli girişli sistemde en iyi tüm sistem performansı  $R = 0,8687$  olarak bulunmuştur. DGÇ yöntemi sonraki başlıkta anlatılacak olan gerçek zamanlı uygulamada iyi sonuç vermiştir. Fakat bu deneydeki veri tabanı hem standartları farklı hem veri tutarlılığı kesinleştirilmeyen deney 1 verileri dahil edilmemiştir. Diğer veriler için görüntünün tersini almak suretiyle veri tabanı boyutu 2 katına çıkarılmıştır. Elde edilen bu

sonular deęerlendirilerek regresyon modelleri iin DG modeli aday model olmaktan ıkmıřtır. Her ne kadar sistemde gecikme olduęundan dolayı gecikmeli giriř etkisinden dolayı modelin daha iyi ğreneceęi varsayılmıřsa da elde edilen sonular bu savı ürütmüřtür. Bu yüzden nihai regresyon modeli iin YSA ve ESA modelleri aynı veri seti ile deęerlendirilmiřtir. DG modeli ile yapılan testlerde elde edilen sonular nihai ROI seimi iin fikir versede YSA ve ESA modelleri iin ayrıca deęerlendirilecektir. Bu deneysel alıřma iin ayrıntılı sonular Ek D. CD'sinde 11 nolu klasörün ierisindedir.

**izelge 7.3** : DG ğrenme modeli iin optimum gecikmeli giriř sayısı ve optimum nöron sayısında modelin performans sonuları

|                  |                      |                        |              | YSA Öğr. Yönt. | Tüm Sistem Performansı |               | Test Performansı |               |
|------------------|----------------------|------------------------|--------------|----------------|------------------------|---------------|------------------|---------------|
|                  | Yerel Pencere Sayısı | Gecikmeli Giriř Sayısı | Nöron Sayısı |                | MSE                    | R             | MSE              | R             |
| ROI-Filtrelenmiř | 4x4                  | 6                      | 18           | LM             | 0,2419                 | 0,8396        | 0,7551           | 0,3978        |
|                  | 5x5                  | 6                      | 12           | LM             | 0,2133                 | 0,8595        | 0,6943           | 0,3402        |
|                  | 6x6                  | 5                      | 12           | LM             | 0,3081                 | 0,8028        | 1,1429           | 0,1842        |
|                  | 7x7                  | 2                      | 12           | LM             | 0,2279                 | 0,8454        | 0,5793           | 0,4656        |
|                  | 4x4                  | 3                      | 18           | SCG            | 0,3346                 | 0,7655        | 0,4910           | 0,4581        |
|                  | 5x5                  | 6                      | 14           | SCG            | 0,3018                 | 0,7857        | 0,4803           | 0,4359        |
|                  | 6x6                  | 6                      | 16           | SCG            | 0,3258                 | 0,7688        | 0,4859           | 0,3897        |
|                  | 7x7                  | 6                      | 12           | SCG            | 0,3002                 | 0,7928        | 0,5226           | 0,4085        |
| ROI-Maskelenmiř  | <b>4x4</b>           | <b>3</b>               | <b>12</b>    | <b>LM</b>      | <b>0,1944</b>          | <b>0,8687</b> | <b>0,7771</b>    | <b>0,7659</b> |
|                  | 5x5                  | 6                      | 12           | LM             | 0,2063                 | 0,8616        | 0,8596           | 0,7510        |
|                  | 6x6                  | 4                      | 12           | LM             | 0,2070                 | 0,8595        | 0,4139           | 0,6426        |
|                  | 7x7                  | 4                      | 12           | LM             | 0,2118                 | 0,8560        | 0,6688           | 0,2909        |
|                  | 4x4                  | 5                      | 18           | SCG            | 0,3003                 | 0,7872        | 0,8246           | 0,7682        |
|                  | 5x5                  | 6                      | 20           | SCG            | 0,2753                 | 0,8091        | 0,8342           | 0,7703        |
|                  | 6x6                  | 6                      | 20           | SCG            | 0,2852                 | 0,8040        | 0,5605           | 0,4604        |
|                  | 7x7                  | 5                      | 16           | SCG            | 0,2912                 | 0,7957        | 0,4290           | 0,5457        |

Bu alıřmada YSA ve ESA modelleri inřa edilirken veri tabanın %70'i eęitim, %15'i doęrulama ve %15'i test iřlemi iin kullanılmıřtır. Bu veri tabanı kullanılarak daha önce anlatılan parametreler iin YSA modeli iin optimum parametre arařtırması yapılmıřtır. Bu kapsamda LM ğrenme yöntemi iin znelik ıkarma ařamasındaki yerel pencere boyutu ve gizli katman nöron sayısı kararlařtırlacaktır. izelge 7.4'te YSA regresyon modeli iin lambda tahmin sonuları verilmiřtir.

**Çizelge 7.4 : YSA regresyon modeli için lambda tahmin sonuçları**

|                   |                      |              | Tüm Sistem Performansı |               | Eğitim Performansı |               | Test Performansı |               |
|-------------------|----------------------|--------------|------------------------|---------------|--------------------|---------------|------------------|---------------|
|                   | Yerel Pencere Sayısı | Nöron Sayısı | MSE                    | <i>R</i>      | MSE                | <i>R</i>      | MSE              | <i>R</i>      |
| ROI- Filtrelenmiş | 4x4                  | 20           | 0,0687                 | 0,9555        | 0,0648             | 0,9582        | 0,0769           | 0,9495        |
|                   | 5x5                  | 20           | 0,0597                 | 0,9614        | 0,0533             | 0,9655        | 0,0749           | 0,9512        |
|                   | 6x6                  | 14           | 0,0609                 | 0,9606        | 0,0530             | 0,9658        | 0,0759           | 0,9502        |
|                   | 7x7                  | 16           | 0,0527                 | 0,9660        | 0,0449             | 0,9711        | 0,0694           | 0,9554        |
| ROI- Maskelenmiş  | 4x4                  | 20           | 0,0718                 | 0,9533        | 0,0691             | 0,9550        | 0,0747           | 0,9513        |
|                   | <b>5x5</b>           | <b>18</b>    | <b>0,0553</b>          | <b>0,9643</b> | <b>0,0513</b>      | <b>0,9669</b> | <b>0,0658</b>    | <b>0,9568</b> |
|                   | 6x6                  | 20           | 0,0609                 | 0,9606        | 0,0530             | 0,9656        | 0,0748           | 0,9523        |
|                   | 7x7                  | 18           | 0,0550                 | 0,9645        | 0,0466             | 0,9702        | 0,0706           | 0,9536        |

Çizelge 7.4'ten de görüldüğü gibi en iyi sonuç 5x5 yerel pencere boyutu ve 18 gizli nöron için makelenmiş ROI seçim yöntemi için test sonucu  $R = 0,9568$  olarak bulunmuştur. ROI seçme yöntemi olarak dairesel maske ile maskelenmiş ve filtrelenmiş dikdörtgenel bölge seçimi için YSA ve ESA modellerinde her ikisi içinde sonuç alınmıştır. Maskelenmiş görüntü ve filtrelenmiş görüntü hemen hemen aynı sonucu vermiştir. Elde edilen bu sonuç nihai sistem için model parametreleridir. Çünkü tüm verileri denenenerek elde edilmiş en geniş model parametresi sonucudur. Bu deneysel çalışma için ayrıntılı sonuçlar Ek D. CD'sinde 11 nolu klasörün içerisinde yer almaktadır.

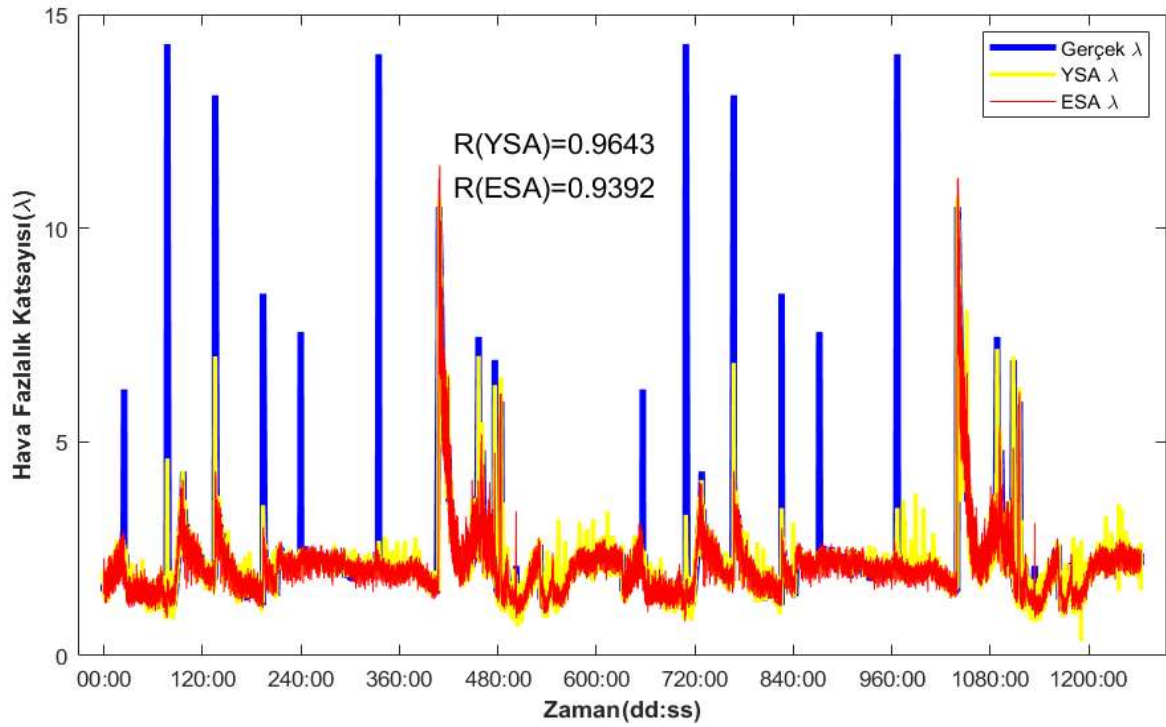
ESA modeli olarak daha önce anlatılan sebeplerden dolayı googlenet ESA'sı kullanılarak tüm verilerle değerlendirilmiştir. Çizelge 7.5'te googlenet ESA'sı regresyon modeli için lambda tahmin sonuçları verilmiştir. Çizelge 7.3'ten de görüldüğü gibi en iyi test sonucu filtrelenmiş görüntü için  $R = 0,9375$  olarak bulunmuştur. Maskelenmiş görüntünün tüm sistem performansı daha iyi olmasına rağmen filtrelenmiş görüntü için test performansı daha iyi olmuştur.

**Çizelge 7.5 : Derin öğrenme (ESA) için lambda tahmin sonuçları**

| ROI Yöntemi | Tüm Sistem Performansı |          | Eğitim Performansı |          | Test Performansı |               |
|-------------|------------------------|----------|--------------------|----------|------------------|---------------|
|             | MSE                    | <i>R</i> | MSE                | <i>R</i> | MSE              | <i>R</i>      |
| Maske       | 0,0940                 | 0,9386   | 0,0911             | 0,9413   | 0,1070           | 0,9285        |
| Filtre      | 0,0932                 | 0,9392   | 0,0892             | 0,9418   | 0,0943           | <b>0,9375</b> |

## 7.5 Sonular ve Deęerlendirme

Bu deney en geniř deney verileri deęerlendirilerek 151614 adet grnt ile gerekleřtirilmiřtir. Bu deney sonucunda ROI seiminde filtreleme teknięi ve maskeleye teknięi arasında fazla bir fark olmadıęı nicel verilerle gsterilmiřtir. Yerel pencere boyutu iin 5x5 olması ve gizli katman nron sayısının 18 olması en iyi modelin dięer parametreleridir. DGC regresyon modeli řařırtıcı bir řekild ok kt sonu vermiřtir. ESA modeli olarak googlenet n eęitimli aęla eęitilen modelde sistem performansı YSA modelinden daha dřk olarak blunmuřtur. ESA ve YSA modellerinde en iyi test performansı veren modeller iin gerek ve tahmin edilen lambda deęerleri grafiksel olarak řekil 7.7’de verilmiřtir.



Şekil 7.7 : Gerek lambda ve ESA ve YSA modellerinin tahmin ettięi lambda

## 7.6 Gerek Zamanlı Fan Kontrol Uygulaması


Bu bařlıkta Tbitak projesi kapsamında MİMSAN A.ř firmasında yapılan son deneyler verilecektir. Bu kapsamda 13.02.2019, 14.2.2019 (deney 9) ve 15.02.2019 (deney 10) tarihlerinde ilgili deneyler yapılmıřtır. İlk gn, deney sistemin ayaęa kaldırılması ve ilk denemelerden oluřmakta saęlıklı veri alınmadıęı deneydir. İkinci gn, projenin makine mhendislięi ekibinin kontrol uygulaması gerekleřtirmesi iin sistemin kontroln kendilerine verilip kontrol uygulaması iin denemeler yapılmıřtır. İkinci gnde dięer

kameradan sonradan kullanılmak üzere yapılan deneyden bağımsız olarak alev görüntüsü kaydedilmiştir. 15.02.2019 tarihli deney ise geliştirdiğimiz gauss kontrol uygulamasının gerçek zamanlı sistemde iki farklı YSA regresyon modeliyle test edildiği deneydir. Sonraki gün yani 16.02.2019 tarihli deney sadece makine mühendisliği ekibinin kendi başına yaptığı deneydir. İlk 3 gün yapılan deneyler kapsamında gerçekleştirilen çalışmalar ve elde edilen bulgulara değinilecektir. Bir önceki başlıkta verilen sistem analizi sonuçları bu deneylerden sonra yapılmıştır. Dolayısıyla bu deneylerdeki sistem bileşenleri ve nihai tavsiye edilen sistem bileşenleri arasında farklar vardır. Çünkü en son optimizasyon işlemleri bu deneylerden sonra yapılmıştır.

Deneylerin yapıldığı fındık kömürlü otomatik yüklemeli kömür kazanı için zaten kömür yüklemesini otomatik yapan bir kontrol kartı bulunmaktadır. Fakat ilgili kontrol kartıyla sadece yükleme ve bekleme süresi ayarlanarak kullanıcının tecrübesine dayanan bir kontrol mekanizması mevcuttur. Mevcut kazanda anlık olarak yanma süreci değerlendirilerek yanma optimizasyonunu yapan bir sistem mevcut değildir. Projenin hedeflediği alev görüntüsü ile yanma kontrol işleminin gerçekleştirilmesi işlemi için belli bir kömür yükleme ve bekleme süresi için fan devri, geliştirilen kontrol uygulaması ile kontrol edilmiştir. Bu işlem için 5 sn kömür yüklemesi ve 115 sn bekleme süresi için fan kontrolü yapılarak yanma işleminin kontrolü sağlanmıştır. Fan kontrolü için alev görüntüsünden öznitelik alınıp daha önceden  $\lambda$  tahmini için eğitilen YSA regresyon modeli ile anlık  $\lambda$  tahmini yapılmaktadır. İdeal yanma durumunda  $\lambda=1.4$  olduğundan dolayı tahmin edilen  $\lambda$  değerine göre hata hesaplanmakta ve bu hata değerine göre fan kontrolü yapılmaktadır.

Fan devri için daha önceden anlatılan gömülü kart uygulamasıyla aynı işlemi yapan bir Matlab programı geliştirilmiştir. İlgili Matlab programında da kamera ayarları kullanıcı tarafından ayarlanabilecek şekilde düzenlenmiştir. Gömülü kartta 5v PWM işaretini kart üstündeki çıkış portlarından üretile biliniyorken Matlab uygulamasının koştugu bilgisayarda bu mümkün olmamaktadır. Bu yüzden projenin elektronik ekibi tarafından bir adet seri porttan aldığı veriye (fan devri kontrol değişkeni) göre 10v PWM işaretini üreten bir elektronik kart geliştirilmiştir. Gömülü bilgisayar için ilgili kontrol devresi yerine bir adet yükselteç ile 5v PWM işaretininin 10v PWM işaretine dönüştürülmesi yeterli olacaktır. PWM üretici devresinin çıkışı yani PWM işaretini bir evirici ile asenkron 3 fazlı motora sahip fanı

sürmekte kullanılmıştır. Şekil 7.8’de geliştirilen PWM üretici, evirici kart ve fan (3 fazlı asenkron motor) gösterilmektedir.



Şekil 7.8 : Fan kontrolü için deney düzeneği


Fan kontrolü yapılırken hatanın pozitif (Denklem (7.1)) ve negatif (Denklem (7.2)) olduğu taraflar için iki adet tek yönlü gauss eğrisi uydurularak bir kontrol algoritması geliştirilmiştir. Buna göre fan devri için en yüksek ve düşük devir adımı ve ideal yanma durumundaki fan devir adımı belirlenmektedir. Şekil 7.9’da 5 sn yükleme ve 115 sn bekleme durumunda fanı kontrol etmek için uygulanan kontrol işaretini grafiksel olarak verilmiştir.

$$U = \left( e^{-\frac{1}{2}x\left(\frac{\lambda-\lambda_{opt}}{7^2}\right)^2} - 1 \right) x U_{opt} + U_{opt} , \quad \lambda - \lambda_{opt} \geq 0 \quad (7.1)$$

$$U = \left( 1 - e^{-\frac{1}{2}x\left(\frac{\lambda-\lambda_{opt}}{(0.45)^2}\right)^2} \right) x (U_{max} - U_{opt}) + U_{opt}, \quad \lambda - \lambda_{opt} < 0 \quad (7.2)$$

Burada;  $U$  fan devrini ayarlayan Gauss kontrol işaretini,  $e = 2.7183$ ,  $\lambda_{opt}$  değeri kullanılan kömür çeşidi için ideal yanma durumundaki  $\lambda$  değerini belirlemektedir ve  $\lambda_{opt} = 1.4$  olarak alınmıştır.  $U_{opt}$  ise 5 sn yükleme 115 sn bekleme için ideal yanma durumu yani hata sıfır

iken ki kontrol işaretini ifade etmektedir ve  $U_{opt} = 120$  olarak alınmıştır.  $U_{max}$  kontrol işaretinin maksimum değeridir.



**Şekil 7.9 :** Fan kontrolü için geliştirilen Gauss kontrol işareti-hata değişimi

Fabrikada gerçek zamanlı fan kontrol uygulaması yapılırken 15.02.2019 tarihli deneyde kullanılan iki çeşit YSA regresyon modeli çeşitli deneysel çalışmalar sonucunda karar verilmiştir. Yapılan bu deneysel çalışmalara kısaca değinilecektir. Çizelge 3.2’de kısaca özetlenen deney verilerden 3 adet veri tabanı oluşturulmuştur. Bu veri tabanları oluşturulurken endüstriyel kamera ve web kamerası birlikte (1. veri tabanı), sadece web kamerası görüntüleri (2. veri tabanı) ve 2. veri tabanından farklı çözünürlükteki deneyin çıkarıldığı tüm verilerin 600x800 çözünürlükte olduğu deney verileri (3. veri tabanı) ile oluşturulmuştur. Çizelge 7.6’da ilgili veri tabanları için kullanılan deney verileri verilmiştir.

Bu üç veri tabanı ile görüntüler yeniden boyutlandırılmadan yani orijinal boyutunda ve her bir veri tabanı için dikdörtgenel ROI seçilerek öznelikler çıkarılmıştır. Öznelikler çıkarılırken görüntünün ilk iki momenti olan ortalama ve standart sapma kullanılmıştır. Görüntü momentleri çalışmasından edinilen tecrübeler değerlendirilerek 5x5, 6x6 ve

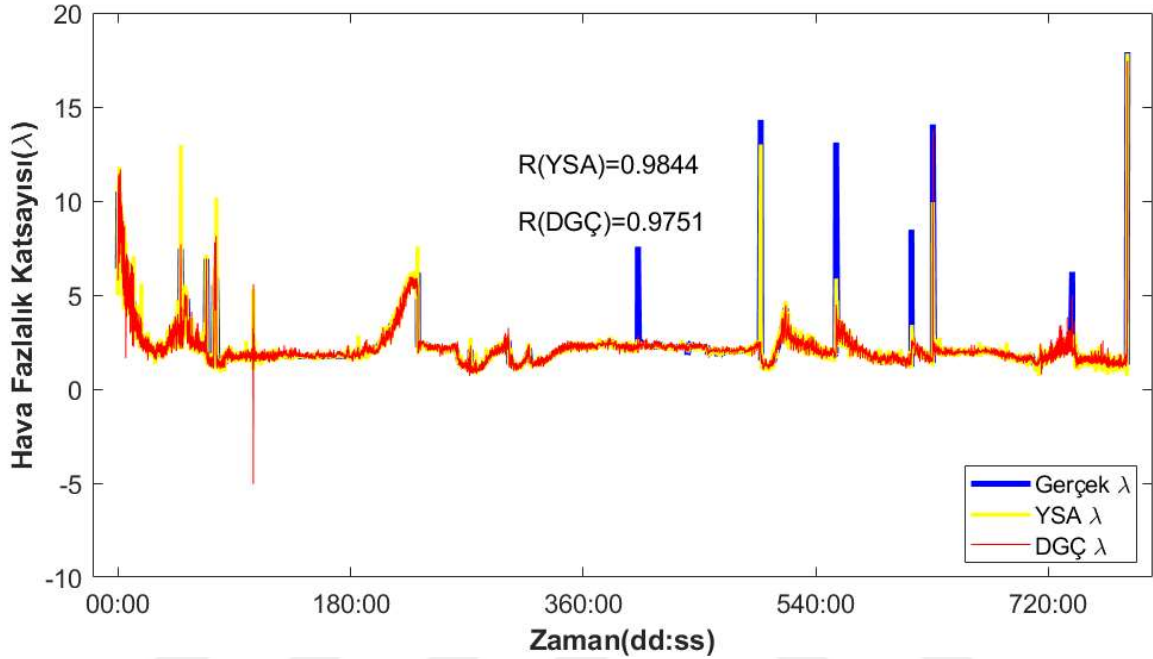
7x7'lik yerel pencereler için RGB renk uzayında her bir renk bileşenin yerel penceresi için bu iki öznitelik hesaplanıp öznitelik birleştirme tekniği ile nihai öznitelikler oluşturulmuştur.

**Çizelge 7.6 : Gerçek zamanlı uygulama için oluşturulan veri tabanları**

| Deney No | Veri Tabanı -1 |           | Veri Tabanı -2 |           | Veri Tabanı -3 |           |
|----------|----------------|-----------|----------------|-----------|----------------|-----------|
|          | Kamera -1      | Kamera -2 | Kamera -1      | Kamera -2 | Kamera -1      | Kamera -2 |
| 1        | ✓              |           |                |           |                |           |
| 2        | ✓              |           |                |           |                |           |
| 3        |                | ✓         |                |           |                |           |
| 4-a      |                | ✓         |                |           |                |           |
| 4-b      |                | ✓         |                |           |                |           |
| 5-a      |                | ✓         |                | ✓         |                | ✓         |
| 5-b      |                | ✓         |                | ✓         |                | ✓         |
| 5-c      |                | ✓         |                | ✓         |                | ✓         |
| 6-a      |                | ✓         |                | ✓         |                | ✓         |
| 6-b      |                | ✓         |                | ✓         |                | ✓         |
| 6-c      |                | ✓         |                | ✓         |                | ✓         |
| 7        |                | ✓         |                |           |                |           |
| 8-a      |                | ✓         |                | ✓         |                |           |
| 8-b      |                | ✓         |                | ✓         |                |           |
| 8-c      |                | ✓         |                | ✓         |                |           |


YSA regresyon modeli oluşturulurken görüntü momentleri çalışması sonuçları değerlendirilerek 8 ve 12 gizli nörona sahip modeller sonuç elde edilmiştir. Ayrıca veri tabanı boyutu büyüdüğü için 20 gizli nörona sahip modeller içinde sonuç elde edilmiştir. En nihayetinde veri tabanı bir ve iki için 15 adet, üç için ise 12 adet YSA regresyon modeli oluşturulmuştur. Bu YSA regresyon modellerinin hepsi için 14.02.2019 tarihindeki deneylerde gerçek zamanlı performans analizi yapılarak 6 adet YSA regresyon modeli nihai model için aday bırakılmıştır. 15.02.2019 tarihli deneyde bu 6 adet YSA regresyon modeli sonuçları gerçek zamanlı olarak gözlemlenmiştir. Birinci veri tabanı verileri ile eğitilen iki adet model en iyi iki model olarak öne çıkmıştır. Bunlardan ilki YSA regresyon modeli diğeri 5 adet önceki girişi alan DGÇ modelidir. DGÇ modeli için 2, 3, 4, 5 ve 6 önceki girişlerin sisteme giriş olarak verildiği modeller değerlendirilerek anlık ve 4 önceki girişin (toplam 5 giriş) model girişine dahil edilmesine karar verilmiştir. YSA modeli için 7x7'lik yerel pencereye sahip 20 gizli nörona sahip model gerçek zamanlı (deney 10-a) olarak fan kontrolünde kullanılmıştır. Benzer şekilde 7x7'lik yerel pencere için önceki 5 girişi alıp sonuç üreten DGÇ modeli gerçek zamanlı (deney 10-b) olarak fan kontrolünde kullanılmıştır. Şekil 7.10'da veri tabanı-1 verileriyle oluşturulan YSA ve DGÇ modeli için tahmin edilen  $\lambda$  değerleri ve BGA cihazından ölçülen gerçek  $\lambda$  değerleri grafiksel olarak verilmiştir. Şekilde DGÇ modelinin  $\lambda$  tahmininde eksi sonuç verdiği görülmektedir. Gerçekte böyle bir durum söz konusu olmaz çünkü yanma süreci ardışık devam eder ama

tüm deney verileri oluşturularak gerçekleştirilen model için farklı zamanlarda gerçekleştirilen deney verilerinin birleşiminde birisinin bittiği diğerinin başladığı noktada büyük  $\lambda$  değişimleri olabilir. Bu yüzden grafikte eksi sonuç çıkmıştır. Bu iki modelin gerçek zamanlı deney uygulamasında elde edilen bulgulara kısaca değinilecektir.



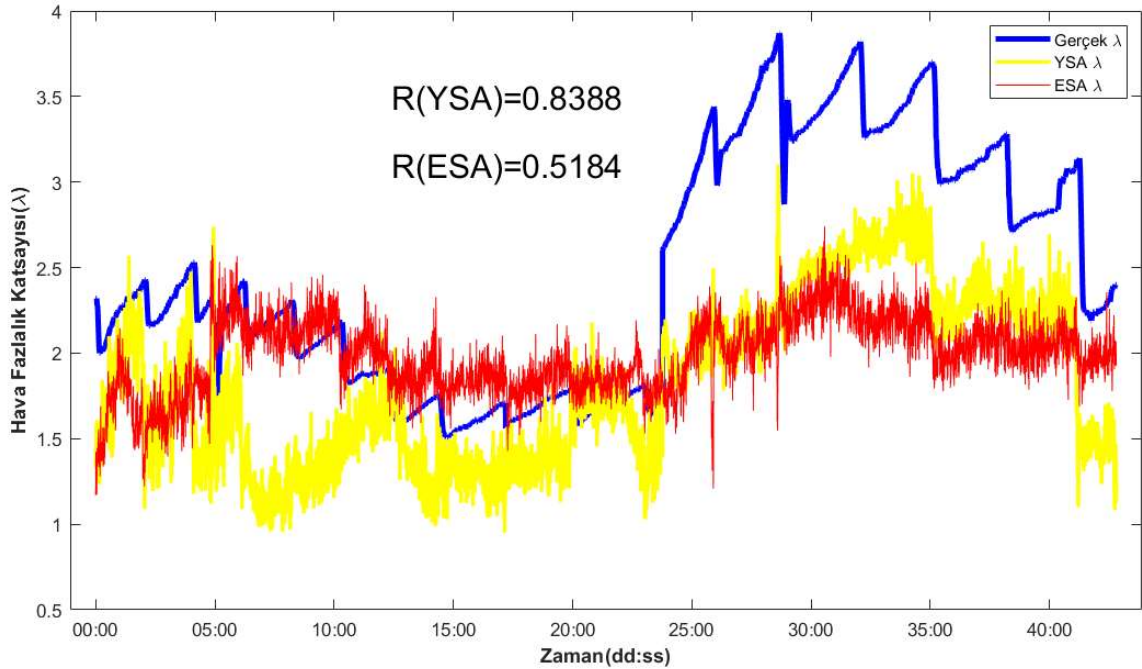
Şekil 7.10 : Veri tabanı-1 için YSA ve DGÇ modeli  $\lambda$  tahmini

DGÇ modeli, YSA modelinden daha iyi sonuç vermiştir. Şekil 7.11'de deney 10-a (YSA regresyon modeli) ve deney 10-b (DGÇ regresyon modeli) için BGA cihazından ölçülen gerçek  $\lambda$  değerleri grafiksel olarak verilmiştir. Bu deneyde regresyon modeli ile  $\lambda$  tahmini yapılmıştır. Bu tahmine göre hata işareti hesaplanıp fan kontrolü için kullanılan  $U$  Gauss kontrol işareti üretilmiştir. Gerçek zamanlı olarak kömür kazanının kontrol edildiği bu uygulama için BGA'dan ölçülen  $\lambda$  değişimi ilgili grafiklerde verilmiştir. Bu uygulama sadece kontrolcü etkisini görmek için yapılmıştır. Kontrolcü tasarımı bu tez çalışmasının dışında olup ayrıca çalışılıp geliştirilmeye müsaittir. Deneyler yapılırken bazı regresyon modelleri anlık olarak aykırı değerler ürettiği gözlemlenmiştir. Bu yüzden bu aykırı değerlerin tolere edilmesi için fan kontrol işareti üretilirken ilk 10 işaretten sonraki anlık işaret önceki 10 işaretin medyanı olarak alınmıştır. Her ne kadar en iyi iki regresyon modelinde bu durum gözlemlenmesede aykırı değerlere karşı sistemi koruyucu bir bileşen olarak sistemde tutulmuştur.



**Şekil 7.11** : Gerçek  $\lambda$  değişimi, (a) deney 10-a ve (b) deney 10-b için

Önerilen parametreler ile YSA ve ESA modelleri için deney 9-a verileri ile test edilmiştir. Modeller eğitilirken deney 2-8 verileri kullanılmıştır. Önerilen parametreler ile YSA ve ESA modelleri için deney 9-a Şekil 7.12’de verilmiştir. Bu modeller oluşturulurken ROI seçme yöntemi olarak filtreleme tekniği kullanılmıştır. Elde edilen sonuçlar islenme problemi çözüldüğünde sistemin gerçek zamanlı olarak koşabileceğini desteklemektedir.



**Şekil 7.12** : Önerilen YSA ve ESA modeller için deney 9-a için gerçek ve tahmin edilen  $\lambda$  değerleri

## 8. SONUÇLAR

Bu tez çalışmasında kazanlarda verim kontrolü için kullanılan temel parametre olan  $\lambda$ -hava fazlalık katsayısının alev görüntüsü ile tahmin edilebilmesi için yeni bir yaklaşım sunulmuştur. Sunulan deney TÜBİTAK 117M121 nolu proje kapsamında proje ortağı olan MİMSAN A.Ş. firmasının sağladığı kazan ve deney ortamında gerçekleştirilmiştir. Deney düzeneği için ihtiyaç duyulan iki kameradan aynı anda görüntü alınıp istenilen ayarlarda kaydeden, bu ayarları saklaya bilen genel bir video yakalayıcı bu tez kapsamında gerçekleştirilmiştir. Geliştirme ortamı olarak Visual Studio .Net VC++ platformu, OpenCV kütüphanesi ve DirectShow kütüphanesi kullanılmıştır. Veri temizleme, veriyi görselleştirme, veriyi senkronize etme ve öznitelik çıkarıp YSA regresyon modeli ile tahmin etme işlemi için Matlab ortamında bir kullanıcı arayüzü bu tez çalışması kapsamında gerçekleştirilmiştir.

$\lambda$  tahminine ek olarak BGS ve  $NO_x$  tahmini içinde alev görüntüsü ile tahmin işlemi yapılmıştır. BGS bazı sistemlerde  $\lambda$  gibi sistemi optimize etmek için kullanılmaktadır. Kömür yakıtlı kalorifer kazanında BGS ve alev görüntüsü arasındaki ilişki incelediğimiz kadarıyla ilk kez bu tez çalışması kapsamında incelenmiştir. BGS tahmini ilgili YSA modeli için alev görüntüsünün spektral normu kullanılarak  $R = 0,9908$  doğruluk ile bulunmuştur. Aynı şekilde ESA yaklaşımı ile BGS tahmini  $R = 0,9923$  doğruluk ile bulunmuştur.  $NO_x$  emisyonu tahmini için DVR modeli ve uzamsal yoğunluk dağılımı yaklaşımı ile  $R = 0,9522$  doğruluk ile bulunmuştur. Alev görüntüsü ile BGS tahmini çalışması literatüre kazandırıldığı gibi  $NO_x$  emisyonunun tahmini için sunulan öznitelik yaklaşımı literatürdeki diğer yaklaşımlardan üstündür.

$\lambda$  tahmini için temelde 3 çeşit deneysel çalışma yapılmıştır. Bunlardan ilki modelleme yaklaşımı ile  $\lambda$ 'nın tahmin edilmesi. İkincisi klasik öznitelik çıkarma yaklaşımı ile  $\lambda$ 'nın tahmin edilmesidir. Sonuncusu ESA yaklaşımı ile  $\lambda$ 'nın tahmin edilmesidir.

Modelleme yaklaşımı ile temelde 3 çeşit olmak üzere 8 farklı yöntemle alev görüntüsünden öznitelikler elde edilmiştir. Birinci yöntem, RGB renk uzayında ideal yanmanın belli bir bant aralığında olacağı varsayımına dayanan yöntemdir. Bu yöntemde görüntünün

ızgaralanmıştır. Bu ızgaraların her bir renk kanalının yoğunluk ortalaması alınmaktadır. Bir ızgaranın ideal yanma bölgesi olup olmamasına göre alev görüntüsü, ikili görüntüye çevrilerek regresyon modeli için öznitelikler elde edilmiştir. Bu yaklaşımda 3 farklı eşikleme yöntemi kullanılarak ikili görüntü elde edilmiştir. Her bir ikili görüntüden 10 farklı teknikle öznitelikler elde edilmiştir. Elde edilen tüm öznitelikler YSA regresyon modeli için farklı gizli katman nöron sayıları ve farklı YSA öğrenme modeli yaklaşımları için test edilmiştir. Bu yaklaşımda en iyi sonuç biaslı ikili görüntünün kullanıldığı öznitelik çıkarma yaklaşımı için  $R = 0,9391$  olarak bulunmuştur.

İkinci yöntem ideal yanma bölgesi kullanarak farklı renk kanalları için ideal yanmanın modellenmesi yaklaşımına dayanmaktadır. Bu teknikle 8 farklı renk kanalı ve RGB renk bileşenlerinin çoklu kombinasyonları için öznitelikler elde edilerek YSA regresyon modeline verilmiştir. Bu yaklaşımda da her bir renk kanalı modeli için eşik değerler kullanılarak ikili görüntüler elde edilmiştir. Bu ikili görüntülerden öznitelikler elde edilmiştir. En iyi  $\lambda$  tahmin sonucu Gr2 renk kanalı için ikili görüntünün öznitelik yöntemi olarak kullanıldığı modelde  $R = 0,9311$  olarak bulunmuştur. İdeal yanma bölgesi yaklaşımı geliştirilerek ideal yanmanın piksel boyutunda modellenmesi yaklaşımının temeli atılıp son model oluşturulmuştur.

Modelleme yaklaşımlarının üçüncü yani son yönteminde GD kullanılarak 4 farklı teknik ile alev görüntüsünün piksel yoğunlukları yerine her bir pikselin ideal yanmaya olan benzerliğinin kullanılması yaklaşımına dayanmaktadır. Bu şekilde sunulan 4 farklı teknikle elde edilen  $\lambda$ -alev görüntüsü eşleştirmesi çalışmaları sonuçlarının hepsi literatürde sunulan diğer yöntemlerden daha üstündür. En iyi sonuç R, G ve B renk kanallarının birlikte kullanıldığı ayrık benzerlik toplamı yaklaşımı için  $R = 0,9626$  olarak bulunmuştur. Bu yaklaşım hem piksel olasılıkları yöntemleri içinde hemde tüm modelleme teknikleri içinde en iyi sonucun alındığı yaklaşımdır. Kömür yakıtlı yanma işleminde gelişmiş modelleme yaklaşımı ile ideal yanmanın modellenene bileceği literatürde geçmesine rağmen incelediğimiz kadarıyla ilk kez bu tez kapsamında yapılmıştır.

$\lambda$  tahmini için en iyi sonuçların alındığı görüntü momentleri ile öznitelik elde etme yöntemi için ayrıntılı deneyler yapılmıştır. Bu kapsamda kamera türü, kamera çözünürlüğü, ideal ızgara sayısı, en anlamlı renk kanalları ve ideal YSA regresyon modeli parametreleri araştırması yapılmıştır. Bu kapsamda en ideal YSA regresyon modeli LM yöntemi için 16 adet gizli nörona sahip model olarak bulunmuştur. Öznitelik çıkarma yöntemi için ortalama

ve standart sapma kullanılmıştır. Görüntü momentleri için  $400 \times 400$  çözünürlük ve  $4 \times 4$  ızgara ideal değerler olarak bulunmuştur. İlgili model başarımı deney 2 verileri için  $R = 0,9844$  olarak bulunmuştur.  $\lambda$  tahmini için derin öğrenme yaklaşımı ile aynı veri seti ile farklı ESA modelleri geliştirilerek en uygun ESA modeli araştırılmıştır. Yeni geliştirilen ESA'lar tek renk kanalı ve çoklu renk kanalı için test edilmiştir. Fakat oluşturulan ESA'lar ön eğitilmiş ESA'lardan daha düşük sonuç vermiştir. Bu kapsamda en yüksek başarımlı Resnet101 ESA'sı için  $R = 0,9897$  olarak bulunmuştur.

NARX modelinin yüksek başarıma rağmen gerçek zamanlı uygulama için uygun olmadığı yürütülen çalışmalar sonucunda gösterilmiştir. Bunun yerine DGÇ modelinin daha uygun olabileceği gösterilmiştir.

En son aşamada gerçek zamanlı fan kontrol uygulaması ve alev görüntüsünden  $\lambda$  tahmininin yapılacağı modelin parametreleri tartışılmıştır. Bu kapsamda uygun maliyetli bir model hedeflenerek web kamerasının kullanıldığı ve gömülü bilgisayar olarak latte panda gibi fan kontrol işaretinin üretildiği bir gömülü sistem önerilmiştir. Sistem parametreleri olarak alev görüntüsünün ilk iki momenti olan ortalama ve standart sapmanın öznelik olarak kullanılması en iyi model olarak öne çıkmıştır. RGB renk uzayındaki görüntünün tüm kanallarının kullanılması önerilmiştir. YSA öğrenme modeli olarak LM yöntemi önerilmiştir. LM öğrenme yöntemi eğitim aşamasındaki dezavantajlarına rağmen daha düşük yerel pencere boyutu için daha iyi sonuç vermektedir. Yani öznelik sayısı az olmasına rağmen model daha iyi öğrenmektedir. Öznelik sayısının az olması gerçek zamanlı bir sistemde istenen bir durumdur.

Web kamera ve endüstriyel kamera ile iki tip ROI seçimi ve çözünürlüğün sistemi nasıl etkilediği araştırılmıştır. Yapılan çalışmalar sonucunda ROI seçiminde aynı deney için alev görüntüsü olmayan çevresel bileşenlerin sistem doğruluğunu etkilemediği gösterilmiştir. Fakat gerçek zamanlı bir sistemde alev görüntüsü olmayan çevresel bileşenlerin çıkarılması gerektiği sonucuna varılmıştır. Gerçek zamanlı koşacak bir sistemi gerçekleştirmek için web kamerasının yeterli olduğu ve yüksek çözünürlüğe ihtiyaç olmadığı gösterilmiştir.

En son aşamada YSA regresyon modeli, DGÇ modeli ve googlenet modeli tüm deney verileri ile eğilmiştir. Alev görüntüsünden ROI seçiminde iki yöntem bu deney kapsamında değerlendirilmiştir. Maskleme ve filtreleme yöntemlerinin yakın sonuç vermekle beraber YSA regresyon modeli için en iyi sonuç maskeleyme yönteminde, ESA modelinde ise

filtreleme yönteminde bulunmuştur. YSA regresyon modeli için öznitelik çıkarma aşamasındaki yerel pencere boyutu ve modelin gizli katmanındaki nöron sayısı belirlenmiştir. YSA regresyon modeli tüm deney verileri ile eğitilip test edildiğinde  $R = 0,9643$  olarak bulunmuştur. ESA regresyon modelinde  $R = 0,9392$  olarak bulunmuştur. YSA regresyon modelinde kullanılan ilk iki momentin etkinliği bu deneyle bir kez daha ortaya çıkarılmıştır. Çünkü ESA modelinde model daha karmaşık olup öğrenme eğilimi klasik YSA'dan çok daha fazladır. Fakat alev görüntüsünden lambda tahmini için istenilen doğruluk elde edilmemiştir. Bu da modelin anlamsız bilgileri öğrenmesiyle açıklanabilir. YSA modelinde daha az katmanlı daha sade modellerle sonuç alınması açıkça öznitelik çıkarma yönteminin etkinliğini ortaya koymuştur. Önerilen her bir renk kanalı için yerel pencerelere bölüp ilk iki momentin öznitelik olarak alınması yaklaşımının etkinliği nicel verilerle ortaya konulmuştur. Görüntü momentleri çalışmasının yerel pencere boyutu ve gizli katman nöron sayısını karar vermede yetersiz olduğu sonucuna varılarak bu deneyde optimum parametre araştırılmıştır. Nihai sistemde ROI seçme yöntemi olarak filtreleme (gerçek zamanlı uygulamada maskeleyme işleminden daha iyi sonuç vermiştir) yöntemine karar verilmiştir. Yerel pencere boyutu için 5x5 olması ve gizli katman nöron sayısının 18 olması en iyi modelin diğer parametreleridir.

Yürütülen çalışmalar sonucunda sistemi gerçekleştirmek için tek kameranın yeterli olacağı gösterilmiştir. Endüstriyel kamera kullanılarak sistem gerçekleştirilebileceği gibi web kamerasının yeterli olacağı endüstriyel kameranın pahalı bir çözüm olduğu gösterilmiştir. Kazanın baca tarafına açılan delikten görüntü alınırken (kamera -1) sorunla karşılaşmıştır. İslenme diğer tarafa göre daha çabuk ve daha yoğun olduğu gözlemlenmiştir. Bu yüzden gözetleme deliğinin bacanın olduğu taraf harici bir yere açılması daha uygundur. İslenme problemi için iki türlü çözüm vardır. Birincisi camın otomatik bir mekanizma ile temizlenmesi ikincisi gözetleme deliğinin etrafından kazanın içine doğru hava üflemdir. Hava üflenmesiyle is ve tozun cama ulaşması önlenir. Fakat her iki durumun yeni bir deney mekanizması ile test edilmesi gerekmektedir. Her ne kadar elimizde büyük bir veri olsada bu veri  $\lambda$  aralığında (0-21) homojen dağılmadığı için yetersizdir. Aynı şekilde yürütülen çalışmalar göstermiştir ki kameranın kazana sabitlenerek montaj edilmesi gerekmektedir. Buda ancak islenme problemi çözülünce yapılabilmektedir. Eğer kamera montajı yapılırsa ve islenme problemi çözülürse iki sorun ortadan kalkmış olacaktır. Birincisi islenme problemi ikincisi kamera ve yanma odası arasındaki açığı ve görüş mesafesinden kaynaklanabilecek değişik varyasyonların ortadan kalkmasıdır. Bu şekilde en

ideal açı ve görüş mesafesi için deneysel çalışmalar yapılabilecektir. Aynı şekilde gerçek zamanlı uygulamada gözlemlenen bir diğer sorun fan kapasitesinin sistemi doğrudan etkilediği görülmüştür. En ideal kontrol algoritması yapılırken mutlaka fanın kapasitesine göre kontrol algoritmasının geliştirilmesi gerekmektedir. Geçer zamanlı çalışacak bir ürünün ortaya konulması için bu eksiklikler göz önüne alınarak benzer test düzeneğiyle ilgili çalışma tekrarlanıp üretilene dönüştürülebilir.

Bu tez çalışmasında literatürdeki benzer çalışmalar değerlendirilerek  $\lambda$ -alev görüntüsü eşleştirmesi için en ideal öznitelik elde etme yaklaşımı araştırması derinlemesine yapılmıştır. Mevcut sunulan öznitelik çıkarma yaklaşımlarının zayıf yönleri değerlendirilerek yeni öznitelik çıkarma yaklaşımları sunulmuştur. Hem BGS-alev görüntüsü ilişkisi literatüre kazandırılmış hemde alev görüntüsü- $\lambda$  eşleştirmesi için literatürdeki en yüksek doğrulukla sonuç elde edilmiştir. Ayrıca araştırdığımız kadarıyla ideal yanmanın modellendiği ilk çalışma bu tez çalışması kapsamında yapılmıştır. Sistemi gerçeklemek için gerekli olan kullanıcı arayüzü, iki kamera için evrensel video yaklayıcı ve gerçek zamanlı gömülü bilgisayar uygulması gerçekleştirilmiştir. ESA yaklaşımıyla BGS ve  $\lambda$  tahmin modelleri sunulmuştur.

## KAYNAKLAR

- [1] **Conti, J., Holtberg, P., Diefenderfer, J., LaRose, A., Turnure, J. T., & Westfall, L.** (2016). *International Energy Outlook 2016 With Projections to 2040*. Washington DC.
- [2] **Munawer, M. E.** (2018). Human health and environmental impacts of coal combustion and post-combustion wastes. In *Journal of Sustainable Mining*, 17(2), pp. 87–96).
- [3] **Bilgin, A.** (2011). Kazanlarda enerji Verimliliği ve Emisyonlar. *VIII. Ulusal Tesisat Mühendisliği Kongresi*, 122, (pp. 59–65). Turkey : İzmir, October 25-28.
- [4] **Williams, A., Jones, J. M., Ma, L., & Pourkashanian, M.** (2012). Pollutants from the combustion of solid biomass fuels. In *Progress in Energy and Combustion Science* , 38(2), 113–137.
- [5] **Luo, Z., Xiang, Q., Cheng, Q., & Lou, C.** (2016). Changing Characteristics of Flame Images under Different Oxy-Fuel Atmospheres in a 3-MW Pilot-Scale Furnace. *IEEE Transactions on Instrumentation and Measurement*, 65(10), 2265–2271.
- [6] **Kobylecki, R.** (2011). Unburned carbon in the circulating fluidised bed boiler fly ash. *Chemical and Process Engineering*, 32(4), 255–266.
- [7] **Klika, Z., Bartoňová, L., & Spears, D. .** (2001). Effect of boiler output on trace element partitioning during coal combustion in two fluidised-bed power stations. *Fuel*, 80(7), 907–917.
- [8] **Roy, B.** (2014h). Oxy-fuel fluidized bed combustion using Victorian brown coal: An experimental investigation. *Fuel Processing Technology*, 117, 23–29.
- [9] **Talu, M. F., Onat, C., & Daskın, M.** (2017). Prediction of Excess Air Factor in Automatic Feed Coal Burners by Processing of Flame Images. *Chinese Journal of Mechanical Engineering*, 30(3), 722–731.
- [10] **Lee, J.-M., Kim, D.-W., & Kim, J.-S.** (2012). Unburned carbon fraction with operation variables in a commercial circulating fluidized bed boiler during co-combustion of various anthracites. *Korean Journal of Chemical Engineering*, 29(4), 452–459.
- [11] **Sun, D., Lu, G., Zhou, H., Yan, Y., & Liu, S.** (2015). Quantitative Assessment of Flame Stability Through Image Processing and Spectral Analysis. *IEEE Transactions on Instrumentation and Measurement*, 64(12), 3323–3333.
- [12] **Wang, F., Wang, X. J., Ma, Z. Y., Yan, J. H., Chi, Y., Wei, C. Y., Ni, M. J., & Cen, K. F.** (2002). The research on the estimation for the NO<sub>x</sub>emissive concentration of the pulverized coal boiler by the flame image processing technique. *Fuel*, 81(16), 2113–2120.
- [13] **Baek, W. B., Lee, S. J., Baeg, S. Y., & Cho, C. H.** (2001). Flame image processing & analysis for optimal coal firing of thermal power plant. *ISIE 2001: IEEE International Symposium on Industrial Electronics Proceeding, Vols I-III*, pp.928-931.
- [14] **Combustion Efficiency and Excess Air.** (n.d.). Retrieved October 24, 2018, from <https://www.engineeringtoolbox.com/boiler-combustion-efficiency->

- [15] **Kenneth C. Weston.** (1992). *Energy Conversion* (1st ed.). PWS Publishers.
- [16] **Lu, G., Yan, Y., Huang, Y., Reed, A., Van, Y., Huang, Y., & Reed, A.** (1999). An Intelligent Vision System for Monitoring and Control of Combustion Flames. *Measurement and Control*, 32(6), 164–168.
- [17] **Lou, C., Li, W. H., Zhou, H. C., & Salinas, C. T.** (2011). Experimental investigation on simultaneous measurement of temperature distributions and radiative properties in an oil-fired tunnel furnace by radiation analysis. *International Journal of Heat and Mass Transfer*, 54(1–3), 1–8.
- [18] **Lu, G. L. G., Stasiak, a., Shao, J. S. J., & Yan, Y. Y. Y.** (2007). Digital Imaging Based Measurement of Combustion Flame Characteristics. *2007 IEEE International Workshop on Imaging Systems and Techniques*, 5–8.
- [19] **Huang, H. W., & Zhang, Y.** (2011). Digital colour image processing based measurement of premixed CH<sub>4</sub>+ air and C<sub>2</sub>H<sub>4</sub>+ air flame chemiluminescence. *Fuel*, 90(1), 48–53.
- [20] **Golgiyaz, S., Talu, M. F., & Onat, C.** (2016). Otomatik Beslemeli Kömür Brülörleri İçin Hava Fazlalık Katsayısının Görüntü Tabanlı Gauss Modeli ile Kestirimi . *International Artificial Intelligence and Data Processing Symposium (IDAP'16)*, 528–531.
- [21] **Golgiyaz, S., Talu, M. F., & Onat, C.** (2019a). Estimation of Flue Gas Temperature by Image Processing and Machine Learning Methods. *European Journal of Science and Technology*, 283–291.
- [22] **Golgiyaz, S., Talu, M. F., & Onat, C.** (2019b). Artificial neural network regression model to predict flue gas temperature and emissions with the spectral norm of flame image. *Fuel*, 255, 115827.
- [23] **Ballester, J., & García-Armingol, T.** (2010). Diagnostic techniques for the monitoring and control of practical flames. *Progress in Energy and Combustion Science*, 36(4), 375–411.
- [24] **Gur, S., Danielson, T., Xiong, Q., Hin, C., Pannala, S., Frantziskonis, G., Savara, A., & Daw, C. S.** (2016). Wavelet-based surrogate time series for multiscale simulation of heterogeneous catalysis. *Chemical Engineering Science*, 144, 165–175.
- [25] **Liukkonen, M., Hiltunen, T., Hälikkä, E., & Hiltunen, Y.** (2011). Modeling of the fluidized bed combustion process and NO<sub>x</sub> emissions using self-organizing maps: An application to the diagnosis of process states. *Environmental Modelling & Software*, 26(5), 605–614.
- [26] **Kohse-Hö Inghaus, K., Barlow, R. S., Aldén, M., Rgen Wolfrum, J.,** (2005). Combustion at the focus: Laser diagnostics and control. *Proceedings of the Combustion Institute*, 30(1), 89–123.
- [27] **Deleo, M., Savelev, A., Kennedy, L. A., Zelepouga, S. A., De Leo, M., Savelev, A., Kennedy, L. A., & Zelepouga, S. A.** (2007). OH and CH luminescence in opposed flow methane oxy-flames. *Combustion and Flame*, 149(4), 435–447.
- [28] **Panoutsos, C. S., Hardalupas, Y., & Taylor, A. M. K. P.** (2009). Numerical evaluation of equivalence ratio measurement using OH\*and

CH\*chemiluminescence in premixed and non-premixed methane-air flames. *Combustion and Flame*, 156(2), 273–291.

- [29] **Lackner, M.** (2007). Tunable Diode Laser Absorption Spectroscopy (TDLAS) In The Process Industries – A Review. *Reviews in Chemical Engineering*, 23(2).
- [30] **Xu, L., Yan, Y., Cornwell, S., & Riley, G.** (2004). On-Line Fuel Identification Using Digital Signal Processing and Fuzzy Inference Techniques. *IEEE Transactions on Instrumentation and Measurement*, 53(4), 1316–1320.
- [31] **Ballester, J., Sanz, A., Hernandez, R., & Smolarz, A.** (2005). *Detection and [] analysis of emitted radiation for advanced monitoring and control of combustors* (R. S. Romaniuk, S. Simrock, & V. M. Lutkovski (Eds.); p. 59482H).
- [32] **Liu, H., Tan, H., Xiong, X., Ma, L., Miao, Y., & Xu, T.** (2015). Development and Application of A Coal Combustion Life Cycle On-line Monitoring System. *Energy Engineering*, 112(1), 28–46.
- [33] **Ruan, C., Chen, F., Cai, W., Qian, Y., Yu, L., & Lu, X.** (2019). Principles of non-intrusive diagnostic techniques and their applications for fundamental studies of combustion instabilities in gas turbine combustors: A brief review. In *Aerospace Science and Technology* (Vol. 84, pp. 585–603). Elsevier Masson SAS.
- [34] **Qiu, X., Duan, L., Duan, Y., Li, B., Lu, D., & Zhao, C.** (2020). Ash deposition during pressurized oxy-fuel combustion of Zhundong coal in a lab-scale fluidized bed. *Fuel Processing Technology*, 204, 106411.
- [35] **Akhmetshin, R., Nyashina, G. S., & Strizhak, P. A.** (2020). Comparative analysis of factors affecting differences in the concentrations of gaseous anthropogenic emissions from coal and slurry fuel combustion. *Fuel*, 270, 117581.
- [36] **Rodríguez, F., Tova, E., Cortés, V., & Caadas, L.** (2002). OPTICOM: Advanced automatic monitoring system of local combustion conditions for improving boiler performance in PC power plants. *Fuel*, 81(5), 637–645.
- [37] **Heitor, M. V., & Moreira, A. L. N.** (1993). Thermocouples and sample probes for combustion studies. *Progress in Energy and Combustion Science*, 19(3), 259–278.
- [38] **Hansen, N., Cool, T. A., Westmoreland, P. R., & Kohse-Höinghaus, K.** (2009). Recent contributions of flame-sampling molecular-beam mass spectrometry to a fundamental understanding of combustion chemistry. In *Progress in Energy and Combustion Science* (Vol. 35, Issue 2, pp. 168–191). Pergamon.
- [39] **Yoshiie, R., Hikosaka, N., Nunome, Y., Ueki, Y., & Naruse, I.** (2015). Effects of flue gas re-circulation and nitrogen contents in coal on NOX emissions under oxy-fuel coal combustion. *Fuel Processing Technology*, 136, 106–111.
- [40] **Zhao, S., Pudasainee, D., Duan, Y., Gupta, R., Liu, M., & Lu, J.** (2019). A review on mercury in coal combustion process: Content and occurrence forms in coal, transformation, sampling methods, emission and control technologies. *Progress in Energy and Combustion Science*, 73, 26–64.
- [41] **Docquier, N., & Candel, S.** (2002). Combustion control and sensors: A review. *Progress in Energy and Combustion Science*, 28(2), 107–150.

- [42] **González-Cencerrado, A., Peña, B., & Gil, A.** (2012). Coal flame characterization by means of digital image processing in a semi-industrial scale PF swirl burner. *Applied Energy*, *94*, 375–384.
- [43] **González-Cencerrado, A., Gil, A., & Peña, B.** (2013). Characterization of PF flames under different swirl conditions based on visualization systems. *Fuel*, *113*, 798–809.
- [44] **Xiangyu, Z., Shu, Z., Huaichun, Z., Bo, Z., Huajian, W., & Hongjie, X.** (2016). Simultaneously reconstruction of inhomogeneous temperature and radiative properties by radiation image processing. *International Journal of Thermal Sciences*, *107*, 121–130.
- [45] **Huang, B., Luo, Z., & Zhou, H.** (2010). Optimization of combustion based on introducing radiant energy signal in pulverized coal-fired boiler. *Fuel Processing Technology*, *91*(6), 660–668.
- [46] **Zheng, S., Luo, Z., Deng, Y., & Zhou, H.** (2014). Development of a distributed-parameter model for the evaporation system in a supercritical W-shaped boiler. *Applied Thermal Engineering*, *62*(1), 123–132.
- [47] **Tóth, P., Garami, A., & Csordás, B.** (2017). Image-based deep neural network prediction of the heat output of a step-grate biomass boiler. *Applied Energy*, *200*, 155–169.
- [48] **Li, N., Lu, G., Li, X., & Yan, Y.** (2014). Prediction of pollutant emissions of biomass flames using digital imaging, contourlet transform and Radial Basis Function network techniques. *Conference Record - IEEE Instrumentation and Measurement Technology Conference*, 697–700.
- [49] **Li, X., Sun, D., Lu, G., Krabicka, J., & Yan, Y.** (2012). Prediction of NO<sub>x</sub> emissions through flame radical imaging and neural network based soft computing. *IST 2012 - 2012 IEEE International Conference on Imaging Systems and Techniques, Proceedings*, *44*(0), 502–505.
- [50] **Li, N., Lu, G., Li, X., & Yan, Y.** (2016). Prediction of NO<sub>x</sub> Emissions from a Biomass Fired Combustion Process Based on Flame Radical Imaging and Deep Learning Techniques. *Combustion Science and Technology*, *188*(2), 233–246.
- [51] **Li, N., Lu, G., Li, X., & Yan, Y.** (2015). Prediction of Pollutant Emissions of Biomass Flames Through Digital Imaging, Contourlet Transform, and Support Vector Regression Modeling. *IEEE Transactions on Instrumentation and Measurement*, *64*(9), 2409–2416.
- [52] **Bonefacic, I., Blecich, P., Bonefačić, I., & Blecich, -P.** (2015). Two-color temperature measurement method using BPW34 PIN photodiodes. In *Engineering Review*, *35*, pp. 259-266.
- [53] **Kuhn, P. B., Ma, B., Connelly, B. C., Smooke, M. D., & Long, M. B.** (2011). Soot and thin-filament pyrometry using a color digital camera. *Proceedings of the Combustion Institute*, *33*(1), 743–750.
- [54] **Xiangyu, Z., Xu, L., Yu, Y., Bo, Z., & Hongjie, X.** (2018). Temperature measurement of coal fired flame in the cement kiln by raw image processing. *Measurement: Journal of the International Measurement Confederation*.
- [55] **Tang, Q., Zhou, H., Lu, G., Yan, Y., & Li, Y.** (2017). Combining flame monitoring

techniques and support vector machine for the online identification of coal blends. *Journal of Zhejiang University-SCIENCE A*, 671–689.

- [56] Li, T., Zhang, C., Yuan, Y., Shuai, Y., & Tan, H. (2018). Flame temperature estimation from light field image processing. *Applied Optics*, 57(25), 7259.
- [57] Lou, C., Zhou, H. C., Yu, P. F., & Jiang, Z. W. (2007). Measurements of the flame emissivity and radiative properties of particulate medium in pulverized-coal-fired boiler furnaces by image processing of visible radiation. *Proceedings of the Combustion Institute*, 31 II, 2771–2778.
- [58] Liu, Z., Zheng, S., Luo, Z., & Zhou, H. (2016). A new method for constructing radiative energy signal in a coal-fired boiler. *Applied Thermal Engineering*, 101, 446–454.
- [59] Aldén, M., Bood, J., Li, Z., & Richter, M. (2011). Visualization and understanding of combustion processes using spatially and temporally resolved laser diagnostic techniques. *Proceedings of the Combustion Institute*, 33(1), 69–97.
- [60] Zhou, H., Tang, Q., Yang, L., Yan, Y., Lu, G., & Cen, K. (2014). Support vector machine based online coal identification through advanced flame monitoring. *Fuel*, 117(PARTB), 944–951.
- [61] Horng, W.-B., Peng, J.-W. & Chen, C.-Y. (2005). A new image-based real-time flame detection method using color analysis. *Proceedings. 2005 IEEE Networking, Sensing and Control*, 100–105.
- [62] Chen, J., & Bao, Q. (2012). Digital image processing based fire flame color and oscillation frequency analysis. *Procedia Engineering*, 45, 595–601.
- [63] Sujatha, K. (2011) *Image Processing For Flame Monitorini In Power Station Boilers* (Doctoral dissertation). Retrieved from <https://shodhganga.inflibnet.ac.in/handle/10603/13803>
- [64] Lu, G., Zhou, H., Li, X., & Yan, Y. (2013). A simple index based quantitative assessment of flame stability. *IST 2013 - 2013 IEEE International Conference on Imaging Systems and Techniques, Proceedings*, 44(0), 190–193.
- [65] Jiang, Z.-W. W., Luo, Z.-X. X., & Zhou, H.-C. C. (2009). A simple measurement method of temperature and emissivity of coal-fired flames from visible radiation image and its application in a CFB boiler furnace. *Fuel*, 88, 980–987.
- [66] Chen, J., Chang, Y. H., Cheng, Y. C., & Hsu, C. K. (2012). Design of image-based control loops for industrial combustion processes. *Applied Energy*, 94, 13–21.
- [67] Zhou, Z., Tian, D., Wu, Z., Bian, Z., & Wu, W. (2015). 3-D Reconstruction of Flame Temperature Distribution Using Tomographic and Two-Color Pyrometric Techniques. *IEEE Transactions on Instrumentation and Measurement*, 64(11), 3075–3084.
- [68] Sujatha, K., & Pappa, N. (2011). Combustion monitoring of a water tube boiler using a discriminant radial basis network. *ISA Transactions*, 50(1), 101–110.
- [69] Büchner, D., Schraube, C., Carlon, E., von Sonntag, J., Schwarz, M., Verma, V. K., & Ortwein, A. (2015). Survey of modern pellet boilers in Austria and

Germany - System design and customer satisfaction of residential installations. *Applied Energy*, 160, 390–403.

- [70] **Hernández, R., & Ballester, J.** (2008). Flame imaging as a diagnostic tool for industrial combustion. *Combustion and Flame*, 155(3), 509–528.
- [71] **Dean, J. A.** (1960). *Flame photometry*. McGraw-Hill series in advanced chemistry.
- [72] **González-Cencerrado, A., Peña, B., & Gil, A.** (2015). Experimental analysis of biomass co-firing flames in a pulverized fuel swirl burner using a CCD based visualization system. *Fuel Processing Technology*, 130(C), 299–310.
- [73] **Chen, J., Hsu, T. Y., Chen, C. C., & Cheng, Y. C.** (2010). Monitoring combustion systems using HMM probabilistic reasoning in dynamic flame images. *Applied Energy*, 87(7), 2169–2179.
- [74] **Chen, J., Chan, L. L. T., & Cheng, Y. C.** (2013). Gaussian process regression based optimal design of combustion systems using flame images. *Applied Energy*, 111, 153–160.
- [75] **Testo 350 - baca gası analiz sistemi için analizör ünitesi** (n. d.). Retrieved May 9, 2019, from <https://www.testo.com/tr-TR/testo-350/p/0632-3510>
- [76] **Doyle, B. W.** (2003). *Combustion Source Evaluation, Student Manual Air Pollution Training Institute, Course 427* (I. Ltd. (Ed.); Third).
- [77] **Testo 350 Brochure.** (2016). Testo Inc., New Jersey, USA. Retrieved from <https://www.testo350.com/downloads/350/literature-manuals/1-testo-350-brochure.pdf>
- [78] **Basler ace aca1600-20uc - Area Scan Camera.** (n. d.). Retrieved September 30, 2019, from <https://www.baslerweb.com/en/products/cameras/area-scan-cameras/ace/aca1600-20uc/>
- [79] **Microsoft LifeCam Studio - Vatan Bilgisayar.** (n. d.). Retrieved September 30, 2019, from <https://www.vatanbilgisayar.com/microsoft-lifecam-studio-7552.html#genel-bakis>
- [80] **Logitech - HD Webcam C310.** (n. d.). Retrieved September 30, 2019, from <https://www.logitech.com/tr-tr/product/hd-webcam-c310#specification-tabular>
- [81] **Hanbay, K., Golgiyaz, S., & Talu, M. F.** (2017). Real time fabric defect detection system on Matlab and C++/Opencv platforms. *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–8.
- [82] **Late Panda - Windows 10.** (). Retrieved September 30, 2019, from <https://kaketayo.net/latte-panda/>
- [83] **Itu-r(Recommendation Sector of ITU).** (2017). *Studio encoding parameters of digital television for standard 4:3 and wide-screen 16:9 aspect ratios BT Series Broadcasting service.* Retrieved from <http://www.itu.int/ITU-R/go/patents/en>
- [84] **George Casella, R. L. B.** (2001). *Statistical Inference* (2nd editio). Cengage Learning.
- [85] **McLachlan, G., & Peel, D.** (2000). *Finite Mixture Models*. John Wiley & Sons, Inc.
- [86] **Haralick, R. M., Shanmugam, K., & Dinstein, I.** (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-

3(6), 610–621.

- [87] Luo, Z., Wang, F., Zhou, H., Liu, R., Li, W., & Chang, G. (2011). Principles of optimization of combustion by radiant energy signal and its application in a 660 MWe down- and coal-fired boiler. *Korean Journal of Chemical Engineering*, 28(12), 2336–2343.
- [88] Moghaddasi, M. R., & Noorian-Bidgoli, M. (2018). ICA-ANN, ANN and multiple regression models for prediction of surface settlement caused by tunneling. *Tunnelling and Underground Space Technology*, 79, 197–209.
- [89] Shi, H. (2012). Combining Support Vector Regression and Kernel Principal Component Analysis to Monitor NO<sub>x</sub> Emissions in Coal-Fired Utility Boiler. *2012 Asia-Pacific Power and Energy Engineering Conference*, pp.1–4.
- [90] Jiang, W., Xing, X., Zhang, X., & Mi, M. (2019). Prediction of combustion activation energy of NaOH/KOH catalyzed straw pyrolytic carbon based on machine learning. *Renewable Energy*, 130, 1216–1225.
- [91] Qi, M., Luo, H., Wei, P., & Fu, Z. (2018). Estimation of low calorific value of blended coals based on support vector regression and sensitivity analysis in coal-fired power plants. *Fuel*, 236, 1400–1407.
- [92] Parveen, N., Zaidi, S., & Danish, M. (2017). Development of SVR-based model and comparative analysis with MLR and ANN models for predicting the sorption capacity of Cr(VI). *Process Safety and Environmental Protection*, 107, 428–437.
- [93] Quej, V. H., Almorox, J., Arnaldo, J. A., & Saito, L. (2017). ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. *Journal of Atmospheric and Solar-Terrestrial Physics*, 155, 62–70.
- [94] Wu, F., Zhou, H., Ren, T., Zheng, L., & Cen, K. (2009). Combining support vector regression and cellular genetic algorithm for multi-objective optimization of coal-fired utility boilers. *Fuel*, 88, 1864–1870.
- [95] Vapnik, V. N. (2000). *The nature of statistical learning theory*. Springer.
- [96] **Shallow Neural Network Time-Series Prediction and Modeling - MATLAB & Simulink.** (n. d.) Retrieved October 17, 2019, from <https://www.mathworks.com/help/deeplearning/gs/neural-network-time-series-prediction-and-modeling.html;jsessionid=93306317ca2292b7cd6165dcb592>
- [97] Hubel, D. H., & Wiesel, T. N. (1959). Receptive fields of single neurones in the cat's striate cortex. *The Journal of Physiology*, 148(3), 574–591.
- [98] Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. In *Massachusetts: The MIT Press* (1st ed.). Massachusetts: The MIT Press.
- [99] **Pretrained Deep Neural Networks - MATLAB & Simulink.** (n. d.). Retrieved April 3, 2020, from <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>
- [100] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision*

and Pattern Recognition, 07-12-June, 1–9.

- [101] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- [102] **Zhang, X., Zhou, X., Lin, M., & Sun, J.** (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6848–6856.
- [103] **Keras Documentation.** (n. d.). Retrieved April 4, 2020, from <https://keras.io/applications/#resnet50>
- [104] **KaimingHe/deep-residual-networks: Deep Residual Learning for Image Recognition.** (n. d.). Retrieved April 4, 2020, from <https://github.com/KaimingHe/deep-residual-networks>
- [105] **ImageNet.** (n. d.). Retrieved April 3, 2020, from <http://www.image-net.org/>
- [106] **Places: A 10 million Image Database for Scene Recognition.** (n. d.). Retrieved April 3, 2020, from <http://places2.csail.mit.edu/>
- [107] **Zhou, B., Khosla, A., Lapedriza, A., Torralba, A., & Oliva, A.** (2016). Places: An Image Database for Deep Scene Understanding. *Journal of Vision*, 17(10), 296. <http://arxiv.org/abs/1610.02055>
- [108] **Firildak, K., & TALU, M. F.** (2019). Evriřimsel Sinir Ađlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi Investigation of Transfer Learning Approaches Used Convolution Neural Networks. *Anatolian Journal of Computer Science*, 4(5), 88–95.
- [109] **Pratt, L. Y.** (1993). Discriminability-Based Transfer between Neural Networks. *Advances in Neural Information Processing Systems*, 204–211.
- [110] **Torrey, L., & Shavlik, J. ()**. Transfer Learning. In *Handbook of Research on Machine Learning Applications and Trends* (pp. 242–264). IGI Global.
- [111] **Zhou, H., Lou, X.S.,** Model establishment of fuel controlled objective in utility boilers based on signal of radiation energy form furnaces and simulation on its control, *Proceedings of Chinese Society for Electrical Engineering*, 16.
- [112] **Ögren, Y., Tóth, P., Garami, A., Sepman, A., & Wiinikka, H.** (2018). Development of a vision-based soft sensor for estimating equivalence ratio and major species concentration in entrained flow biomass gasification reactors. *Applied Energy*, 226(June), 450–460.
- [113] **Convert Classification Network into Regression Network - MATLAB & Simulink.** (n. d.). Retrieved April 13, 2020, from <https://www.mathworks.com/help/deeplearning/ug/convert-classification-network-into-regression-network.html>
- [114] **The U.S. Energy Information Administration (EIA).** (2018). *Annual Energy Outlook 2018 with projections to 2050*. Retrieved from [https://www.eia.gov/outlooks/aeo/pdf/0383\(2017\).pdf%5Chttp://www.eia.gov/outlooks/aeo/pdf/0383\(2017\).pdf](https://www.eia.gov/outlooks/aeo/pdf/0383(2017).pdf%5Chttp://www.eia.gov/outlooks/aeo/pdf/0383(2017).pdf)
- [115] **International Energy Agency (IEA).** (2018). World Energy Balances 2018. In *Word*

*Energy Balances 2018 (World Energy Balances)*. OECD.

- [116] **Turkey: the voice of coal in Europe**. (n. d.). Retrieved August 2, 2019, from <https://euracoal.eu/info/country-profiles/turkey/>
- [117] **The U.S. Energy Information Administration (EIA)**. (2019). *Annual Energy Outlook 2019 with projections to 2050*. Retrieved from [www.eia.gov/aeo](http://www.eia.gov/aeo)
- [118] **International Energy Agency (IEA)**. (2018). *Energy Efficiency 2018*. In *International Energy Agency*. OECD.




## EKLER

### EK A. Geçmiş ve Gelecek Perspektifinde Dünya ve Türkiye’de Kömür

Yenilenebilir enerji kaynakları ve alternatif yakıt teknolojilerine olan ilginin artmasından dolayı kömür yakıtlı kazan teknolojileri üzerinde çalışılmasının ne kadar mantıklı olduğu sorusunu akla getirebilmektedir. Ülkemiz ve dünyadaki durum değerlendirelerek bu sorunun cevabı verilebilir.

Kömür ülkemiz gibi geniş kömür yatakları bulunan birçok ülke için önemli bir enerji kaynağı olmaktadır. Gelecekte de enerji ihtiyacının giderilmesi ve enerji güvenliği açısından önemini korumaya devam edecektir. Şekil 10.1’de enerji kaynağına göre dünya enerji tüketimi ve bölgelere göre kömür tüketimi verilmiştir [1]. Kömür 2030 yılına kadar petrol ve diğer sıvı yakıtların ardından, dünya çapında en büyük ikinci enerji kaynağı olmaya devam edecektir. Kömür, 2030’dan 2040’a kadar, sıvı yakıtlar ve doğal gazın arkasından üçüncü en büyük enerji kaynağı olmaya devam edecektir. 2012–40 projeksiyon dönemi boyunca, OECD (Ekonomik İş birliği ve Kalkınma Örgütü) üyesi olmayan ülkelerdeki toplam kömür tüketimi ortalama olarak artmaktadır. Projeksiyon boyunca, en çok kömür tüketen üç ülke Çin, ABD (Amerika Birleşik Devletleri) ve Hindistan’dır. Bu ülkeler dünya kömür kullanımının %70’inden fazlasını oluşturmaktadır. Çin’de kömür tüketimi 2012’den 2040’a kadar pek değişmezken, Hindistan’da ve OECD olmayan Asya’nın diğer ülkelerinde kömür kullanımı artmaya devam edecektir. Kömür, petrol ve diğer sıvı yakıtların kullanımının arttığı 2030 yılına kadar OECD dışı bölgelerde tüketilen en büyük enerji kaynağıdır [1].


Sektörlere göre enerji tüketimi ve en büyük payı alan elektrik enerjisi üretimi sektöründe ilgili yakıtlardan net elektrik üretimi Şekil 10.2’de verilmiştir.



**Şekil A.1 :** Enerji kaynağına göre dünya enerji tüketimi (a) ve bölgelere göre dünya kömür tüketimi (b) (Noktalı çizgi ile belirtilende ABD, TEP dahil verileri ifade etmektedir), 1990–2040(Katrilyon Btu - İngiliz ısı birimi (British thermal units)) [1]


Hemen hemen her sektörde 2050 yılına kadar enerji ihtiyacında artış olacaktır. TEP’e (Temiz Enerji Politikaları) rağmen kömürün elektrik üretimindeki payı gelecek öngörülerinde

azalmasına rağmen önemini korumaya devam edecektir. 2050 yılında bile kömürün birçok ülke için önemli ve stratejik bir enerji kaynağı olmaya devam edeceği söylenebilir. Küresel ısınma ile mücadele politikalarının kömürün daha az tüketilmesi ile ilgili baskısı ve yenilenebilir enerji sektöründeki büyümeye rağmen kömür gelecekte de önemli bir enerji kaynağı olmaya devam edecektir. Özellikle gelişmekte olan ülkeler açısından kömürden üretilen enerjinin artırılması için politikalar izleneceği öngörülmektedir [114].



**Şekil A.2 :** Sektörlere göre enerji tüketimi - Katrilyon Btu (a) ve ilgili yakıtlardan net elektrik üretimi - milyar kilovat saat (b) (Noktalı çizgi ile belirtilende ABD'nin TEP dahil verileri ifade etmektedir), 1990–2050 [114]


Ülkemiz kömür madeni açısından zengin bir ülke olarak kabul edilebilir. Şekil 10.3'te Türkiye için kaynağa göre TBK (Toplam Birincil Enerji Kaynakları) ktep (kilo ton eşdeğer petrol) cinsinden verilmiştir [115].



**Şekil A.3 :** 1990-2016 yılları arasında Türkiye için TBK [115]

OECD Avrupa'da, 2016 yılında TBEK %0,6 büyürken 2017 yılında TBEK %1,7 artmıştır. TBEK'teki bu büyümenin büyük kısmı Türkiye (%8, 11000 ktep) ve İspanya kaynaklıdır [115]. Şekil 10.3'te görüldüğü gibi kömür, Türkiye için yerli enerji kaynağı arasındaki payı açısından değerli bir enerji kaynağıdır. Dolayısıyla kömürün yakılmasıyla oluşan emisyonların azaltılması yani çevreye olan negatif etkilerinin en aza indirilmesi de ülkemiz için o derece önemli olmaktadır.


Dünyada kimyasal özelliklerine göre yakma işlemlerinde kullanılan birçok kömür çeşidi vardır. En yaygın olarak kullanılanlar antrasit, bitümlü, alt bitümlü ve linyittir. Şekil 10.4'te ülkemiz için türüne göre kömür üretimi kt (kilo ton) cinsinden verilmiştir.




**Şekil A.4 :** Ülkemiz için türüne göre kömür üretimi kt (kilo ton) [115]

Türkiye'nin yerli enerji kaynakları büyük çoğunluğu linyit ve az miktarda taşkömürü içermektedir. Kömür ithalatı ile birlikte, kömür ve linyit TBEK'in %27,3'ünü karşılamıştır. %99'u ithal edilen doğal gaz TBEK'in %30,2'sini karşılamıştır. %89'u ithal edilen petrol 2015 yılında TBEK'in %30,1'ini karşılamıştır. Türkiye, sınırlı petrol ve gaz kaynaklarının aksine, büyük kömür kaynaklarına sahiptir. Türkiye kömür sektörü, 2015 yılında 1,5 milyon ton taş kömürü ve 41,8 milyon ton linyit üretmiştir. Kömür ithalatı 2005'ten bu yana ikiye katlanmış ve 2015 yılında 31,5 milyon ton olarak gerçekleşmiştir. Kömür çoğunlukla enerji üretimi için kullanılmıştır [116].

Sektörlere göre enerji kaynaklı  $CO_2$  emisyonu Şekil 10.5'te verilmiştir. Gelecek perspektifinde bile mesken kaynaklı  $CO_2$  emisyonu yüksek olmaktadır. Bu durum açıkça mevcut verimli enerji teknolojilerinin hana kullanımı için uygun olmadığını göstermektedir. Verimli enerji teknolojilerinin hanelerde kullanılacak seviyede ekonomik ve kolay uygulanabilir olması için gelecekte de çalışmaların yapılacağını göstermektedir.



(a)



(b)

**Şekil A.5 :** Sektörlere göre enerji kaynaklı  $CO_2$  emisyonları [114] - milyar ton  $CO_2$  (a) ve son kullanım sektörüne göre  $CO_2$  yoğunluğu [117] – her milyar Btu başına metrik ton  $CO_2$  (b)

Kömür ile enerji üretiminde verimlilik kontrolü çok elzem bir konu olmaktadır. Genel olarak enerji verimliliğini artırmaya yönelik fırsatları değerlendirmek son derece uygun maliyetli olacaktır. Dünyadaki araçları, binaları ve ekipmanları daha verimli hale getirmek için harcanan her bir dolar, ortalama üç kat daha düşük yakıt faturaları olarak geri dönüş yapar [118]. Enerji verimliliği iyileştirmelerinin getirdiği enerji tasarrufu, daha düşük sera gazı emisyonları ve daha az hava kirliliği olarak çevreye olumlu etki edecektir. Enerjinin daha efektif olarak elde edilince, enerji ihtiyacı için azalan harcamalar yoluyla hane halkı satın alma gücü artacaktır. Efektif enerji elde edilmesiyle enerji ithalat azaltılarak enerji güvenliği artırılır ve modern enerji hizmetlerine erişim gibi çeşitli faydalar sağlar [118].

## EK B. BGA Cihazı İçin Teknik Bilgiler

Çizelge B.1 : BGA cihazı için teknik bilgiler [75]

|                                   |               |  |
|-----------------------------------|---------------|--|
| Sıcaklık                          | Ölçüm Aralığı | 0 / +1760 °C   |
|                                   | Doğruluk      | ±1 °C (0 / +1760 °C)   |
|                                   | Hassasiyet    | 0,1 °C (0 / +1760 °C)  |
| O <sub>2</sub>                    | Ölçüm Aralığı | 0 / +25  |
|                                   | Doğruluk      | ±0,8 % Ölçülen değer (0 / +25)   |
|                                   | Hassasiyet    | 0,01 % Hacim (0 / +25)   |
| CO –Düşük                         | Ölçüm Aralığı | 0 / 500 ppm  |
|                                   | Doğruluk      | ±5 % Ölçülen değer (+40 / +500 ppm)<br>±2 ppm (0 / +39,9 ppm)                                      |
|                                   | Hassasiyet    | ±0,1 ppm (0 / +500 ppm)  |
| NO-Düşük                          | Ölçüm Aralığı | 0 / 300 ppm  |
|                                   | Doğruluk      | ±5 % Ölçülen değer (+40 / +300 ppm)<br>±2 ppm (0 / +39,9 ppm)                                      |
|                                   | Hassasiyet    | ±0,1 ppm (0 / +300 ppm)  |
| NO <sub>2</sub>                   | Ölçüm Aralığı | 0 / 500 ppm  |
|                                   | Doğruluk      | ±5 % Ölçülen değer (+100 / +500 ppm)<br>±5 ppm (0 / +99,9 ppm)                                     |
|                                   | Hassasiyet    | ±0,1 ppm (0 / +500 ppm)  |
| SO <sub>2</sub>                   | Ölçüm Aralığı | 0 / 500 ppm  |
|                                   | Doğruluk      | ±5 % Ölç. değer (+100 / +2000 ppm)<br>±10 % Ölç. değer (+2001 / +5000 ppm)<br>±5 ppm (0 / +99 ppm) |
|                                   | Hassasiyet    | ±0,1 ppm (0 / +5000 ppm)   |
| CO <sub>2</sub> – Kıızıl Ötesi    | Ölçüm Aralığı | 0 / +50 Hacim  |
|                                   | Doğruluk      | ±0,3 % hacim + 1% ölç. değ.(0 / +25 %)<br>±0,5 % hacim + 1,5% ölç. değ.(25 / +50 %)                |
|                                   | Hassasiyet    | ±0,01 % hacim (0 / +25 % hacim)<br>±0,5 % hacim (>25 % hacim)                                      |
| Çalışma Sıcaklığı                 |               | -5 / +45   |
| Batarya Ömrü                      |               | 5 saat   |
| Saklanma Sıcaklığı                |               | -20 / 50   |
| Maksimum Negatif Basınç/Baca gazı |               | -300 mbar  |
| Maksimum Pozitif Basınç/Baca gazı |               | 50 mbar  |

## EK C. Geliştirilen Kullanıcı Arayüzü Yazılımları


Yürütülen tez çalışması için ilk olarak Visual Studio .Net C# ortamında bir kullanıcı arayüzü hazırlanmıştır. Bu arayüz ilk geliştirilen arayüz olup ideal yanmanın RGB renk uzayında ideal yanma rengine (tek nokta) ile temsil edildiği varsayımına dayanılarak geliştirilmiştir. Projenin nihai hedefi olarak her ne kadar gömülü bilgisayarda koşabilecek bir yazılım hedeflenmiş olsada ar-ge aşamasında C++ yerine Matlab programının kullanılmasına karar verilmiştir. Kazandan elde edilen görüntü ve  $\lambda$  değerleri arasındaki ilişkinin ortaya çıkarılabilmesi için kullanıcı dostu bir yazılım ortamı sağlayan Matlab 2018b kullanılmıştır. Verilerin okunması, özneliklerinin çıkarılması, öznelik- $\lambda$  eşleşmesini yapan, öğrenme mimarisinin eğitim/test faaliyetlerinde Matlab'ın görüntü işleme ve yapay öğrenme araç kitleri kullanılmıştır. Sistem mimarisinin bu ortamda olgunlaşmasından sonra gerçek zamanlı gömülü kart versiyonu Visual Studio .Net C++ platformu ve OpenCV kütüphanesi aracılığıyla gerçekleştirilmiştir. Bu son uygulamada gerçek zamanlı olarak Latte Panda gömülü bilgisayarda koşabilen anlık olarak aldığı kamera görüntüsünden  $\lambda$  tahmini yapılmıştır. Bu kısımda kısaca bu programlar tanıtılmıştır.

### C1 Microsoft C# .Net Kullanıcı Arayüzü


Microsoft C# .Net yazılım geliştirme platformu kullanıcı etkileşimli uygulamaların geliştirilmesi için birçok hazır araç sunan gelişmiş bir platformdur. Bu platform kullanılarak RGB renk uzayında ideal yanmanın modellenmesi yaklaşımına dayanarak alev görüntülerinden  $\lambda$  tahmini için uygun özneliklerin elde edilmesi için bir kullanıcı arayüzü geliştirilmiştir. Kazan üzerinde açılan gözetleme deliğinden elde edilen görüntülerde alev ait olmayan bölgelerin değerlendirmeye alınmaması için kullanıcının alev bölgesini belirleyebilmektedir. Gözetleme deliği dairesel açıldığı için kamera çözünürlüğünden bağımsız olarak her ihtimalde seçim bölgesi kare olacaktır. C#.Net ortamında geliştirilen bu programın arayüzü Şekil 10.6'da gösterilmektedir.

Şekil 10.6'daki (a) ve (b) görüntülerindeki okla işaretlenmiş 1'den 11'e kadar olan ilgili işaretli bölgeler sırasıyla açıklanacaktır.

1. Alev görüntülerinin olduğu çalışma klasörünün yolu belirlenir.
2. Alev bölgesi (ROI- Region of Interest/İlgilenilen Bölge) kullanıcı tarafından belirlenebilmektedir. Ön kabul olarak tüm görüntünün içine bir daire çizilerek ROI bu daire içi kabul edilir. Fakat gerçekte dairenin merkezi ve çapı farklı olabilmektedir. Kullanıcı ilgili alanlara yatayda ve düşeyde merkezin ne kadar öteleneyeceğini ve daire yarıçapının ne kadar değişeceğini metin kutularına girerek belirlemektedir.
3. Görüntünün yatayda ve dikeyde kaç parçaya bölüneceği belirtilir.
4. Tasarlanan program üç farklı yöntem ile öznelik çıkarmaktadır. Bu yöntemlerin eşik değeri ilgili alanlara girilerek belirlenmektedir.
5. Hangi öznelik çıkarma yönteminin kullanılacağını belirtmek için kullanılmaktadır.



(a)



(b)

**Şekil C.6 :** Geliştirilen C# programı ve alev bölgesinin kullanıcı tarafından belirlenmesi

6. Bu butona tıklanınca çalışma klasöründeki ilk görüntü ekrana gelip kullanıcının belirlediği parametrelere göre görüntüye daire çizilmektedir. Bu şekilde dairenin merkezi ve yarıçapı görülüp düzenlenmektedir.
7. Ekranda gösterilen görüntünün ilk halini yani ızgaralanmamış ve daire çizilmemiş halinin gösterilip gösterilmeyeceği seçeneği için kullanılmaktadır.
8. Ekranda gösterilen görüntünün tam yolunu göstermektedir.
9. Kaydırma butonu aracılığı ile çalışılacak dosya değiştirilebilir.
10. Üzerinde çalışılacak görüntü çift tıklama ile seçilir. Seçilen eşik yöntemi ve eşik değerine göre ilgili görüntü için ideal yanma (kırmızı) ve ideal olmayan yanma


(yeşil) olmak üzere daire içindeki ızgaralar boyanır. Bu şekilde kullanıcının eşik değeri belirlemede fikir sahibi olması sağlanır.

11. Seçilen eşik yöntemine göre öznelikler çıkarılıp bir metin dosyasına kaydedilir.

## C2 Matlab Kullanıcı Arayüzü

Tez çalışmaları yürütülürken veri senkronizasyonu ve alev görüntüsünden öznelik çıkarıp bu özneliklerle YSA regresyon modelinin eğitilmesi için kullanıcı dostu bir arayüzü geliştirilmesine karar verilmiştir. Matlab uygulaması ilk başta C# programına benzer inşa edilmiştir. İlk yapılan çalışma tek bir görüntüyle modelleme yaklaşımına dayanmaktadır. Bu çalışmanın kullanıcı dostu olması hedeflenerek kullanıcı ara yüzüne ilaveler yapılmıştır. Bu arayüzle alev görüntüleri ile  $\lambda$  değeri için kullanıcının belirleyeceği şekilde veri senkronizasyonunu destekleyen bir program tasarlanmıştır. Şekil 10.7’de ilgili programın ekran görüntüsü verilmiştir.


BGA cihazının verileri daha önce bahsedildiği gibi ilgili firmanın sağladığı yazılım kullanılarak kişisel bilgisayara USB bağlantısı ile alınmakta ve Excel dosyası olarak kaydedilmektedir. Benzer şekilde kamera ile alınan görüntülerde aynı bilgisayara kaydedilmektedir. Şekil 10.7’de veri hazırlama (“A”), öznelik elde etme (“B”) ve regresyon (“C”) olmak üzere 3 kısımdan oluşan kullanıcı ara yüzünden kısaca bahsedilecektir.



Şekil C.7 : Kullanıcı ara yüzü için “Veri Hazırlama” sekmesi

“A” sekmesi “Veri Hazırlama” kısmını ve programın ilk sekmesini ifade etmektedir. Bu sekmede 1-7 okları ile gösterilen alanlar, “D-E” sekmeleri ve “D” sekmesinin altında bulunan F-H sekmeleri bulunmaktadır. İlgili alanlar kısaca anlatılacaktır.


1. Nolu buton BGA cihazının verilerinin bulunduğu yeri belirtmek için kullanılmaktadır. İlgili buton tıklanınca “.xlsx” uzantılı dosya seçmemize izin veren dosya iletişim kutusu belirecektir. Kullanıcı ilgili Excel dosyasını seçince dosya adı ilgili butonun önündeki metin kutusunda belirecektir. Eğer dosya seçmeden dosya iletişim kutusu kapanırsa ilgili metin kutusunda 0 (sıfır) yazılacaktır. Kullanıcı bu dosyayı seçmeden programda ilerlemesine izin verilmemektedir.
2. Nolu buton kamera görüntülerinin kaydedildiği klasörü belirtmek için kullanılmaktadır. İlgili butona basınca 2 nolu okla belirtilen klasör iletişim penceresi belirecektir. Kullanıcı ilgili klasörü seçince klasörün kısaltılmış yolu butonun solundaki metin kutusunda belirecektir. 1 nolu alanda olduğu gibi kullanıcı klasör yolunu seçmeden programda ilerleyemez. Diğer butonlara basınca bu konuda uyarı almaktadır.
3. Nolu buton kullanıcın seçtiği  $\lambda$  ve görüntüler grafiksel olarak “F” sekmesinde gösterilmektedir. Şekil 10.8’de deney-2 için gerçek  $\lambda$  ve kamera görüntüleri gösterilmiştir. Şekil 10.8’de  $\lambda$  verileri mavi ile gösterilmiştir. Kamera görüntülerini ifade etmek için aynı grafikte 1.5 değerinde kırmızı renk olarak ifade edilmiştir. Bu şekilde zaman ekseninden bakılarak verinin senkron olup olmadığı görülmektedir.



Şekil C.8 : Deney-2 için gerçek  $\lambda$  ve kamera görüntüleri

4. Kamera ile elde edilen görüntü ile baca gazı analizöründen elde edilen  $\lambda$  değerleri zamansal olarak senkron olmaya bilmektedir. Ara yüz de bunun için 4 nolu alandaki metin kutusuna kullanıcın belirleyeceği bir değer zaman farkı için saniye cinsinden maksimum ara değer üretme eşiği olarak alınmıştır.
5. Bu şekilde görüntü ile BGA cihazı verisi için maksimum zaman farkına (öncesinde veya sonrasında olabilecek en yüksek zaman farkının saniye (sn) cinsinden farkı) müsaade edilmekte ve uygun olmayan veriler elenmektedir. 5 nolu okla gösterilen “Görüntü Uygunluğunu Göster” butonuna basılınca verinin kullanıcının girdiği eşiğe


göre ne kadar uygun olup olmadığı Şekil 10.9'daki gibi “G” sekmesinde grafiksel olarak gösterilmektedir.



Şekil C.9 : Verinin uygunluğunun grafiksel olarak gösterilmesi

- Şekil 10.11'de görüldüğü gibi uygun veriler (+1) ile uygun olmayan veriler (-1) ile gösterilmiştir. Deney-2 için şekilde de görüldüğü gibi deneyin en başında bazı görüntülere karşılık kullanıcının belirlediği eşikteki uzaklıkta ilgili  $\lambda$  değeri olmamaktadır. Kullanıcı 6 nolu “Görüntüleri Yeniden Düzenle” butonuna basınca bu veriler yok sayılmakta ve kullanıcı Şekil 10.9’da gösterilen “Veri Tabanında -9- adet Veri Çıkarılarak Yeniden Düzenlenmiştir” gibi bir bilgi mesajı ile bilgilendirilmektedir.
- Nolu “Ara Değer Üret ve  $\lambda$ 'yı Göster” butonuna basınca iki veri arasında saniyede örnekleme farkı olduğu için daha çok olan görüntülere karşılık eksik olan  $\lambda$  değerleri ara değer üretme yöntemi ile üretilir. Şekil 10.10’da gerçek  $\lambda$  ve ara değer üretilen  $\lambda$ , “H” sekmesinde grafiksel olarak gösterilmiştir.

Şekil 10.10’da “H” sekmesinde alttaki grafik ara değer üretilmiş bir  $\lambda$  değeri için öncesinde veya sonrasında en yakın zamandaki  $\lambda$  değeri ile olan farkını göstermektedir. Bu grafiğe bakılarak ara değer üretme işleminde ne kadar farklılığın olduğu yani ne kadarlık salınımların yapıldığı görülebilir.



Şekil C.10 : Gerçek ve ara değer ile üretilmiş  $\lambda$  ile ara değer üretmede salınım grafikleri

| Image Name       | Image Created Date   |
|------------------|----------------------|
| 1 acA1600-20...  | 04-Haz-2015 03:00:16 |
| 2 acA1600-20...  | 04-Haz-2015 03:00:16 |
| 3 acA1600-20...  | 04-Haz-2015 03:00:17 |
| 4 acA1600-20...  | 04-Haz-2015 03:00:17 |
| 5 acA1600-20...  | 04-Haz-2015 03:00:18 |
| 6 acA1600-20...  | 04-Haz-2015 03:00:18 |
| 7 acA1600-20...  | 04-Haz-2015 03:00:19 |
| 8 acA1600-20...  | 04-Haz-2015 03:00:19 |
| 9 acA1600-20...  | 04-Haz-2015 03:00:20 |
| 10 acA1600-20... | 04-Haz-2015 03:00:20 |
| 11 acA1600-20... | 04-Haz-2015 03:00:21 |
| 12 acA1600-20... | 04-Haz-2015 03:00:21 |
| 13 acA1600-20... | 04-Haz-2015 03:00:22 |
| 14 acA1600-20... | 04-Haz-2015 03:00:22 |

| Lambda Value | Lambda Sample Time   |
|--------------|----------------------|
| 1 7.14       | 04-Haz-2015 03:00:16 |
| 2 7.14       | 04-Haz-2015 03:00:16 |
| 3 7.14       | 04-Haz-2015 03:00:17 |
| 4 7.05       | 04-Haz-2015 03:00:17 |
| 5 6.96       | 04-Haz-2015 03:00:18 |
| 6 6.845      | 04-Haz-2015 03:00:18 |
| 7 6.73       | 04-Haz-2015 03:00:19 |
| 8 6.62       | 04-Haz-2015 03:00:19 |
| 9 6.51       | 04-Haz-2015 03:00:20 |
| 10 6.465     | 04-Haz-2015 03:00:20 |
| 11 6.42      | 04-Haz-2015 03:00:21 |
| 12 6.64      | 04-Haz-2015 03:00:21 |
| 13 6.86      | 04-Haz-2015 03:00:22 |
| 14 7.32      | 04-Haz-2015 03:00:22 |

| Images Name     | Images Created Date  |
|-----------------|----------------------|
| 1 acA1600-20... | 04-Haz-2015 03:00:11 |
| 2 acA1600-20... | 04-Haz-2015 03:00:12 |
| 3 acA1600-20... | 04-Haz-2015 03:00:12 |
| 4 acA1600-20... | 04-Haz-2015 03:00:13 |
| 5 acA1600-20... | 04-Haz-2015 03:00:13 |
| 6 acA1600-20... | 04-Haz-2015 03:00:14 |
| 7 acA1600-20... | 04-Haz-2015 03:00:14 |
| 8 acA1600-20... | 04-Haz-2015 03:00:15 |
| 9 acA1600-20... | 04-Haz-2015 03:00:15 |

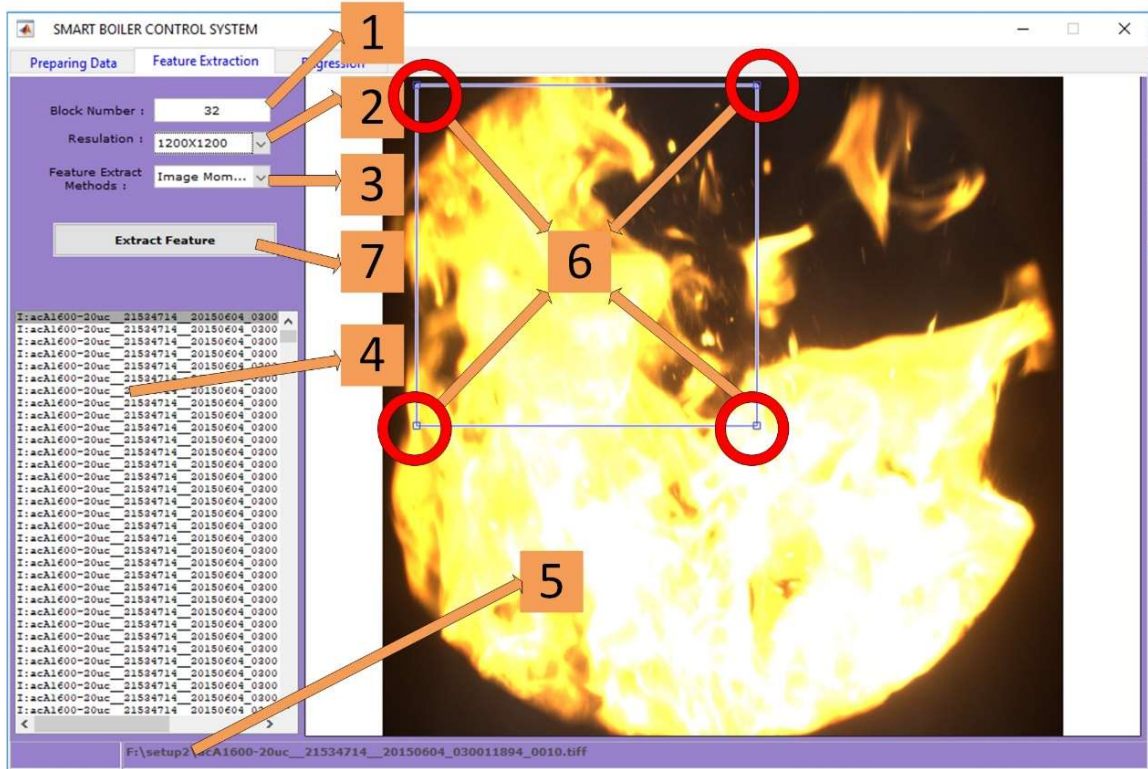
| Lambda Value | Lambda Sample Time     |
|--------------|------------------------|
| 1 7.14       | 4.06.2015 03:00:16.000 |
| 2 7.14       | 4.06.2015 03:00:17.000 |
| 3 6.96       | 4.06.2015 03:00:17.999 |
| 4 6.73       | 4.06.2015 03:00:19.000 |
| 5 6.51       | 4.06.2015 03:00:20.000 |
| 6 6.42       | 4.06.2015 03:00:21.000 |
| 7 6.86       | 4.06.2015 03:00:21.999 |
| 8 7.78       | 4.06.2015 03:00:23.000 |
| 9 8.71       | 4.06.2015 03:00:24.000 |
| 10 8.71      | 4.06.2015 03:00:24.999 |
| 11 9.36      | 4.06.2015 03:00:25.999 |
| 12 9.7       | 4.06.2015 03:00:27.000 |
| 13 9.87      | 4.06.2015 03:00:28.000 |
| 14 10        | 4.06.2015 03:00:28.999 |

Şekil C.11 : Veri hazırlama kısmı için görüntü ve  $\lambda$  bilgilerinin tablolarda verilmesi

Grafik sekmesinde (“D”) veri hazırlama kısmı için bilgilendirici grafik içeren şekiller kullanıcıya verilmiş fakat bununla yetinilmemiştir. Tablo sekmesinde (“E”) Şekil 10.11’de görüldüğü gibi gerçek  $\lambda$  ve ara değer üretilmiş tüm  $\lambda$  değerleri, karşılık geldikleri zaman,

uygun olan görüntüler ile uygun olmayan görüntülerin adları ve karşılık geldikleri zaman tablolar şeklinde verilmiştir. Grafikselsel gösterimle kullanıcıya çabuk yorumlayacağı bilgiler verilmiş tablolar şeklinde ise ayrıntılı inceleme için kullanıcıya kolaylık sağlanmıştır.

Veri hazırlama kısmı bittikten sonra “Öznitelik Elde Etme” sekmesi olan “B” sekmesine geçilir. Bu bölümde Şekil 10.12’de gösterilen yerel pencere sayısının belirlenmesi, çözünürlüğün ayarlanması, ROI belirlenmesi, öznitelik elde etme yönteminin belirlenmesi ve özniteliğin çıkarılması aşamalarından oluşmaktadır. Kısaca bu sekme anlatılacaktır.



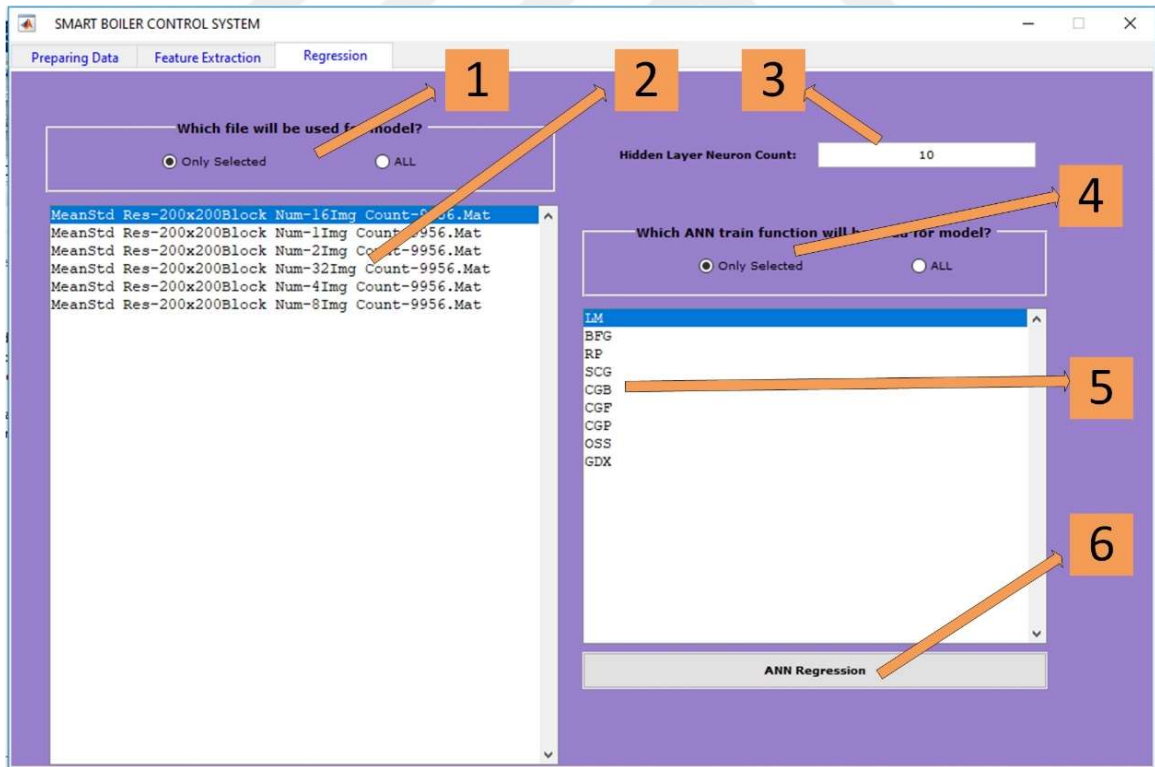
Şekil C.12 : Kullanıcı ara yüzü için “Öznitelik Elde Etme” sekmesi

1. Nolu veri giriş kutusu yerel pencere sayısına karar vermek için kullanıcının giriş yaptığı kısımdır. Yerel pencere boyutu kullanıcının girdiği değerin karesine eşit olacaktır. Yani yatay ve düşey olarak kullanıcının girdiği değer kadar eşit parçaya bölünmektedir.
2. Kameradan alınan çözünürlük çok yüksek olması durumunda veya çözünürlük etkisi araştırılmak istendiğinde ilgili görüntüler yeniden boyutlandırılarak bilmektedir. Açılan kutudan kullanıcı istediği çözünürlüğü seçebilmektedir.
3. Farklı öznitelik elde etme yöntemleri bu program tarafından desteklenmektedir. Görüntü momentleri, GLCM vb. gibi yöntemlerden hangisi ile öznitelik elde edileceği açılan kutudan kullanıcı tarafından seçilebilmektedir.
4. Daha önce veri hazırlama sekmesinde yeniden düzenlenmiş tüm görüntüler liste kutusunda görülmekte kullanıcı ilgili bir görüntüyü seçerek ROI'nın seçilmesi için kullanabilmektedir.

5. Kullanıcının seçtiği görüntünün adı ve tam yolu bu kısımda görülebilmektedir.
6. Alev görüntüsünün kenarlarında istenmeyen fazlalıklar olabilmektedir. Bu durumda kullanıcı ön işlem için seçtiği görüntü üzerinde beliren şeffaf bir kareyi kullanarak ilgilenilen bölgeyi seçebilir. Kullanıcı şeffaf kareyi fare ile tutup taşıyabildiği gibi şeffaf kutuyu kenarlarında bulunan mavi bölgeye fareyi götürerek kareyi büyütüp küçülebilmektedir. Şeffaf kutuyu konumlandırılırken görüntünün dışına çıkılmasına izin verilmemektedir. Eğer şeffaf kutu görüntünün dışına çıkarsa bir uyarı mesajı ile kullanıcı uyarılmaktadır.
7. Öznitelik çıkarma aşamasının başlaması için kullanılan butondur.

Öznitelik elde etme sekmesinden hesaplama işlemi bittikten sonra ilgili görüntüler için öznitelik yönteminin adı, seçilen çözünürlük, yerel pencere sayısı ve toplam veri tabanı boyutu dosyanın adı olacak şekilde ilgili görüntüler için elde edilen öznitelikler ve  $\lambda$  değerleri “.Mat” uzantılı olarak kaydedilir. Kaydedilen bu veriler “Regresyon” yani “C” sekmesinde YSA modeli inşa etmek için kullanılmaktadır. Şekil 10.13’te “C” sekmesinin görüntüsü verilmiştir.

Öznitelik dosyalarından hangisinin kullanılacağı, YSA mimarisi ve hangi YSA öğrenme yönteminin kullanılacağı bu kısımda kullanıcı tarafından belirlenir. Geliştirilen programın daha iyi anlaşılması için Şekil 10.13’te okla gösterilen kısımlar kısaca anlatılacaktır.



Şekil C.13 : Kullanıcı ara yüzü için “Regresyon” sekmesi

1. Öznitelikler daha önceden ön tanımlı bir klasöre kaydedilmektedir. Bu özniteliklerden biriyle mi YSA modelinin kurulup performans kriterlerinin ortaya konulacağı yoksa hepsiyle ayrı ayrı mı kurulacağı kullanıcı tarafından seçilmektedir.

Hepsi seçimi verilmesinin sebebi öznitelik elde etme yöntemi sonuçlarını karşılaştırmak için kullanıcıya kolaylık sağlamaktır.

- Öznitelik elde etme kısmında veya daha önceden kaydedilmiş özniteliklerin bulunduğu klasördeki tüm dosyalar liste kutusunda gösterilmektedir. Eğer kullanıcı sadece bir dosya üzerinde çalışacaksa ilgili dosyayı buradan seç bilmektedir.
- Gizli katmandaki nöron sayısı YSA mimarilerinde seçimli olup modelin performansına doğrudan etki etmektedir. Kullanıcı gizli katmandaki nöron sayısına metin kutusuna girdiği sayıyla belirlemektedir.
- YSA'nın sınıflandırma ve regresyon modellerinde birbirine göre zayıf ve üstün yönleri bulunan farklı öğrenme yaklaşımları bulunmaktadır. Kullanıcı isterse bunlardan sadece birisiyle modeli eğitebileceği gibi hepsiyle ayrı ayrı eğitmesini de isteyebilir. Bu seçeneğin verilmesinin sebebi kullanıcının öğrenme yaklaşımlarının sonuçlarını kıyaslamak için kısa sürede sonuç elde edebilmesidir.
- Matlab programının desteklediği tüm YSA öğrenme metotları liste şeklinde verilmiştir. Eğer kullanıcı sadece bir öğrenme metoduyla YSA modelini eğitip doğruluk sonuçlarını almak istiyorsa liste kutusundan ilgili metodu seç bilmektedir.
- “YSA Regresyon” butonuna basınca kullanıcının inşa ettiği YSA regresyon modeli için her bir öğrenme modeli için ayrı bir dosya olmak üzere modellerin öğrenme, doğrulama, test ve tüm model olmak üzere 8 adet sonucu tablo şeklinde dosyaya kaydedilmektedir. Şekil 10.14'te sonuçların tutulduğu örnek bir dosya içeriği verilmiştir.

| Sıra No | Ozn_Dosya_Adi   | Tum_Sistem_MS | Tum_Sistem_R | Egitim_MSE   | Egitim_R    | Dogrulama_MSE | Dogrulama_R | Test_MSE    | Test_R      | YSA_Ogr_Yont | YSA_Gizli_Katme |
|---------|---|---------------|--------------|--------------|-------------|---------------|-------------|-------------|-------------|--------------|-----------------|
| 1       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,197475552   | 0,801007018  | 1,218910911  | 0,801255914 | 1,148390431   | 0,809009229 | 1,146490713 | 0,790951373 | trainlm      | 2               |
| 2       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,110857642   | 0,817105493  | 1,082765639  | 0,821897616 | 1,110623346   | 0,807998184 | 1,24223813  | 0,80405056  | trainlm      | 2               |
| 3       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,198025381   | 0,800924079  | 1,184984917  | 0,798546111 | 1,322100065   | 0,802330062 | 1,134829482 | 0,810447728 | trainlm      | 2               |
| 4       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,288428067   | 0,783896114  | 1,297075364  | 0,778827253 | 1,139377961   | 0,809557059 | 1,397108675 | 0,7819004   | trainlm      | 2               |
| 5       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,111925486   | 0,816864038  | 1,116998259  | 0,815650593 | 1,153069095   | 0,827787034 | 1,047099872 | 0,811087181 | trainlm      | 2               |
| 6       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 1,198804468   | 0,800758582  | 1,232401661  | 0,798997356 | 1,149854396   | 0,787536115 | 1,090907631 | 0,820416487 | trainlm      | 2               |
| 7       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,722848918   | 0,885249941  | 0,730719718  | 0,886118617 | 0,698574494   | 0,87622973  | 0,710378885 | 0,889213646 | trainlm      | 2               |
| 8       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,71338434    | 0,886849795  | 0,718855927  | 0,887304969 | 0,720557421   | 0,882091435 | 0,680667409 | 0,889281852 | trainlm      | 2               |
| 9       | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,771157635   | 0,877051862  | 0,770112466  | 0,87642411  | 0,788416502   | 0,877347513 | 0,758778087 | 0,879697727 | trainlm      | 2               |
| 10      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,774161583   | 0,87664007   | 0,75810267   | 0,87547542  | 0,85033314    | 0,8837512   | 0,772960303 | 0,875916457 | trainlm      | 2               |
| 11      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,723822751   | 0,885131082  | 0,679233486  | 0,89111095  | 0,805266574   | 0,875658562 | 0,850541809 | 0,867811538 | trainlm      | 2               |
| 12      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,711675501   | 0,887133139  | 0,715255491  | 0,887948821 | 0,670523782   | 0,8941036   | 0,736114205 | 0,875562348 | trainlm      | 2               |
| 13      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,557916028   | 0,912701427  | 0,539228149  | 0,913976168 | 0,635345576   | 0,91060328  | 0,56772996  | 0,908687454 | trainlm      | 2               |
| 14      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,466063254   | 0,92768574   | 0,456940827  | 0,928359054 | 0,454291266   | 0,930650054 | 0,520422864 | 0,922626201 | trainlm      | 2               |
| 15      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,52317536    | 0,918437889  | 0,520070148  | 0,919001128 | 0,520646629   | 0,923550326 | 0,540200629 | 0,911229367 | trainlm      | 2               |
| 16      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,542811673   | 0,915184519  | 0,5221237476 | 0,918171237 | 0,550860665   | 0,914834235 | 0,631279197 | 0,901989525 | trainlm      | 2               |
| 17      | 04_06_2015_03_00-Ortalama_SatndartSapma - Renk_Kanali RGB - Pencere | 0,464995277   | 0,927813326  | 0,45377392   | 0,930361422 | 0,529905613   | 0,915533787 | 0,452471317 | 0,928471603 | trainlm      | 2               |

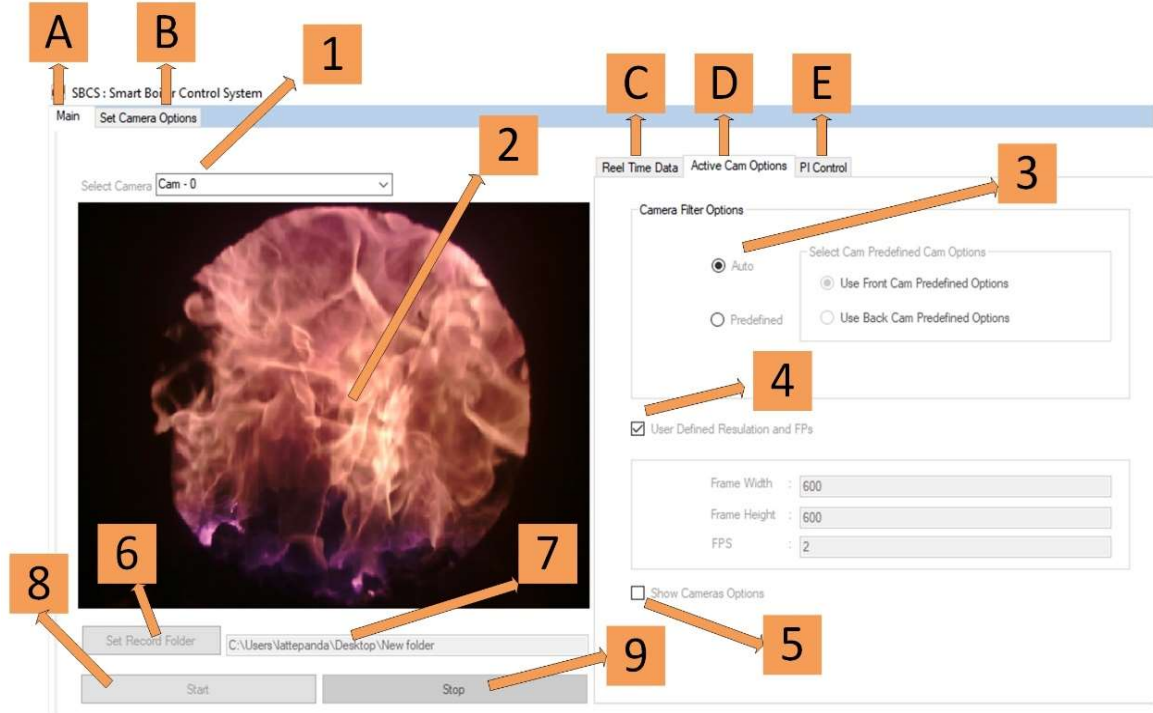
Şekil C.14 : YSA regresyon modeli için örnek bir sonuç dosyası içeriği

Şekil 10.14'te sütunlar sırayla; sıra no, öznitelik dosyasının adı, tüm model için MSE (ortalama karesel hata) ve R (korelasyon katsayısı), eğitim için MSE ve R, doğrulama için MSE ve R, test için MSE ve R, YSA öğrenme yöntemi ve sonuncusu gizli katmandaki nöron sayısının göstermektedir.

## C4 Gömülü Kontrol Uygulaması

Gömülü bilgisayarda koşan program Latte Panda gömülü bilgisayarı için geliştirilmiştir. Veri kayıt programı değiştirilerek ve eklemeler yapılarak bu program elde edilmiştir. Veri kayıt programındaki kamera özelliklerinin ayarlanması kısmı bu programda tek kamera için

kullanılmıştır. Bu yüzden ayrıca anlatılmayacaktır. Geliştirilen programın ekran görüntüsü Şekil 10.15’te verilmiştir. İlgili gömülü bilgisayar uygulaması, tek kamera için anlık görüntü alıp daha önceden eğitilmiş YSA regresyon modeli ile  $\lambda$  tahmini yapmaktadır. İlgili  $\lambda$  tahmini için geliştirilen kontrol uygulamasına göre hata hesaplanıp ona göre fan devir hızına ayarlanıp yanma kontrolü yapılmaktadır. Bu uygulamada kömür yüklemesi kontrol edilmediği için kömür yüklemesi sabit kabul edilip belli bir kömür yüklemesine göre (115 sn bekleme 5 sn yükleme) hava girişi kontrol edilmiştir.



Şekil C.15 : Geliştirilen gömülü kontrol uygulamasının ekran görüntüsü

Geliştirilen program anlık alınan görüntüden  $\lambda$  tahmini yapmakta, kontrol uygulamasına göre hata işareti üretmekte ve üretilen işarete göre fan kontrolünü yapmaktadır. Şekil 10.15’te görüldüğü gibi ana program (“A”) ve kamera özelliklerinin ayarlanması (“B”) sekmeleri olmak üzere iki kısımdan oluşmaktadır. Kamera özelliklerinin ayarlanması (“B”) sekmesi daha önceki bölümde veri kayıt yazılımı başlığında anlatılan kısım ile hemen hemen aynıdır. Bu yüzden tekrardan anlatılmayacaktır. Şekil 10.15’te ekran görüntüsü verilen ana program (“A”) sekmesindeki ilgili alanları kısaca anlatılacaktır.

1. İlgili kameranın açılan kutu ile seçildiği kısımdır.
2. Seçilen kamera görüntüsünün gösterildiği alandır.
3. Kamera özellikleri için ön tanımlı mı yoksa sürücü tarafından otomatik mi atanacağı seçiminin yapıldığı kısımdır. Kamera özellikleri için iki farklı dosya şeklinde saklanmasını desteklemektedir. Bu sadece kolaylık sağlamak açısındandır. Normalde programda tek kamera vardır. Fakat iki farklı şekilde ayarlarının saklanmasını desteklemektedir.
4. Kameranın çözünürlüğü ve FPS ilgili seçme çentiği seçildiğinde bu alandaki değerler atanmaktadır.

5. DirectShow kütüphanesinin sağladığı kamera ayarlama ara yüzlerinin gösterilmesiyle ilgili seçim alanıdır.
6. Kontrol işlemi yapılırken aynı zamanda elde edilen görüntüler geriye dönük optimizasyon çalışmaları için saklanmaktadır. Verilerin saklanacağı klasörün yolu bu alandaki buton tıklanarak açılan dosya iletişim penceresinden seçilir.
7. Seçilen veri kayıt klasörünün tam yolu bu alandaki metin kutusunda gösterilmektedir.
8. Programın başlatıldığı butondur. Her başlamada veri kayıt klasörü otomatik olarak daha önce veri kayıt programında anlatıldığı gibi otomatik olarak oluşturulmaktadır.
9. Programın sonlandırıldığı butondur.



**EK D. Ayrıntılı Uygulama Sonuçları CD'si**



## ÖZGEÇMİŞ

**Ad Soyad** : Sedat GOLGİYAZ  
**Doğum Tarihi ve Yeri** : 1981-Bingöl  
**E-posta** : sedat12@gmail.com, sedatg@bingol.edu.tr

## ÖĞRENİM DURUMU:

**Lisans** : 2005, Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü.

**Yüksel Lisans** : 2013, Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü.

## MESLEKİ DENEYİM:

- **2010-** , Bingöl Üniversitesi Bilgisayar Mühendisliği Bölümünde Araştırma Görevlisi, Bingöl.
- **2009 – 2010**, Teknik Personel, Ptt Genel Müdürlüğü, Ankara
- **2008**, Teknik Personel, Grup Peryod Entegre Yönetim Bilgi Sistemleri A.Ş, İstanbul
- **2007**, Yönetici, ARLA Mühendislik San. Ve Tic. LTD. ŞTİ., İstanbul

## Yayın listesi:

### TEZDEN TÜRETİLEN YAYINLAR

- Golgiyaz, S., Talu, M. F., & Onat, C.** (2016). Otomatik Beslemeli Kömür Brülörleri İçin Hava Fazlalık Katsayısının Görüntü Tabanlı Gauss Modeli ile Kestirimi . *International Artificial Intelligence and Data Processing Symposium (IDAP'16)*, 528–531.
- Golgiyaz, S., Talu, M. F., & Onat, C.** (2019a). Estimation of Flue Gas Temperature by Image Processing and Machine Learning Methods. *European Journal of Science and Technology*, 283–291.
- Golgiyaz, S., Talu, M. F., & Onat, C.** (2019b). Artificial neural network regression model to predict flue gas temperature and emissions with the spectral norm of flame image. *Fuel*, 255, 115827.

### TEZDEN TÜRETİLMEYEN YAYINLAR

- Hanbay, K., Golgiyaz, S., & Talu, M. F.** (2017). Real time fabric defect detection system on Matlab and C++/Opencv platforms. *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, 1–8.