T.C
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKA TEKNİKLERİ İLE DİZEL MOTOR PERFORMANSININ MODELLENMESİ VE YAKIT OPTİMİZASYONU

Kemal TÜTÜNCÜ

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

Konya, 2009

ÖZET

Doktora Tezi

YAPAY ZEKA TEKNİKLERİ İLE DİZEL MOTOR PERFORMANSININ MODELLENMESİ VE YAKIT OPTİMİZASYONU

Kemal TÜTÜNCÜ

Selçuk Üniversitesi Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Prof. Dr. Novruz ALLAHVERDİ

2009, 205 Sayfa

Jüri: Prof. Dr. İnan GÜLER
Prof. Dr. Novruz ALLAHVERDİ
Doç. Dr. Yüksel ÖZBAY
Doç. Dr. Salih GÜNEŞ
Yrd. Doç. Dr. Ali KAHRAMAN

İçten yanmalı motorların performans ve emisyon karakteristiklerinin modellenmesi yanma işleminin herhangi bir matematiksel modelleme içermediğinden dolayı yorucu ve uzun zaman alan motor testlerinin yapılmasını gerektirmektedir. Bu deneyler sadece çevreye zarar vermekle, zaman alıcı olmakla ve yüksek maliyetli sensörlerden dolayı pahalı olmakla kalmayıp aynı zamanda insan sağlığı ve çevre için de tehdit oluşturmakta ve pahalı iş gücünü gerektirmektedir. Bunlara ek olarak hassas olmayan sensörlerin kullanılmasından dolayı sadece belirli sayıda noktalar için ölçüm yapılabilmekte ara değerler için her hangi bir ölçüm yapılamamaktadır. Tüm bu sebeplerden dolayı otomotiv imalatçıları daha hassas ve daha az zaman alan ölçüm tekniklerinin elde edilebilmesi için çalışmaktadırlar. Buda motorun yanma odasında ve ilgili diğer kısımlarında yeni ve yüksek maliyetli

sensörlerin monte edilmesini gerektirmektedir. Montaj ise bazı parçaların değişikliğe uğraması ile sonuçlanmaktadır. Buda beraberinde yüksek maliyet getirmektedir. Montaj gerektiren sensörlerin yüksek maliyeti yalnızca alınan verimin çok yüksek düzeyde olması durumunda karşılanabilir. Verimin üst düzeyde olması ise daha hassas modelle, yakıt ve emisyon optimizasyonu anlamındadır. Dolayısıyla bu endüstri için var olan ekipmanları kullanıp motor yapısında her hangi bir değişikliğe gitmeden yapılacak ölçüm ve hesaplama teknikleri oldukça değer kazanmaktadır. Yapay Zeka (YZ) teknikleri daha hassas modelleme yapmak için ek sensörlere ihtiyaç doğurmayacağı için bu problemin çözümünde en iyi aday olarak görülmektedir. Var olan ölçüm değerleri YZ teknikleri tarafından kullanılarak daha hassas motor performans ve emisyon karakteri modellemesi gerçekleştirilebilmektedir. Bugüne kadar farklı YZ teknikleri kullanılarak hava-yakıt oranı, yanma zamanlaması, emisyon vb. içten yanmalı motor performans ve emisyon karakteristiğinin modellenmesi ve kontrolü geleneksel yöntemlere göre daha verimli bir şekilde yapılmıştır. Bu sistemler geleneksel modelleme ve kontrol sistemleri ile karşılaştırıldığında verimlilik, optimallık ve istikrar açısından daha iyi olduğu görülmektedir. Bu alanda YZ teknikleri kullanımı 1986 yılında başlamış ve günümüze kadar süre gelmiştir.

Bilindiği üzere YZ teknikleri doğrusal olmayan ve matematiksel olarak modellenemeyen karmaşık problemlerin çözümünde kullanılan alternatif teknolojidir. Örneklerden öğrenebilir, gürültülü ve eksik veriler üzerinde doğru sonuçlar elde edilmesine imkan kılar. Bir kere eğitildiler mi yüksek hızda tahmin ve genelleme yapabilirler. Kontrol ve güç sistemleri, robot uygulamaları, desen tanıma, imalat, hava tahmini, tıp, sinyal işleme ve optimizasyon gibi bir çok alanda başarılı sonuçlar vermektedirler. YZ teknikleri uzman sistemler (US), bulanık mantık (BM), yapay sinir ağları (YSA), genetik algoritmalar (GA) ve birden fazla tekniğin birlikte kullanıldığı hibrid sistemleri içermektedir.

Bu çalışmada iki ayrı motor veri kümesi üzerinde YZ teknikleri ile motor performans ve emisyon karakteristiğinin noktasal ve aralıksal modellemesi ile yakıt optimizasyonu gerçekleştirilmiştir. Dizel motor veri kümesi üzerinde Yapay Sinir Ağları (YSA) ile gerçekleştirilen noktasal modellemede elde edilen sonuçların deneysel sonuçlara % 99,58 yaklaşık sonuç verdiği tespit edilmiştir. YSA ile benzinli

motor veri kümesinde yapılan noktasal modellemede ise elde edilen sonuçların deneysel sonuçlara % 98,5 yaklaşık sonuç verdiği tespit edilmiştir. Noktasal modellemede amaç motor deneylerinin yerini alabilecek ve motor performans ve emisyon karakteristiğini sadece deneylerde ölçülen noktalarda değil tüm noktalarda belirleyen bir model gerçekleştirmektir.

Çalışmada ikinci olarak verilen performans ve emisyon değerlerine göre giriş parametreleri ya da giriş parametreleri verildiğinde performans ve emisyon değerleri hangi optimum aralıkta olmalıdır sorusuna cevap aranmıştır. Buda ileri ve geri yönlü optimum aralıksal modelleme anlamına gelmektedir. Bulanık *c*-ortalamalar ve ANFIS tekniği birlikte kullanılarak dizel motor üstünde giriş ve çıkış parametreleri optimum aralıklara bölünerek ileri ve geri yönlü optimum aralıksal modellemede %100'lük başarı sağlanmıştır. Buda verilen motor giriş parametrelerine (Afr, Pb, Fr, Cy ve L) göre tork, güç ve spesifik yakıt tüketimi ile emisyon değerlerinin (HC, CO_2 ve NO_x) hangi optimum aralıkta olması (ya da tersi) gerektiğinin %100 başarı ile bulunması anlamındadır. Benzinli motor veri kümesi üzerinde yapılan uygulama sonucunda ise yine ileri ve geri yönlü modellemede % 100 oranında doğru aralık kestirimi yapılmıştır.

Çalışmanın son aşamasında ise optimal yakıt tüketiminin belirlenmesi amacıyla tek amaçlı ve çok amaçlı GA optimizasyon teknikleri dizel ve benzinli motor verileri üzerinde uygulanmıştır. Her iki teknik dizel motor verisi üzerinde iyi sonuç verirken benzinli motorun sadece 2 girişli veriye sahip olmasından dolayı iyi değer elde edilmemiştir. Yapay Sinir Ağı ve çok amaçlı GA tekniklerinden NSGA II ilk kez motor verileri üzerinde optimizasyon amaçlı olarak kullanılmış ve başarılı sonuç vermiştir.

Anahtar Kelimeler – Yapay zeka, motor performansı, emisyon, yapay sinir ağları, uyarlamalı nöro-bulanık sonuç çıkarım sistem, çok amaçlı genetik algoritmalar.

ABSTRACT

PhD Thesis

MODELLING OF DIESEL ENGINE PERFORMANCE AND FUEL OPTIMISATION

Kemal TÜTÜNCÜ

Selçuk University

Graduate School of Natural and Applied Sciences

Department of Electrical-Electronics Engineering

Supervisor: Prof. Dr. Novruz ALLAHVERDİ

2009, 205 pages

Jury: Prof. Dr. İnan GÜLER

Prof. Dr. Novruz ALLAHVERDİ

Assoc. Prof. Dr. Yüksel ÖZBAY

Assoc. Prof. Dr. Salih GÜNEŞ

Asist. Prof. Dr. Ali KAHRAMAN

Modeling the characteristics of performance and emission of internal combustion engine requires tired-some and time consuming engine tests, since there is no mathematical model of combustion process. Not only are these experiments expensive, time consuming and costly but also can cause negative conditions for human health, environment pollution and expensive labour force. Moreover, limited numbers of points are measured at these tests and there is no way of measuring every point for the given interval due to non-sensitive sensors. So that, automotive manufacturers try to have new measurement techniques to have more sensitive and less time consuming measurement. This requires installation of new costly sensors

into the combustion chamber and other related parts of engine. Installation can cause some modification on parts. It is only acceptable if the results obtained by sensors are so profitable. Because, the more you have sensitive modeling the more you will have fuel and emission optimization. Because, the more you have sensitive modeling the more you will have fuel and emission optimization. So that, new way of measurement and calculation techniques that don't require modification on the engine part and use the current equipments are so valuable for this industry. Artificial Intelligence (AI) techniques seem to be best solution for this problem due to not demanding any additional sensor installation. Existing measured values are used in AI techniques to predict more sensitive performance and emission characteristics modeling of internal combustion engine. By using different AI systems, controlling and modeling of different parameters of IC engines such as air-fuel ratio, ignition timing, emission and etc. have been done till today in effective ways regarding to the traditional methods. When these systems compared with traditional control and modeling systems, it has been seen that novel AI systems are better than traditional model in terms of efficiency, robustness, reliability and optimality.

As it's known AI techniques are accepted as a technology that offers an alternative way to tackle non-linear and highly complex problems that can't be modeled in mathematics. They can learn from examples and they are able to handle noisy and incomplete data. Once they are trained they can perform prediction and generalization at high speed. They have been used in diverse applications in control, robotics, pattern recognition, forecasting, medicine, power systems, manufacturing, optimization and signal processing. AI systems comprise areas like, expert systems (ES), artificial neural networks (ANN), genetic algorithms (GA), fuzzy logic (FL) and various hybrid systems, which combine two or more techniques.

In this study, point-by-point and interval modeling of engine performance and emission characteristics of two different engine data and also fuel optimization were realized. By usin ANN on diesel engine obtained results are matched with the experimental data as the ratio of %99,58. This ratio was %98.5 for the petrol-driven or gas engine. The aim of point by point modeling is to build a system that will take place of the engine experiments to predict the engine performance and emission characteristics not only on measured points but all.

In the second stage of the study, the answer of the questions of which optimum input parameter's interval must be matched with the given performance and emission values or vice versa was investigated. This means optimum interval modeling in both forward and backward direction. Fuzzy *c*-means, *k*-means and ANFIS techniques were used for optimum interval modelling. Firstly, inputs and outputs parameters were grouped into optimal numbers independently by using fuzzy *c*-means and *k*-means clustering algorithm. Later on, these optimal numbers of clustered or grouped parameters were applied to ANFIS for modeling engine performance and emissions characteristic. The forward and backward modeling that includes fuzzy c-means clustering and ANFIS found outputs in correct optimal interval as 100% ratio. It means torque, power and specific fuel consumption and emission values (HC, CO_2 and NO_x) were found in correct optimal intervals as 100% ratio according to given engine input parameters (Afr, Pb, Fr, Cy and L). Moreover, since the reverse modeling has the same correctness ratio, input parameters were found in correct optimal intervals as 100% ratio according to given performance and emission values. The difference between forward and backward chaining is the reversing input and output parameters. This technique is applied to both diesel engine and gas engine. In both application correct classification ratios were obtained as %100 for both reverse and forward interval modeling of two engine. In the previous studies, implementation of optimal interval modeling that is based on grouping data instead of point by point and determines optimal interval for the performance and emission values according to given input values or vice versa has never been done.

In the final stage of the study, single objective and multi-objective GA optimization techniques were applied to both engine. Both of techniques created good results for optimization of the diesel engine. Since the input data of the gas engine was only two and both of them were used as constant value neither single objective nor multi-objective GA created good optimization results for gas engine. It was the first time to use ANN and NSGA II that is one of the technique of multi-objective GA on engine data.

Key Words –Artificial intelligence, engine performance, emission, artificial neural networks, Adaptive neuro-fuzzy inference system, multiobjective genetic algorithms.

TEŞEKKÜR

Bu çalısmada bana yol gösteren ve her türlü bilimsel katkıyı sağlayan değerli hocam ve danışmanım Sayın Prof. Dr. Novruz ALLAHVERDİ'ye teşekkür ederim. Tez aşamam boyunca bana her türlü desteği saglayan Tez İzleme Komitesi üyeleri S.Ü. Elektrik-Elektronik Mühendisliği Bölümü Öğretim Üyeleri Sayın Doç. Dr. Yüksel ÖZBAY ve Doç. Dr. Salih GÜNEŞ'e teşekkür ederim. Çalışmam esnasında büyük katkıları bulunan mesai arkadaşlarım Ögr. Gör. Dr. Rıdvan Saraçoğlu, Arş. Gör. Murat Köklü ve Arş. Gör. Tahir Sağ'a da teşekkür ederim. Ayrıca, bu tez çalışması süresince bana destek olan eşim Saliha Uysal Tütüncü'ye ve kızım Hatice Nisa ile oğlum Orhan Alptuğ Tütüncü'ye de minnettarlığımı ve sevgilerimi burada ifade etmek istiyorum.

Kemal TÜTÜNCÜ

Konya, 2009

İÇİNDEKİLER

	ÖZET	**i**
	ABSTRACT	**iv**
	TEŞEKKÜR	**vii**
	İÇİNDEKİLER	**viii**
	ŞEKİLLER LİSTESİ	**xi**
	TABLOLAR LİSTESİ	**xv**
	SİMGELER ve KISALTMALAR	**xx**
1.	**GİRİŞ**	**1**
1.1..	Motor Performans ve Emisyon Karakteristiğinin Belirlenmesi ve Temelleri	3
1.2.	Motor Performans ve Emisyon Karakteristiğinin Belirlenmesinde Karşılaşılan Problemler	4
1.3.	Çalışmanın Amacı ve Önemi	5
1.4.	Literatür Araştırması	7
1.5.	Tezin Organizasyonu	21
2.	**DİZEL MOTORLAR VE PERFORMANS KARAKTERİSTİKLERİ**	**23**
2.1.	Dört Zamanlı Motorların Çalışma Sıralaması	26
3.	**MATERYAL VE METOT**	**35**
3.1.	Materyal	35
3.2.	Metot	39
3.2.1	Çoklu- Regresyon	39
3.2.2	Uyarlamalı bulanık uzman sistem (ANFIS)	41
3.2.3.	Yapay zeka ve Yapay sinir ağları	44
3.2.3.1.	YSA	44
3.2.3.2.	YSA'nın genel özellikleri	45
3.2.3.3.	YSA'nın dezavantajları	46
3.2.3.4.	YSA'nın temel yapısı	47
3.2.3.5.	Yapay sinir ağı hücresi	47
3.2.3.6.	YSA öğrenme algoritmaları	49
3.2.3.7.	Performans fonksiyonunun seçimi	50
3.2.3.8.	YSA modelleri	52
3.2.3.9.	Çok katmanlı perseptron (ÇKP) modeli	53
3.2.4.	Bulanık Mantık	59
3.2.4.1.	K-ortalamalar	62
3.2.4.2.	Bulanık *c*-ortalamalar	64
4.	**DİZEL MOTOR PERFORMANSI VE EMİSYON KARAKTERİSTİĞİNİN ÇOKLU-REGRESYON ANALİZİ İLE BELİRLENMESİ**	**69**
4.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Uygulama	69
4.2.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Uygulama	74
5.	**DİZEL MOTOR PERFORMANSI VE EMİSYON KARAKTERİSTİĞİNİN YAPAY ZEKA TEKNİKLERİ İLE BELİRLENMESİ**	**79**

5.1.	ANFIS ile Modelleme	79
5.1.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde ANFIS Uygulaması	79
5.1.2.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde ANFIS Uygulaması	87
5.2.	YSA ile Modelleme	87
5.2.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde ANFIS Uygulaması	93
5.2.2.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde YSA Uygulaması	111
6.	**MOTORUN PERFORMANS VE EMİSYONUNUN NOKTASAL DEĞERLER YERİNE ARALIKSAL OLARAK İLERİ VE TERS YÖNLÜ MODELLEMESİ**	**124**
6.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde İleri ve Ters Yönlü Aralıksal Modelleme	124
6.1.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Tersten Aralıksal Modelleme	125
6.1.2.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde İleri Yönlü Aralıksal Modelleme	139
6.2.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde İleri ve Ters Yönlü Aralıksal Modelleme	141
6.2.1.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Tersten Aralıksal Modelleme	141
6.2.2	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde İleri Yönlü Aralıksal Modelleme	149
7.	**GENETİK ALGORİTMA İLE YAKIT OPTİMİZASYONU**	**152**
7.1.	Genetik Algoritmalar	152
7.1.1	Tek Amaçlı Genetik Algoritmalar	152
7.1.2	Çok Amaçlı Genetik Algoritmalar	157
7.2.	Yakıt Optimizasyonu	159
7.2.1.	Tek Amaçlı GA Kullanılarak Gerçekleştirilen Yakıt Optimizasyonu	161
7.2.1.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Tek Amaçlı GA Uygulaması	161
7.2.1.2.	Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Tek amaçlı GA Uygulaması	171
7.2.2.	Çok Amaçlı GA Kullanılarak Gerçekleştirilen Yakıt Optimizasyonu	175
7.2.2.1.	300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Çok Amaçlı GA Uygulaması	175
7.2.2.2.	Briggs ve Stratton Vanguard Benzinli Motor Motor Veri Kümesinde Çok Amaçlı GA Uygulaması	179
8.	**SONUÇ VE ÖNERİLER**	**182**
8.1.	Sonuçlar	182
8.2.	Öneriler	184
9.	**KAYNAKLAR**	**185**

EKLER **193**
Ek 1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesi **193**
Ek 2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesi **196**
Ek 3. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II öklit minimizasyonu **198**
Ek 4. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II sfc optimizasyonu **199**
Ek 5. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II HC optimizasyonu **200**
Ek 6. Ek 4. 300PS E1 J1 Yüksek Torklu Dizel Motor tam yük NSGA II sfc (yakıt tüketimi) optimizasyonu **201**
Ek 7. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II öklit minimizasyonu **202**
Ek 8. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II sfc minimizasyonu **203**
Ek 9. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II HC minimizasyonu **204**
Ek 10. Briggs ve Stratton Vanguard Benzinli Motor 10 avans NSGA II sfc (yakıt tüketimi) optimizasyonu **205**

ŞEKİLLER LİSTESİ

Şekil 1.1.	**EMS ve fonksiyonları**	**2**
Şekil 2.1.	**Motorda emme zamanı esnasında piston görüntüsü**	**27**
Şekil 2.2.	**Motorda emme zamanı esansında hacim basınç ilişkisi**	**28**
Şekil 2.3.	**Motorda sıkıştırma zamanı esnasında piston görüntüsü**	**28**
Şekil 2.4.	**Motorda sıkıştırma zamanı esansında hacim basınç ilişkisi**	**29**
Şekil 2.5.	**Motorda yanma zamanı esnasında piston görüntüsü**	**29**
Şekil 2.6.	**Motorda yanma zamanı esansında hacim basınç ilişkisi**	**30**
Şekil 2.7.	**Motorda egzoz zamanı esnasında piston görüntüsü**	**30**
Şekil 2.8.	**Motorda egzoz zamanı esansında hacim basınç ilişkisi**	**31**
Şekil 2.9.	**Bir dizel motorun teorik diyagramı**	**31**
Şekil 2.10.	**Bir dizel motorun güç, moment ve yakıt sarfiyatı diyagramı**	**32**
Şekil 2.11.	**Dizel motorda performans ve emisyon karakteristiğini belirleyen parametreler**	**34**
Şekil 3.1.	**300PS E1 J1 dizel motor verisi için devir-güç grafiği**	**36**
Şekil 3.2.	**300PS E1 J1 dizel motor verisi için devir-tork grafiği**	**37**
Şekil 3.3.	**300PS E1 J1 dizel motor verisi için devir-özgül yakıt tüketimi (Sfc) grafiği**	**37**
Şekil 3.4.	**Briggs ve Stratton Vanguard benzinli motor verisi için devir-güç grafiği**	**38**
Şekil 3.5.	**Briggs ve Stratton Vanguard benzinli motor verisi için devir-tork grafiği**	**38**
Şekil 3.6.	**Briggs ve Stratton Vanguard benzinli motor verisi için devirözgül yakıt tüketimi (Sfc) grafiği**	**39**
Şekil 3.7.	**Bulanık uzman sisteminin genel yapısı**	**42**
Şekil 3.8.	**ANFIS sisteminin genel yapısı**	**43**
Şekil 3.9.	**Temel yapay sinir ağı hücresi**	**48**
Şekil 3.10.	**Çok katmanlı perseptron ağ yapısı**	**53**
Şekil 3.11.	**Eğitme İşlemi**	**57**
Şekil 3.12.	**Bulanık Mantık modeli**	**61**
Şekil 3.13.	**Klasik Mantık Modeli**	**61**
Şekil 3.14.	**Örnek *k*-ortalamalar kümelemesi (*k*=2)**	**64**
Şekil 3.15.	**Tek boyutlu örnek bir veri seti**	**66**
Şekil 3.16.	**Kesin üyelik eğrisi**	**66**
Şekil 3.17.	**Bulanık üyelik eğrisi**	**67**
Şekil 3.18.	**Kesin ve bulanık üyelik matrisleri**	**67**
Şekil 4.1.	**300PS E1 J1 deneysel (ölçülen) CO_2 ve çoklu-regresyonla hesaplanan CO_2**	**71**
Şekil 4.2.	**300PS E1 J1 deneysel (ölçülen) HC ve çoklu-regresyonla hesaplanan HC**	**72**
Şekil 4.3.	**300PS E1 J1 deneysel (ölçülen) NO_x ve çoklu-regresyonla hesaplanan NO_x**	**72**
Şekil 4.4.	**300PS E1 J1 deneysel (ölçülen) Güç (P) ve çoklu-regresyonla hesaplanan**	**73**
Şekil 4.5.	**300PS E1 J1 deneysel (ölçülen) Tork (Tq) ve çoklu-regresyonla hesaplanan Tq**	**73**

Şekil 4.6.	**300PS E1 J1 deneysel (ölçülen) Sfc ve çoklu-regresyonla hesaplanan Sfc**	**74**
Şekil 4.7.	**Briggs ve Stratton Vanguard deneysel (ölçülen) HC ve çoklu-regresyonla hesaplanan HC**	**76**
Şekil 4.8.	**Briggs ve Stratton Vanguard deneysel (ölçülen) güç (P) ve çoklu-regresyonla hesaplanan P**	**77**
Şekil 4.9.	**Briggs ve Stratton Vanguard deneysel (ölçülen) güç (P) ve çoklu-regresyonla hesaplanan P**	**77**
Şekil 4.10.	**Briggs ve Stratton Vanguard deneysel (ölçülen) özgül yakıt tüketimi (Sfc) ve çoklu-regresyonla hesaplanan Sfc**	**78**
Şekil 5.1.	**300PS E1 J1 CO_2 çıkış parametresi için oluşturulan ANFIS mimarisi**	**81**
Şekil 5.2.	**300PS E1 J1 CO_2 çıkış parametresinin tamamlanmış ANFIS eğitiminden bir görüntü**	**81**
Şekil 5.3.	**300PS E1 J1 CO_2 çıkış parametresi için oluşturulan ANFIS'den kurallardan bazıları**	**82**
Şekil 5.4.	**Briggs ve Stratton Vanguard güç (P) çıkış parametresi için oluşturulan ANFIS mimarisi**	**85**
Şekil 5.5.	**Briggs ve Stratton Vanguard güç (P) çıkış parametresinin tamamlanmış ANFIS eğitiminden bir görüntü**	**85**
Şekil 5.6.	**Briggs ve Stratton Vanguard güç (P) çıkış parametresi için oluşturulan ANFIS'tan test aşamasından enstantane**	**86**
Şekil 5.7.	**300PS E1 J1 CO_2 için eğitim seti ve doğrulama seti için R-kare mutlak hata değişimi**	**98**
Şekil 5.8.	**300PS E1 J1 CO_2 için eğitim seti ve doğrulama seti için doğruluk oranı değişimi**	**98**
Şekil 5.9.	**300PS E1 J1 CO_2 için eğitim grafiği**	**99**
Şekil 5.10.	**300PS E1 J1 CO_2 için test grafiği**	**100**
Şekil 5.11.	**300PS E1 J1 CO_2 için validasyon grafiği**	**100**
Şekil 5.12.	**300PS E1 J1 CO_2 için tüm veriler grafiği**	**101**
Şekil 5.13.	**Briggs ve Stratton Vanguard güç (P) için eğitim seti, doğrulama seti mutlak hata değişimi**	**114**
Şekil 5.14.	**Briggs ve Stratton Vanguard güç (P) için eğitim seti ve doğrulama seti için R-kare mutlak hata değişimi**	**114**
Şekil 5.15.	**Briggs ve Stratton Vanguard güç (P) için eğitim grafiği**	**115**
Şekil 5.16.	**Briggs ve Stratton Vanguard güç (P) için test grafiği**	**116**
Şekil 5.17.	**Briggs ve Stratton Vanguard güç (P) için validasyon grafiği**	**116**
Şekil 5.18.	**Briggs ve Stratton Vanguard güç (P) için tüm veriler grafiği**	**117**
Şekil 6.1.	**300PS E1 J1 dizel motor giriş ve çıkış parametreleri**	**125**
Şekil 6.2.	**300PS E1 J1 dizel motor parametrelerin terslenmesi**	**125**
Şekil 6.3.	**Afr bulanık *c*-ortalamaları kullanarak oluşturulan ANFIS**	**133**
Şekil 6.4.	**Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS eğitiminden bir görüntü**	**134**
Şekil 6.5.	**Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS eğitimi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması**	**134**
Şekil 6.6.	**Bulanık c-ortalamalar ile elde edilen afr çıkış**	**135**

	parametresinin ANFIS testi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması	
Şekil 6.7.	Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS kural ve sonuç ara yüz ekranı	136
Şekil 6.8.	K-ortalamalar ve ANFIS ile Pb parametresi için eğitim seti 1 eğitim sonuçları	138
Şekil 6.9.	K-ortalamalar ve ANFIS ile Pb parametresi için test seti 1 test sonuçları	139
Şekil 6.10.	Briggs ve Stratton Vanguard benzinli motor giriş ve çıkış parametreleri	141
Şekil 6.11.	Briggs ve Stratton Vanguard benzinli motor parametrelerin terslenmesi	141
Şekil 6.12.	Devir bulanık *c*-ortalamaları kullanarak oluşturulan ANFIS	145
Şekil 6.13.	Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS eğitimi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması	146
Şekil 6.14.	Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS testi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması	146
Şekil 6.15.	Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS kural ve sonuç ara yüz ekranı	148
Şekil 7.1	Genetik algoritmanın temel birimleri	153
Şekil 7.2.	NSGA II prosedürü	159
Şekil 7.3.	Yakıt optimizasyonu için tasarlanan GA programı	161
Şekil 7.4.	Tam yükte tüm devirlerde minimum yakıt tüketimi için maksimum güç noktalar	165
Şekil 7.5.	Tam yükte tüm devirlerde maksimum güç için minimum özgül yakıt yakıt tüketim noktaları	165
Şekil 7.6.	Tam yükte tüm devirlerde güç için deneysel motor verileri	166
Şekil 7.7.	Tam yükte tüm devirlerde özgül yakıt tüketimi için deneysel motor verileri	166
Şekil 7.8.	Minimum NO_x ve özgül yakıt tüketimi için optimum sfc değerleri	168
Şekil 7.9.	Minimum NO_x ve özgül yakıt tüketimi için optimum NO_x değerleri	168
Şekil 7.10.	Minimum NO_x ve özgül yakıt tüketimi için optimum güç değerleri	168
Şekil 7.11.	Minimum NO_x ve özgül yakıt tüketimi için optimum tork değerleri	169
Şekil 7.12.	Minimum NO_x ve özgül yakıt tüketimi için optimum HC değerleri	169
Şekil 7.13.	Tam yükte tüm devirlerde NO_x için deneysel motor verileri	169
Şekil 7.14.	Tam yükte tüm devirlerde tork için deneysel motor verileri	170
Şekil 7.15.	Tam yükte tüm devirlerde HC için deneysel motor verileri	170
Şekil 7.16.	Maksimum güç için tüm devirlerdeki minimum yakıt noktaları	172

Şekil 7.17.	**Sıfır avans ve tüm devirlerde minimum yakıtta elde edilen maksimum güç noktaları**	**173**
Şekil 7.18.	**Sıfır avans ve tüm devirlerde deneysel olarak elde edilen özgül yakıt tüketim değerleri**	**173**
Şekil 7.19.	**Sıfır avans ve tüm devirlerde deneysel olarak elde edilen güç değerleri**	**173**
Şekil 7.20.	**Minimum HC için tüm devirlerdeki minimum yakıt noktaları**	**175**
Şekil 7.21.	**Minimum yakıtta tüm devirlerdeki minimum HC noktaları**	**175**
Şekil 7.22.	**1000 devir için 6 çıkış parametresinin aynı anda optimizasyonu**	**176**
Şekil 7.23.	**Dizel motor için tam yükte optimum yakıt tüketim noktaları**	**178**
Şekil 7.24	**Dizel motor için tam yükte optimum yakıtta NO_x değerleri**	**178**
Şekil 7.25.	**Dizel motor için tam yükte optimum yakıtta HC değerleri**	**178**
Şekil 7.26.	**Dizel motor için tam yükte optimum yakıtta güç değerleri**	**179**
Şekil 7.27.	**Dizel motor için tam yükte optimum yakıtta tork değerleri**	**179**

TABLOLAR LİSTESİ

Tablo 4.1.	**300PS E1 J1 çıkış parametrelerinin girişlere bağlı olarak Çoklu-regresyon denklemleri**	**70**
Tablo 4.2.	**300PS E1 J1 çıkış parametrelerinin çoklu-regresyonla modellenmesi test hatası**	**71**
Tablo 4.3.	**Briggs ve Stratton Vanguard çıkış parametrelerinin girişlere bağlı olarak Çoklu-regresyon denklemleri**	**75**
Tablo 4.4.	**Briggs ve Stratton Vanguard çıkış parametrelerinin çoklu-regresyonla modellenmesi test hatası**	**75**
Tablo 5.1.	**300PS E1 J1 CO_2 çıkış parametresi için 6 farklı eğitim ve test seti ANFIS hata sonuçları**	**80**
Tablo 5.2.	**300PS E1 J1 için tüm çıkış parametrelerinin ANFIS uygulaması eğitim ve test hatası**	**83**
Tablo 5.3.	**Briggs ve Stratton Vanguard güç (P) çıkış parametresi için 6 farklı eğitim ve test seti ANFIS hata sonuçları**	**84**
Tablo 5.4.	**300PS E1 J1 için tüm çıkış parametrelerinin ANFIS uygulaması eğitim ve test hatası**	**87**
Tablo 5.5.	**Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Gaussian aktivasyonlu ÇKP mimarisi sonuçları**	**88**
Tablo 5.6.	**Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı HyperSecant aktivasyonlu ÇKP mimarisi sonuçları**	**89**
Tablo 5.7.	**Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Hypertangent aktivasyonlu ÇKP mimarisi sonuçları**	**89**
Tablo 5.8.	**Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid aktivasyonlu ÇKP mimarisi sonuçları**	**90**
Tablo 5.9.	**Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Hyper-Tangent aktivasyonlu ÇKP mimarisi sonuçları**	**91**
Tablo 5.10.	**Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Gaussian aktivasyonlu ÇKP mimarisi sonuçları**	**91**
Tablo 5.11.	**Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Hyper-Secant aktivasyonlu ÇKP mimarisi sonuçları**	**92**
Tablo 5.12.	**Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid aktivasyonlu ÇKP mimarisi sonuçları**	**92**
Tablo 5.13.	**Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid-Hyper-Tangent aktivasyonlu ÇKP mimarisi sonuçları**	**92**
Tablo 5.14.	**CO_2 birinci eğitim seti kullanılarak yapılan eğitim sonucu elde edilen eğitim hata, doğruluk ve R-kare değerleri**	**95**
Tablo 5.15.	**CO_2 birinci test seti kullanılarak yapılan eğitim sonucu elde edilen test hata, doğruluk ve R-kare değerleri**	**96**
Tablo 5.16.	**CO_2 birinci validasyon seti kullanılarak yapılan eğitim sonucu elde edilen doğrulama hata, doğruluk ve R-kare değerleri**	**96**
Tablo 5.17.	**CO_2 birinci eğitim seti kullanılarak yapılan eğitim sonucu eğitim, test, ve doğrulama için kullanılan tüm noktaların hata, doğruluk ve R-kare değerleri**	**97**
Tablo 5.18.	**CO_2 için 10 farklı eğitim, doğrulama ve test seti**	**102**

kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Tablo 5.19. CO_2 için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 102
Tablo 5.20. HC için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 103
Tablo 5.21. HC için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 104
Tablo 5.22. NO_x için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 104
Tablo 5.23. NO_x için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 105
Tablo 5.24. Güç (P) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 105
Tablo 5.25. Güç (P) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 106

Tablo 5.26. Özgül yakıt tüketimi (Sfc) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 106
Tablo 5.27. Özgül yakıt tüketimi (Sfc) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 107

Tablo 5.28. Tork (Tq) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 107
Tablo 5.29. Tork (Tq) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 108
Tablo 5.30. 300PS E1 J1 çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama R-kare değerleri 109
Tablo 5.31. 300PS E1 J1 çıkış parametrelerinin YSA ile modellenmesi 109

sonucu elde edilen ortalama doğruluk oranları (%)
Tablo 5.32. Güç (P) birinci eğitim seti kullanılarak yapılan eğitim sonucu elde edilen eğitim hata, doğruluk ve R-kare değerleri 112
Tablo 5.33. Güç (P) birinci test seti kullanılarak yapılan eğitim sonucu elde edilen test hata, doğruluk ve R-kare değe 112
Tablo 5.34. Güç (P) birinci validasyon seti kullanılarak yapılan eğitim sonucu elde edilen doğrulama hata, doğruluk ve R-kare değerleri 112
Tablo 5.35. Güç (P) birinci eğitim seti kullanılarak yapılan eğitim sonucu eğitim, test, ve doğrulama için kullanılan tüm noktaların hata, doğruluk ve R-kare değerleri 113
Tablo 5.36. Güç (P) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 118
Tablo 5.37. Güç (P) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 118
Tablo 5.38. HC için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 119
Tablo 5.39. HC için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 119
Tablo 5.40. Özgül Yakıt Tüketimi (Sfc) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 120
Tablo 5.41. Özgül Yakıt Tüketimi (Sfc) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 120
Tablo 5.42. Tork (Tq) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri 121
Tablo 5.43. Tork (Tq) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri 121
Tablo 5.44. Briggs ve Stratton Vanguard çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama R-kare değerleri 122
Tablo 5.45. Briggs ve Stratton Vanguard çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama doğruluk oranları (%) 122
Tablo 6.1. Bulanık *c*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin optimal küme 126

	sayısının *PBM* ile belirlenmesi	
Tablo 6.2.	***K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin optimal küme sayısının siluette ile belirlenmesi**	**127**
Tablo 6.3.	**Bulanık *c*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme merkez sayıları ve merkezleri**	**128**
Tablo 6.4.	***K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme sayısı ve merkezleri**	**129**
Tablo 6.5.	**CO_2 için 26 küme merkezinden oluşan yeni set (bulanık *c*-ortalamalar) ve orijinal set**	**130**
Tablo 6.6.	**CO_2 için 25 küme merkezinden oluşan yeni set (*k*-ortalamalar) ve orijinal set**	**131**
Tablo 6.7.	**300PS E1 J1 dizel motorun Bulanık *c*-ortalamalar ve ANFIS ile tersten modelleme sonuçları**	**137**
Tablo 6.8.	**300PS E1 J1 dizel motorun *K*-ortalamalar ve ANFIS ile tersten modelleme sonuçları**	**138**
Tablo 6.9.	**300PS E1 J1 dizel motorun Bulanık *c*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları**	**140**
Tablo 6.10.	**300PS E1 J1 dizel motorun *K*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları**	**140**
Tablo 6.11.	**Bulanık *c*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin optimal küme sayısının *PBM* ile belirlenmesi**	**142**
Tablo 6.12.	***K*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin optimal küme sayısının siluette ile belirlenmesi**	**143**
Tablo 6.13.	***K*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin küme merkez sayıları ve merkezleri**	**143**
Tablo 6.14.	***K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme sayısı ve merkezleri**	**144**
Tablo 6.15	**Briggs ve Stratton Vanguard benzinli motorun bulanık *c*-ortalamalar ve ANFIS ile geri yönlü aralıksal modelleme sonuçları**	**149**
Tablo 6.16.	**Briggs ve Stratton Vanguard benzinli motorun *k*-ortalamalar ve ANFIS ile geri yönlü aralıksal modelleme sonuçları**	**149**
Tablo 6.17.	**Briggs ve Stratton Vanguard benzinli motorun bulanık *c*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları**	**150**
Tablo 6.18.	**Tablo 6.18. Briggs ve Stratton Vanguard benzinli motorun *k*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları**	**150**
Tablo 7.1.	**Tüm devirlerde tam yük için maksimum güç ve minimum yakıt tüketim noktaları**	**164**
Tablo 7.2.	**Tüm devirlerde motor deneyinden elde edilen tam yük için güç, yakıt tüketimi ve diğer değerler**	**164**

Tablo 7.3.	**Tüm devirlerde tam yük için minimum NO_x ve minimum yakıt tüketim noktaları**	**167**
Tablo 7.4.	**Tüm devirlerde tam yük için ölçülen deneysel NO_x , özgül yakıt tüketimi ve diğer değerler**	**167**
Tablo 7.5.	**Hazırlanan optimizasyon aracının farklı ağırlık değerleri için performansı**	**171**
Tablo 7.6.	**Tüm devirlerde sıfır avans için maksimum güç ve minimum yakıt tüketim noktaları**	**172**
Tablo 7.7.	**Tüm devirlerde sıfır avans için elde edilen deneysel motor verileri**	**172**
Tablo 7.8.	**Tüm devirlerde sıfır avans için minimum HC ve minimum yakıt tüketim noktaları**	**174**

SİMGELER ve KISALTMALAR

EMS	Engine Management System-Motor Kontrol Birimi
İYM	İçten Yanmalı Motor
YZ	Yapay Zeka Teknikleri
YSA	Yapay Sinir Ağları
HYO	Hava Yakıt Oranı
BUS	Bulanık Uzman Sistem
GA	Genetik Algoritma
BM	Bulanık Mantık
EH	Esnek Hesaplama
ANFIS	Uyarlamalı Bulanık Uzman Sistem
RBFN	Radyal Tabanlı Fonksiyon Ağı
BMK	Bulanık Mantık Kontrol
TWC	Üç Yönlü Katalitik Dönüştürücü
ATV	Tüm Arazi Araçları
CO_2	Karbon dioksit
HC	Hidro Karbon
NO_x	
P	Güç
Tq	Tork
Sfc	Özgül Yakıt Tüketimi
L	Yük
Cy	Hız
Afr	Hava Akış Oranı
Fr	Yakıt Oranı
Pb	Boost Basıncı

1. GİRİŞ

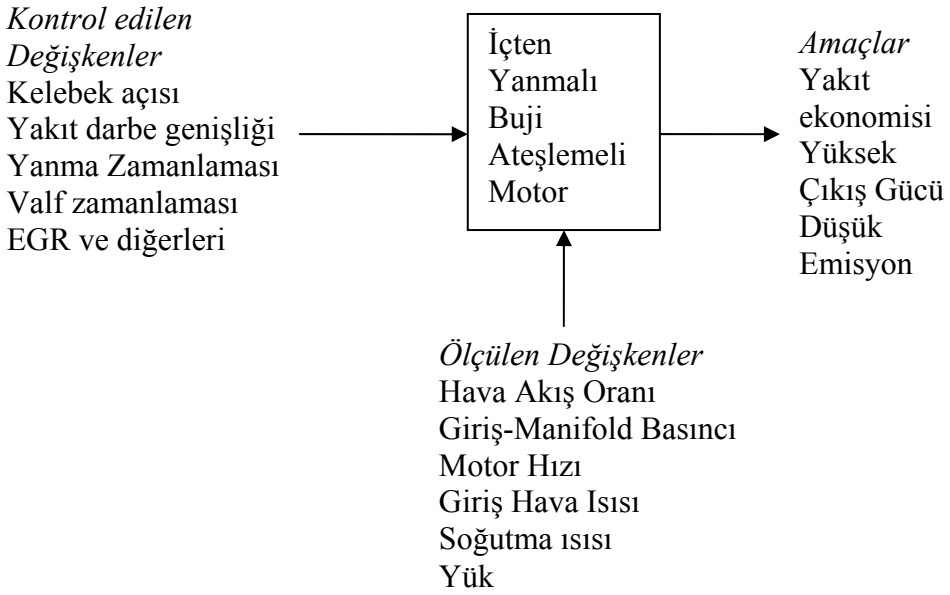
Emisyon standartlarını yakalamak ve gerekli yakıt optimizasyonunu sağlamak için motorun işlevsel parametrelerinin sıkı bir şekilde kontrolünün yapılması gerekmektedir. Motorlarda bu görevi yapan birim ise mikroişlemci tabanlı birim olan motor yönetim sistemi (EMS)-Engine Management System- olarak adlandırılır. EMS kontrol stratejisi maksimum çıkış gücü ve en iyi etkinliğin düşük emisyon dereceleri ile birlikte gerçekleştirmelidir. Aynı zamanda buji-ateşlemeli motorlarda EMS 3-yönlü katalitik dönüştürücünün işlemini gerçekleştirmesi için gerekli olan sınırlarda motorun çalışmasını sağlamalı ve bu yolla egzozda bulunan zararlı içeriklerin daha da azaltılmasını sağlamalıdır. Motor tüm bunlar olurken iyi bir geçiş cevabı ve sürülülebilirlik olarak da adlandırılan ve sürücünün gaz, vites ve kontrol komutlarına cevap anlamına gelen karakteristiğini de en iyi şekilde sergilemelidir.

EMS motora giden yakıt miktarını (*yakıt darbe genişliği* yoluyla), karışımın yanacağı motor devrindeki noktayı (*yanma zamanlaması*), yeniden sirküle edilen gaz miktarını (EGR) ve valf (*sübap*) zamanlaması gibi diğer ileri motor tasarım parametrelerini kontrol eder. Bu parametrelerin değerlerinin belirlenmesini hız, yük, tork, giriş manifold basıncı, farklı noktalardaki sıcaklıklar, hava kütle akış oranı ve kısma valfi (*kelebek*) açısı gibi ölçülen niceliklerden sağlamaktadır. Şekil 1.1'de EMS fonksiyonları ve bu fonksiyonların gerçekleştirilmesi için kullanılan değişkenler gösterilmiştir.

Ticari EMS ürünlerinde kullanılan stratejinin ayrıntılı detayları imalatçılar tarafından korunan bir sır gibidir. *Yakıt darbe genişliği* ve *yanma zamanının* belirlenmesinde EMS Look-up (bakma) tablolarına dayalı 3 boyutlu haritalama metodunu kullanır. Böylece motorun lineer olmayan gerçek zamanlı performansını sergilemesini sağlar. Buna ek olarak motor oldukça farklı ölçek ve tiplerde alıcılarla donanmıştır. Look-up tablo sunumunun en büyük dezavantajı en iyi motor operasyonunu belirlemek için gerekli değerlerin belirlenmesindeki zamanın çok olmasıdır ve bu işlem EMS'nin kalibrasyonu olarak bilinir. Kalibrasyon işlemi itelemeli ya da tekrarlamalı bir işlem olup birçok motor ölçüm devri içerir ve zaman

alıcıdır. Motor imalatçıları için kalibrasyon işlemindeki harcanan zaman ve eforun azaltılması için bulunacak teknikler oldukça fazla değer içermektedir.

EMS motorun hızını krank milinde bulunan bir alıcı vasıtası ile ölçer ve yükün yaklaşık değerini de giriş manifold basıncını kullanarak dolaylı olarak hesaplar. Algoritmik ve matematiksel metotlar bu hesaplamalarda kullanılır. Araştırmalar tam bu noktada devreye girmekte ve geliştirilmiş ileri motor kontrolü YSA ve diğer YZ teknikleri ile yapılıp EMS sistemine entegre edilmeye çalışılınmaktadır.



Şekil 1.1. EMS ve fonksiyonları

1.1. Motor Performans ve Emisyon Karakteristiğinin Belirlenmesi ve Temelleri

Otomotiv tasarım alanında üç ana tema bulunmaktadır:

Yakıt ekonomisi,
Egzozdan yayılan zararlı emisyonun azaltılması,
Yukarıdaki iki faktör gerçekleştirilirken güç performansının da düşmemesi.

İçten yanmalı motorlarda hava/yakıt oranının (HYO) ve yanma zamanlamasının elektronik olarak kontrol edilmesi hem egzoz emisyonunun azaltılması hem de etkin yanmayı sağlar. HYO motorun işlevsel (operasyonel) noktasını, yanma zamanlama açısını, çıkış gücünü ve emisyon derecesini belirler.

Elektronik kontrollü bir motorda, motora sağlanan yakıtın miktarı EMS tarafından belirlenir. EMS bu işlemi yakıt enjektörüne uygulanan kontrol darbelerinin frekansı ve genişliğini kontrol ederek gerçekleştirir. HYO yanma ve kalibrasyon işlemleri için oldukça önemlidir. Karışımda çok fazla yakıt olursa yüksek yakıt tüketimi ve yüksek miktarda HC ve CO emisyonuna yol açar. Az miktardaki yakıt karışım oranı ise aşırı miktarda ısıya ve motorun yanmış egzoz valflerine sahip olması gibi hasara sahip olmasına yol açar.

EMS'nin amacı motorun sürekli izlenmesi ve gerektiğinde anında düzeltme ayarlamalarının yapılmasıdır.

Yanmanın izlenmesi için yaygın olarak kullanılan iki metot vardır.

1- Yanma basıncına bağlı olan analiz metodu
2- Gazda bulunan iyonik akım analiz metodu

Fakat bu iki değerin ölçülmesi beraberinde bir takım problemler doğurur. Yanma basıncının ölçülmesi için kullanılan alıcılar (sensörler) yüksek maliyetlidirler ve bu süreç esnasında güvenilirlik problemi mevcuttur. Nicelik sabit kalsa bile her

zaman aynı sonuçları vermemekte ve hata toleransları yüksek olmaktadır. Dahası, kurulumları yanma odasının şeklinde değişiklik gerektirdiğinden, motorun performansının azalması sonucunu doğururlar. Benzer problem yanma gazlarındaki iyonik akımın incelenmesinde kullanılacak alıcılarda da görülür. Pahalı olan ve kolay bozulmaya eğilimli yüksek voltajlı diyotlar sıklıkla kullanılır ve bunlarda düşük doğruluk payına sahiptir.

1.2. Motor Performans ve Emisyon Karakteristiğinin Belirlenmesinde Karşılaşılan Problemler

Aşağıda maddeler halinde motor performans ve emisyon karakteristiğinin belirlenmesinde önemli sorunlar sıralanmıştır. Görüldüğü üzere bu sorunların temelinde HYO'nın hassas bir şekilde belirlenmesi yatmaktadır. HYO'nın yapısı ve oluşturduğu problemler ise;

-Motor deneylerinde HYO için sadece belirli noktalarda ölçümler yapılmakta olup ara değerler için ölçüm yapılmamaktadır.

-HYO'nın belirlenmesinde matematiksel modelleme yapılamaz ve yapısı itibariyle doğrusal değildir.

-HYO'nın kontrolü emisyon, güç ve tork değerlerinin de kontrolü olduğundan yüksek hassasiyetle değeri belirlenmelidir.

-Motorlarda, EMS'nin HYO ve diğer parametreler için yaptığı kalibrasyon zamanı oldukça fazladır. Ve bu kalibrasyona rağmen bazen optimum HYO, tork ve emisyon değeri elde edilemez.

-Daha hassas bir kontrol sistemi için ek sensörlere ihtiyaç duyulur. Ama sensörler oldukça maliyetli olup bir kısmının monte edilmesi için motor yanma ekipmanlarında yapısal değişikliğe gerek duyulur. Buda beraberinde ek maliyet getirir.

Maliyetleri oldukça yüksek bu faktörlerin giderilmesi için ise yapılmakta olan modelleme ve kontrol çalışmalarının birçoğunda YZ teknikleri üzerinde

yoğunlaşılmaktadır. Doğrusal olmayan veriler üzerinde işlem yapan, uzmanların deneyimlerini kullanan, ek sensörlere gerek duymadan eldeki verilerle yüksek doğrulukta tahmin ve modelleme yapan YZ teknikleri daha az maliyet, zaman tüketimi ve de eldeki kaynaklarının optimum kullanımı anlamına gelmektedir.

1.3. Çalışmanın Amacı ve Önemi

Son yirmi yıldır, motorlu araçlarda kullanılan içten yanmalı motorların üreticileri, ürünlerinin çevreye zararlı yan etkilerini çok başarılı bir şekilde azaltmışlardır. Buna rağmen motordan yayılan kirli gazların miktarının daha fazla azaltılması ve kilometre başına düşen yakıt tüketiminin düşürülmesi konusunda artan bir baskıyla karşı karşıya kalmaktadırlar. Aynı zamanda tüm bunlar yapılırken, sürücüler tarafından talep edilen motor karakteristiklerinden de taviz vermemek zorundadırlar. Bu farklı ihtiyaçların birlikte görülebilmesi ise etkin bir motor kontrolü ve güç biriminin işlevsel parametrelerinin etkin bir şekilde denetlenmesi gerekmektedir. Motorlar da geliştirilmiş kontrolün yapılabilmesi için gerekli olan ileri düzeyde ölçümün sağlanabilmesi için ek alıcılara (sensörlere) ihtiyaç duyulduğundan ötürü finansal zorluklarla karşılaşılmaktadır. Bilindiği gibi motorlarda yapılacak küçük değişikliklerin genel maliyete katkısı çok yüksek olabilmektedir. Bütün bu sebeplerden ötürü var olan alıcılar ve motor parçalarıyla farklı teknikler ve metotlar kullanılarak yapılacak olan araştırmaların önemi maliyet açısından git gide artmaktadır. İlgili ölçüm niceliklerinin dolaylı olarak hesaplanması esasına dayanan sanal alıcı teknikleri dikkate değer potansiyele sahip araştırmaların konusudur. YSA gibi YZ teknikleri, desen tanıma, sinyal analizi ve yorumlama ya da sonuç çıkarma gibi özellikleriyle bu alanda uygulanmalarını cazip kılmaktadırlar. Bu sebepten ötürü, motorlu araçların kontrol ve denetlenmesi alanında YZ kullanımı hem akademik hem de ticari araştırma çevrelerinde dikkate değer bir şekilde artış göstermektedir.

Tüm bunların dışında motorlar ile ilgili yapılan deneyler oldukça zaman alıcı olmaktadır. YZ teknikleri ile oluşturulan sistemlerden elde edilen simülasyon

sonuçları göstermiştir ki, uzun süren deneyleri yapmak yerine oluşturulan sisteme eldeki veriler girdi olarak sunulabilir ve çıkışlar çok kısa zamanda elde edilebilir. Böylelikle öğrenciler ve araştırmacılar için modelleme konusunda zamanın etkin kullanılması sağlanılacaktır.

Bu ve benzeri çalışmalarda geliştirilecek olan yeni teknikler ile yüksek maliyete sahip olan ve motorun modifiyesini gerektiren sensörler yerine yüksek doğruluk oranına sahip ve deneysel sonuçlara yaklaşık sonuçlar veren sistemler (uygulanan teknik ve bu tekniği çalıştıran mikroişlemci gibi) oluşturulabilir. Buda beraberinde daha düşük maliyete sahip ve daha hassas motorlara sahip olunmasını sağar.

Motorlarda yapılan deneylerde sadece belirli devirler için ölçüm yapılır ve bu ölçümler bir tablo halinde kaydedilir. EMS bu tablyou kullanarak kullanıcının isteğine, yol durumuna, yüke ve diğer çevresel şartlara (hava sıcaklığı vb) bağlı olarak silindire alınan yakıt miktarını, yanma odası sıcaklığını vb değerleri ayarlar. Sadece belirli devirlerde ölçüm yapıldğı için bu devirler arasında kalan diğer devirler için EMS yine aynı tabloyu kullanır ve interpolasyon yöntemi ile yaklaşık hesaplama yapar. Bundan ötürü günümüzde taşıtlarda yakıt optimizasyonu için Ortak yollu dizel püskürtme (CRDI) gibi yeni çözümler üretmeye çalışmaktadır. Buda donanımsal değişiklik anlamına gelip uzun süren AR&GE çalışmaları ve yüksek maliyet içermektedir. Bu çalışmada kullanılan YZ teknikleri ile yapılacak modelleme ve benzeri çalışmalarla yapılacak olan modellemelerle ara devirler ve yukarıda bahsedilen etmenlerin de (sürücü isteği vb.) içinde bulunduğu şartlarda uygun yakıt miktarı, güç değeri vb. belirlenebilecektir. Dinamik olarak çalışacak sistem sayesinde EMS bu verilere göre yakıt miktarı vb. değişkenleri ayarlayarak çıkış parametrelerini optimum aralıkta tutabilecektir.

Yakıt ve emisyon optimizasyonu sayesinde tasarruf, ülke ekonomisine katkı, çevreye hassasiyet artacaktır. Günümüzde çamaşır makinelerinden, bulaşık makinelerine ve daha birçok elektronik ev/iş aletlerine uygulanan Bulanık Uzman Sistem (BUS) sayesinde su ve enerji tasarrufu yapılabilmektedir.

YZ tekniklerinin tümü için geliştirilebilecek olan mikroişlemciler sayesinde bu çalışma ve benzeri çalışmalarda yazılımsal olarak gerçekleştirilen motor performans ve emisyon modellemesi realize edilebilecektir.

1.4. Literatür Araştırması

YZ tekniklerinin İçten Yanmalı Motorların (İYM) performansının kontrolü ve modellenmesi ile ilgili çalışmalar, ilerleyen satırlarda görüleceği üzere YSA, GA, BM ve bunların çeşitli karışımları olan Esnek Hesaplama (EH) olmak üzere alt dallara ayrılabilir. Bu tekniklerin ayrı ayrı yada kombinesinin uygulanması ile oluşan çalışmaların listesi aşağıda alt başlıklarda toplanmıştır.

YSA'nın İYM performans kontrolünde kullanımı:

Gelişmiş motor kontrol sistemleri, doğrusal olmayan yanma işleminin dinamik modellemesinin yüksek doğrulukta olmasını gerektirmektedir. Hafner ve ark. (2000) tarafından geliştirilen hızlı YSA uygulaması dizel motor kontrol tasarımı amacı ile yapılmıştır. Yapılan çalışmada özel lokal lineer radyal tabanlı fonksiyon ağı (LOLIMOT) hakkında giriş yapılmış ve uygun dinamik motor modellerinin geliştirilme işlemi tanımlanmıştır. Bu YSA modelleri daha sonra bir üst düzey emisyon optimizasyon aracına entegre edilmiş ve egzozun yakıt tüketimi/torka karşı maliyet fonksiyonunu hesaplayan ve optimal motor ayarlarını belirleyen bölüm tamamlanmıştır. Yazarlara göre sistem optimizasyon aracı motor test standında hızlı cevap verecek şekilde uygulanmış ve gerçek zamanlı motor verileriyle yüksek oranda uygunluk sağlamıştır.

Heister ve Froehlich (2001) tarafından yapılan çalışma ile yanma basınç verilerinin doğrusal olmayan zaman serisi analizi yapılmıştır. Öncelikle, YSA ve uyarlamalı algoritmaların karmaşık teknik sorunların çözümünde yaygın bir şekilde kullanılmasının bir özeti yapılmıştır. YSA'nın giriş/çıkış veri çiftlerinin tanımlanmasında ortak (karşılıklı) bilginin kullanılmasının önemi üzerinde

durulmuştur. YSA'nın eğitim probleminin, verilen problemin sunumu anlamına gelen uygun bilgi içeriğini tanımlayan giriş/çıkış verisinin belirlenmesi olduğu üzerinde durulmuştur. Ayrıca YSA yapısının eğitilmesi, giriş/çıkış sinyalleri arasında fonksiyonel bağımlılığın olmadığı durumlarda (rasgele, stokastik, vb) yetersiz sonuçlar vereceği belirtilmiştir. YSA kullanılarak genel ve nitelikli bir metot ile içten yanmalı bir motorun ölçülen geçişkenlik verileri arasında en uygun noktaların tanımlanmasının ispatı yapılmıştır. Bu bağlamda, bir yanma devri süresince oluşan ve yalnızca yanma odasındaki basınçtaki bir noktada gerçekleşen %50'lik enerji dönüşüm noktasının ortak bilgi (giriş-çıkış verileri arasındaki karşılıklı bilgi) kullanılarak YSA ile tespiti gösterilmiştir.

Isermann and Hafner (2001) mekatronik İYM'ların optimal kontrolü için gerçekleştirdikleri çalışmada öncelikle mekatronik sistemleri genel olarak gözden geçirmişlerdir. Bilindiği gibi mekatronik sistemler mekanik, elektromekanik, elektronik parçalar ve yazılım tabanlı fonksiyonların entegre edildiği sistemler olarak bilinirler. Mekatronik motorlarda kalibrasyon ve parametre ayarı hayati önem taşıdığından yapılan bu çalışmada YSA ile özel olarak tasarlanan motor deneylerinden elde edilen veriler kullanılarak motorun modellenmesi, performansının iyileştirmesi ve optimizasyonu gerçekleştirilmiştir. Motor modelleri daha sonra yakıt tüketimi ve emisyon için çoklu-nesneli performans kriterleri ile birlikte kullanılarak motor kontrolünün statik ve dinamik optimizasyonu sağlanmıştır. Egzoz-gaz devir daimli ve değişken geometrili turbo-yükleyicili dizel motorlar için elde edilen sonuçlar gösterilmiştir. Ayrıca model tabanlı kontrol sistemlerinin gerçekleştirilmesi ve hızlı kontrol prototip sistemleri ile test edilmesi de sunulmuştur.

Park ve ark. (2001) yaptıkları çalışma ile kıvılcım yanmalı motorlarda en tepe basınç değerinin lokasyonuna dayalı (location of peak pressure- LPP) gelişmiş bir kıvılcım kontrol stratejisinin YSA kullanılarak gerçekleştirilmesini göstermişlerdir. Problem ise çok sayıda örnek veriye ihtiyaç duyulması ve yanma işleminin zayıf gerçekleşmesi süresince *geri kancalamaya* sahip olan yanma fazının bulunmasıdır. Bu problemleri çözmek için çok katmanlı perseptron (ÇKP) ağı geliştirilmiştir. LPP ve geri kancalam tahmini hesaplaması ise silindir basınç sensöründen beş adet çıkış voltajına ihtiyaç duyan ÇKP ağı ile sağlanmaktadır. Tahmini hesaplanan LPP yanma

fazı bir indeks olarak düşünülebilir. Ayrıca en iyi tork kontrol parametresi için minimum kıvılcım oranı olarak da düşünülebilir. Geliştirilen sistem gelişmiş kıvılcım kontrolünün performansının arttırılması için motor hızı ve manifold mutlak basıncındaki beklenmedik değişimleri yansıtacak şekilde ileri yönlü bir kontrol olarak kullanılabilir. İleri yönlü kontrolör Radyal tabanlı fonksiyon ağını (RBFN) kullanır. Buna ek olarak hazırlanan kontrol algoritması sensör ayarlamasına ve pegging (sabitleştirme) yordamına gerek duymaz. Çünkü ÇKP ağı LPP'yi sensör çıkış voltajından elde eder. Gelişmiş kıvılcım kontrolünün metodolojisinin uygunluğu ise motorun sabit ve geçişken çalışma durumlarının çok yakından izlenmesiyle deneysel olarak gözlemlenmiştir. Deneysel sonuçlar LPP'nin motorun geçişken çalışma durumunda bile optimal değere ulaştığını göstermektedir.

Li ve Yurkovich (2000) uyarlamalı kayan-mod kontrol tasarım metodunu parçalı, doğrusal olmayan sistemler ve dinamik bilgisi açıkça verilmeyen sistemler için geliştirmişlerdir. Üç katmanlı ileri yönlü YSA, bilinmeyen dinamikler için fonksiyon yakınlaştırıcısı olarak kullanılmıştır. Kontrol kuralı yakınlaştırıcının çıktılarına dayalı olarak tasarlanmıştır. Ve kayan yüzey ise sistemin çıktılarının kararlılık polinomuna göre belirlenmiştir. Durum iz düşümlerinin küçük bir kayan sektöre yakınlaşması ispatlanmıştır. Metot İYM'larda boşta hız kontrol problemi için uygulanmıştır.

Sharkey ve ark. (2000) tarafından yapılan çalışmada dizel motorlarda yanma ile ilgili hataların önceden uyarılmasını sağlayan çoklu ağa sahip bir sistem tasarlanmıştır. İki hata (egzoz vana sızıntısı ve yakıt püskürtme memesi sızıntısı) bir motorda farklı zamanlarda fiziksel olarak oluşabilir. Basınç dönüştürücüsü silindirdeki değişimin hem normal çalışma durumunda hem de yukarıda bahsedilen hatalı çalışma durumunda bir motor devri boyunca algılanmasını sağlar. Bu ölçümlere karşılık gelen veriler YSA da eğitim amaçlı olarak kullanılmıştır. YSA'nın motorun hatalı çalışması ve normal çalışması ayrımını yapması gerçekleştirilmiştir. Her bir ağ alt-konu için eğitilmiş ve birleştirilerek çoklu-ağ sistemi gerçekleştirilmiştir. Çoklu-ağ sisteminin oluşturulması için birleştirilen ağlar yada kısmi alt ağlar ile karşılaştırıldığında daha etkin bir şekilde işleve sahip olduğu görülmüştür. Ayrıca problem çözümünde konu uzmanı ve diğer bir teknik olan karar alma ağacı kullanılması durumu ile karşılaştırıldığında problemi alt dallara bölme,

her birisi için çözüm üretme ve bunları birleştirmeyi kısa zamanda gerçekleştirmesi açısından oldukça verimli bir sistem olduğu görülmüştür.

Thompson ve ark. (2001) sıkıştırma yoluyla yanmayı gerçekleştiren İYM için emisyon ve performans modellemesini gerçekleştirmişlerdir. Bu tip motorların kullanım alanı otobüs, kamyon, güç üretimi, lokomotif ve hibrit elekrikli araçlardır. Bu motorlardaki yanmanın kontrolü hem daha yüksek performans hem de emisyon standardını sağlamak için oldukça gereklidir. Geleceğin motorları var olan "tablo inceleme-haritalama" sistemlerinden daha karmaşık ve daha çok parametrenin yer aldığı kontrol sistemlerine sahip olacaktır. YSA tabanlı motor modelleri çok boyutlu, uygulamalı, öğrenmeli kontrol sistemleri olup geleneksel "tablo inceleme-haritalama" modellerinde ihtiyaç duyulan motor performans yönetim ve emisyonun kinetik yanma denklemlerine ihtiyaç duymamaktadır. YSA'nın ağır vasıta dizel motorların (Navistar T444E) çıkış torkunun ve egzoz emisyon modellemesinin yapıldığı bu çalışma sürekli tork ve egzoz emisyonunun tahmini hesaplanması gerçekleştirilmiştir. Bunun için Federal ağır vasıta motor değişken test prosedürü (FTP) devrinde, ayrıca 2 rasgele devirde ve 100 dakikalık geçişken dinamometre verilerinde eğitim ve test yapılmıştır. %5 sapma üreten YSA modellemesi gerçekleştirilmiştir.

Ortmann ve Glesner (1998) motorlarda ortaya çıkan vuruş (**knock)** olayının bulunması için YSA tabanlı bir model geliştirmişlerdir. Bilindiği üzere yakıt tüketiminin ve emisyonun azaltılıp performansın arttırılması için motorlarda genellikle sıkıştırma oranını arttırma yoluna gidilmektedir. Bu ise beraberinde motor vuruşunu ve uygun motor kontrol parametrelerinin bulunmasını gerektirmektedir. Bundan dolayı yüksek bir tahmin oranında ya da iyi bir öngörüyle motor vuruşunun hesaplanması araba üreticileri için zorunlu hale gelmiştir. Yapılan bu çalışmada kısa bir içerik özgeçmişi yapılmış ve hazırlanan gelişmiş öğrenme algoritmasının her bir devirde vuruşun bulunup ortaya çıkarılmasındaki rolü anlatılmıştır.

Muller ve ark. (1997) sensörlerden gelen verileri yanma zamanının kontrolünde kullanmış ve ölçülen verilerle YSA eğitilerek form faktörlerini belirlemiştir.. Hazırlanan algoritma gerçek zamanlı DSP işlemcilerinde hesaplanabilir ve çok az bir eforla yeni motorlara adapte edilebilir bir şekildedir.

Sharkey ve ark. (1996) tarafından yapılan çalışmada YSA simüle edilmiş veriyi baz alarak yanma kalitesini sınıflandırmak için eğitilmiştir. Dört farklı veri kullanılmıştır; basınç, sıcaklık, birleştirilmiş basınç ve birleştirilmiş sıcaklık. YSA'nın eğitilmesini takiben, dört farklı YSA topolojisi seçilmiş ve %100'lük doğruluk oranına sahip bir test kümesi genellemesi yapacak şekilde YSA'lar birleştirilerek bir sistem oluşturulmuştur. Burada farklı YSA çözümlerinin yaratılması deneylerini takiben en iyi sonuçların iki farklı sensörden (basınç ve sıcaklık) gelen verilerle ortaya çıktığı görülmüştür. Yazarlara göre bu sonuçlar diğer YSA uygulamaları için yapılan savları destekler mahiyette olup YSA'ların bu alanda kullanılmasını teşvik etmektedir.

DeNicolao ve ark. (1996) İYM'larda volumetrik ya da hacimsel etkinliğin geliştirilmesi üzerine çalışma yapmışlardır. Volumetrik etkinlik hava pompalama sisteminin etkinliğinin bir ölçüsüdür. 4 vuruşlu İYM'ların karakteristiği ve kontrolünde kullanılan parametrelerden en yaygın olanlardan bir tanesidir. Ve fiziksel modellemesi de genellikle normal çalışma şartlarında elde edilemeyen bazı niteliksel bilgilere ihtiyaç duyar. Bundan dolayı yalnızca "siyah kutu" yaklaşımı olarak bilinen ve sıklıkla hacimsel etkinliğin ana motor değişkenlerine bağlı olarak belirlenmesine dayalı metot kullanılır. Bu değişkenler arasında, krank mili hızı ve giriş manifold basıncı vardır. Bu çalışmada farklı siyah kutu yaklaşımlarının volumetrik etkinliğin hesaplanmasında kullanılması gözden geçirilmiştir. Bu yaklaşımlar, parametrik (polinom tipi) modellerden, parametrik olmayan modellere ve YSA tekniklerine (RBFN, ÇKP, vb.) kadar geniş alanı içermektedir. Bu yaklaşımların faydaları ve sınırlamaları araştırılmış ve karşılaştırılmıştır.

Stevens ve ark. (1995) paremetrik test planlarına göre avantajlı iki yaklaşım geliştirerek İYM'larda verinin kontrol amaçlı üretimi ve işlenmesi için gerekli maliyeti düşürmüşlerdir. Bilindiği gibi İYM'un performansının oldukça geniş çalışma şartları için 3 boyutlu olarak haritalanması geliştirme süresince yaygın olarak kullanılmaktadır. Yapılan bu çalışma ile yüksek maliyet gerektiren veri toplama ve işleme sürecinin düşürülmesi için, istatistiksel olarak tasarlanan test matrisini, motor kararlığını ve yanma performans parametrelerini eşleştirmek amacı ile kullanmışlardır. Bu yaklaşım gerekli test sayısını minimize etmiş ve işlem sonrası kullanılan teknikler değişkenler arasında var olan ilişkilerin ortaya çıkarılmasında

önemli katkılar sağlamıştır. Bu ise özellikle öncelik niteliksel eğilimlere kanalize olduğunda oldukça etkili ve faydalıdır. Büyük veri kümesi elde edilmeye ihtiyaç duyulduğunda ve değişkenler arası ilişkinin özel bir şekilde ele alınması gerektiğinde YSA ile veri işlemenin etkili bir yaklaşım olduğu bu çalışma ile gösterilmektedir. Bu tekniğin kullanımı motor emisyon ve durum değişkenleri arasındaki ilişkinin hesaplanmasında gerçekleşmektedir.

Morita (1993) petrol yakıtlı motorların yanma parametrelerinin optimizasyonu ile ilgili yaptığı bu çalışmada geleneksel tablo inceleme metodunun yanma parametrelerinin doğrusal olmayan karakteristiklerinin hesaplanmasındaki rolünü YSA ile değiştirmiştir. Ayrıca diğer metoda göre avantaj ve dezavantajlarını araştırmıştır. YSA ile yanma parametrelerinin gerçek zamanlı kontrolü sunulmuştur. Sonuç olarak YSA'nın tablo inceleme metoduna göre daha uygun olduğu tespit edilmiştir.

Korb ve ark. (1999) bir gazlı motorun dinamik modellenmesini YSA kullanarak gerçekleştirmişlerdir. Ayrıca bu modellemeyi hız kontrol sistemi tasarımında kullanmışlardır. Kullanılan YSA topolojisi iki giriş/tek çıkışlı RBFN'dir. RBFN merkezleri adım-genişliği, dikleştirme algoritması ve giriş uzay sıkıştırması kullanılarak seçilmiş ve böylece ayrık veri kümelerinden kaçınma sağlanmıştır. Gaz motor modelinde model hatalarının oluşumunu bulmak amacıyla gürültü verisinin etkisi doğrusal olmayan sistem örneği ile incelenmiştir. Doğrusal olmayan RBFN modelinin kalitesi ölçülen ve simüle edilen verilerin karşılaştırılmasıyla gösterilmiştir.

Howlett ve ark. (1996)'da yaptığı çalışmada bir YSA'nın buji ateşlemeli motorlarda durum izleme ya da teşhis için uygun bir teknik içerisinde kullanılmasını tanımlamaktadır. Kullanılan metot ise normal çalışma şartlarında ateşleme bujisindeki voltaj ve akım değişimini ve YSA analizini içermektedir. Bu teknik kullanılarak yapılan testlerde elde edilen dalga formları, motorun ayarlanmasıyla ilişkili olan HYO, yanma zamanı gibi bilgileri de içermektedir. Veri kazanımının bu şekilde olması diğer tekniklerle karşılaştırıldığında oldukça kolay ve sağlıklıdır. Yapılan çalışmada görülmüştür ki YSA eğitilerek veri soyutlaması sağlanılabilir ve

bu sinyaller üzerinde yapılan analizler HYO'nın belirlenmesinde (%99 doğru sınıflandırma) önemli rol oynar.

Howlett (1998) yukarıda anlatılan çalışmalarında geliştirdikleri YSA'nın eğitimi sırasında HYO'nının değerini düzenli olarak sabit tutmak için bulanık mantık (BM) paradigmasını kullanan bir kontrol mekanizmasını geliştirmişlerdir. Elle değiştirilen HYO, dinamometre ile hız ve yük değişimi, Intel 82C54'ün yakıt darbe genişliğini ayarlaması sistemin en önemli noktalarıdır. Yük ve hız sabit tutularak farklı λ değerleri için kıvılcım dalga boyları örneklenmiştir. Bu veri ise YSA'nın eğitimi için kullanılmıştır. ÇKP ve RBFN mimarisine sahip YSA kullanılarak ilişkili λ için dalga şeklinin düzeltilmesi sağlanmıştır.

Arcaklıoğlu ve ark. (2005) dizel bir motorun performans ve emisyon karakteristiğinin belirlenmesi için YSA tekniği kullanmışlardır. Farklı silindir basıncı ve kelebek açılarında motorun performans ve emisyon değerlerini ÇKP topolojisine sahip YSA kullanarak modellemişlerdir.

Genetik Algoritmaların (GA) İYM'larda kullanımı:

Polifke ve ark. (1998) basitleştirilmiş reaksiyon mekanizmaları için oran katsayılarının optimizasyonunu GA kullanarak gerçekleştirmişlerdir. Gaz tribün yakıcılarındaki akış oldukça türbülenttir (kontrolsüz). Optimizasyonun amacı, basitleştirilmiş ve detaylı kinetik mekanizmaların sıcaklık yayılmalarının üretim oranlarının eşleştirilmesidir. Bir GA, popülasyon sayısı 24 ve nesil başına 64 çocuk olacak şekilde yapılandırılmış ve eşleştirme prosedürü kullanılmıştır. GA tipik olarak birkaç yüz üretimden sonra çok az CPU zamanı harcayarak işlemi durdurur. Sıcaklık ve ana türler ile ara türlerin tepe değerleri detaylı kinetik mekanizmadan elde edilen ile çok iyi şekilde eşleşmiştir. Bu da yanma hızının iyi bir doğrulukla yeniden üretilmesini sağlamıştır. Yazarlara göre, optimize edilen mekanizma sayısal olarak sağlam ve etkili olmakla kalmayıp esnekliği ve kolay kullanılmasından ötürü uygun bir yaklaşım metodudur.

Gielmo ve Santini (2001) İYM'da ılıklaştırma fazı için 3 yönlü katalitik dönüştürücü (TWC) modeli geliştirmişlerdir. İYM ve 3 yönlü TWC'lerden oluşan

sistemlerin kontrolü emisyon için getirilen düzenlemelerde hayati önem taşımaktadır. Burada karşılaşılan önemli problemlerden birisi ise ılıklaştırma fazına geçişte henüz TWC çalışmıyorken yüksek miktarda kirliliğin havaya yayılmasıdır. Bunu engellemek için yapılan bu çalışmada ılıklaştırma kontrol stratejisinin tasarım ve testi için oldukça basit bir dinamik termokimyasal TWC modeli geliştirilmiştir. Bu model art asimptot yaklaşımının daha detaylı modeli olup gaz ve çıkarım eğiliminin arasındaki soğurma katsayısının sonsuza gitmesine izin veren metottur. Dahası yazarlar kısmen quasi-doğrusal hiperbolik parçalı diferansiyel denklem için karakteristik metodu ve kısmen de doğrusal uzay ayrımına dayalı hızlı entegrasyon algoritmasını da bu çalışmada sunmuşlardır. Böylelikle sistemin iki zamanlı ölçek analizi kullanılarak yukarıda bahsedilen ayrışma sağlanır. Model bu amaçla tasarlanan GA ile birlikte tanımlanmış ve geçerliliği deneysel veriler üzerinde kanıtlanmıştır.

Bulanık Mantığın (BM) İYM'da kullanımı:

Taşdemir (2004) benzinli bir motorun girişlerine değişik yüzdelerde avans oranları verilip, istenilen motor devrinde (n) motor çalıştırıldığında ürettiği motor gücü (Pe), motor momenti (Me), özgül yakıt tüketimi (be) ve emisyon parametrelerinden HC değerlerini bulan bir BUS geliştirmiştir. Motor performans ve emisyon karakteristiklerinin belirlenmesinin böyle bir sistem ile kullanılabilirliğini göstermişlerdir. Tasarlanan çok girişli çok çıkışlı BUS'den elde edilen sonuçlar ile motor deneylerinden elde edilen sonuçların karşılaştırılması sonrası BUS çıktılarının yüksek doğrulukla deneysel sonuçlarla örtüştüğü görülmüştür.

Owens ve Segal (2001) süpersonik yanma testleri tezgahı için hava sıcaklığı kontrolünü sağlayan bir sistem geliştirmişlerdir. Yüksek hızlı kor akışına sahip bir süpersonik hava dolaşımlı motor, yanma işleminin içinde olan yakıtın yanma süresini azaltır. Buda süpersonik yanmalı motorlarda, makul ölçekteki yakıcıda etkin karışım ve yanmanın sağlanması için teknolojik mücadeleyi beraberinde getirir. Yapılan bu çalışmada, hidrojen gazı havada yakılarak süpersonik yanma test tezgahında istenen stegnasyon sıcaklığına yükselişi ve bu değerin korunması gerçekleştirilmiştir.

Stegnasyon sıcaklığında istenilen noktanın sağlanması için hidrojen kontrolü 3 fazda gerçeklemiştir. Bunlar sırasıyla tezgahtaki Hidrojen yanmasının sağlanması, hidrojenin yanma sıcaklık değerinde sıçrama yapması ve de istenilen sıcaklık noktası için hidrojen iterasyonunun sağlanmasıdır. BM kullanılarak tasarlanan PC tabanlı danışman kontrolör işlemin 3 farklı fazını da tanır ve en uygun kontrol metodunu seçer.

Trebi-Ollenu ve ark. (2001) İYM kullanan tüm arazi araçları (ATV) için uyarlamalı bulanık mantık kontrol (BMK) sistemi ile kısma valfinin kontrolünü sağlamışlardır. Tasarımın amacı kısma valfi hareketini sağlamak ve kararlı konumda iken sıfır hız hatası sağlayarak farklı eğilime sahip sokak veya arazilerde 2-30 mile/h hız aralığında uygun hızın seçilmesidir. Ve ayrıca bu hızın kararlı durumda korunmasının sağlanmasıdır. Modern üretim araçlarında motor yönetim kontrolü için mikroişlemciler kullanılsa da ATV'lerde kontrol mekanik olarak karbüratör tarafından sağlanmaktadır. Yazarlara göre tüm motorun matematiksel modeli mevcut olmadığından geleneksel tekniklerin bu motor tipine uygulanması oldukça zordur. Bundan dolayı deneyim ve oldukça geniş ölçekte ATV kısma valfleri mekanizması üzerinde yapılmış deneylerden elde edilen veriler ile birlikte oluşturulan uyarlamalı BMK algoritması çözüm için olumlu sonuçlar vermiştir.

Zilouchian ve ark.(2000) jet motorlu yakıt sisteminin kontrolünü sağlamak amacı ile iki farklı BMK tasarlamışlardır. Düşünülen sistem jet motor test tezgahında yakıt dağıtımının kontrolüdür. Bu jet motor yakıt sistemi test tezgahının geliştirilmiş bir şekli olup amaç jet motorun yanma basıncını simüle etmektir.

Laukonen ve ark. (1995) İYM'lar için hata bulma ve izolasyon konusunda çalışma yapmışlardır. Motorun belirli hatalarının bulunması ve izole edilmesi motor sinyallerinin nominal değerlerinden sapma örneklerinin incelenmesi ile sağlanır. Bu çalışmada bir BUS geliştirilerek motor sinyallerinin normal değerlerden sapmasının bulunması ve hesaplanması sağlanmıştır. Böylece belirli aktörlerin ve sensör kalibrasyon hatalarının tespiti mümkün kılınmıştır. BUS modeli doğrusal olmayan oto-regressive kayan ortalamalı sinyal (ARMAX) metodu ile karşılaştırılmış ve hata bulma ile tanımla stratejilerindeki etkinliği gösterilmiştir.

Nam ve ark. (1994) oksijen sensörlü gazolin yakıt püskürtme sistemlerinin kontrolünü BUS ve "kayan-mod" tekniği ile sağlamışlardır. Bu çalışmada kapalı-döngü yakıt püskürtme kontrol metodu geliştirilmiştir. BUS ve "kayan-mod" tekniği kullanılarak HYO'nın korunması sağlanmıştır. Oksijen sensörlerinin histerisinden kaynaklanan chattering **(gürültü)** hatalarının azaltılmasın hazırlanan kayan-mod metodu ile gerçekleştirilirken sistemin kontrolü BUS ile sağlanmıştır.

Matsumoto ve ark. (1994) İYM kontrolü üzerinde çalışma yapmışlardır. Motor yük sistemlerinin tahmini değerlerinin karakteristiği doğrusal değildir. Bundan ötürü, bir gazolin motor için ortalama hızın korunması ya da dizel motor yöntemi gibi geri besleme gerektiren sistemlerde kazanç tasarımı gibi parametreler bu doğrusal olmama karakteristiğini telafi etmek zorundadırlar. Bu amaçla doğrusal olmamaya karşı sağlam ve kararlı bir BK geliştirilmiştir. BK bir dizel motora uygulanmış ve BK'ün PI ve LQI kontrol metotları ile karşılaştırılması yapılmıştır. Sonuç olarak BK'ün diğer iki metotla karşılaştırıldığında daha yüksek derecede güvenilirliğe sahip ve daha hızlı tepki veren bir kontrol sistemi olduğu görünmüştür.

Soliman ve ark (1998) bulanık kontrol sistemi kullanarak dizel bir motor için arıza tespiti yapmışlardır. Kontrol sisteminin girişleri HC, NO_x ile CO olup çıkışı HYO'dır. Modelleme sonucu elde edilen HYO, alıcı ve aktüatörlerden gelen parametreler (kısma açısı, EGR, manifold basıncı ve yakıt akış miktarı) ve EMS kod parametreleri ikinci bir bulanık kontrol sistemine giriş olarak verilmiştir. Bu sistemin çıkışı ise olası hatanın (yanlış ateşleme vb.) kendisidir.

Lee ve ark (2003) manifold hava basıncı ile hızın giriş ve yakıt darbe genişliğinin çıkış olarak kullanıldığı bulanık kontrol sistemi geliştirmişlerdir. HYO değerini bu sistemle 0,8 ile 1 arasında tutarak güç ve tork değerinde %12 artış sağlamışlardır. 6 farklı devir ve 5 yük için tek silindirli benzinli motor üzerinde ölçümler almışlar ve bu ölçümleri bulanık kontrol sisteminde kullanmışlardır.

Lee ve ark (2004) önceki yayında bahsedilen bulanık kontrol sistemini kullanarak güç ve tork değerindeki %12'lik artışa ek olarak CO ve HC emisyonları için sısrasıyla %51 ve %15,4 değerinde azalma sağlamışlardır.

Tütüncü ve ark. (2007) bir dizel motorun verilen güç, tork, özgül yakıt tüketim değerlerine göre hava akış oranı, yük, devir, boost basıncı ve yakıt oranının

hangi aralıkta olması gerektiğini bulanık mantık temelli uyarlamalı bulanık-sinir kontrol sistemi ile gerçekleştirmişlerdir.

EH'nın İYM'larda kullanımı:

Wang ve ark. (2001) kıvılcım yanmalı motorların yanma zamanı kontrolü için bir sistem geliştirmişlerdir. Optimum yanma zamanı, maksimum fren torku anlamına gelip silindirdeki yanmanın gelişme ve yayılma oranıyla değişir. Buda diğer faktörlerin yanı sıra, motor tasarımına, çalışma şartlarına ve HYO'na bağlıdır. Modern motorlarda yanma zamanı genellikle sabit açık döngülü bir tasarımla sabitlenmekte yoluyla olmaktadır. Yapılan bu tasarımda ise motorun hız, yük ve soğutma sıcaklığına bağlı fonksiyonlar kullanılmıştır. İstenilen ise yanma zamanının optimum dereceye ayarlanarak en iyi tork, minimum yakıt tüketimi ve maksimum güç elde edilmesinin sağlanmasıdır. Yanma zamanlaması kontrol sistemi BM ve YSA kullanılarak gerçekleştirilmiştir. Fiber optik sensör sistemi emisyon aydınlatmasını ölçmek için geliştirilmiştir. Bu aydınlatma yanma basıncı ve yanma zamanı kontrolünün korelasyonunu sağlamaktadır. Yapılan çalışmada, doğal gaz ile çalışan 4 silindirli kıvılcım yanmalı bir Ford 1600cm^3 motor deneysel amaçlı olarak kullanılmıştır. Birkaç motor testi yanma yoğunluğu bulma sistemi optimizasyonu için yapılmıştır. Sonuçlar motorun yumuşak hesaplama yöntemi kullanılarak kontrol edilmesinin oldukça fazla miktarda ve uygun bilgiyi sağladığını göstermiştir. Böylelikle uzun süren deneyler yerine EH kullanılarak elde edilecek sonuçların aynı olduğu gözlemlenmiştir.

Du ve ark. (2001) RBFN tabanlı YSA kullanarak motorun silindir başı titreşim sinyallerinden İYM'un silindir basıncını yeniden oluşturmuşlardır. Silindir basıncı ile silindir başı titreşim sinyalleri arasındaki ilişki analiz edilmiştir. RBFN silindir basıncı zaman serisi ile motor silindir başı titreşim sinyalleri arasında parametrik olmayan eşleştirme modeli için kullanılmıştır. Bulanık *c*-ortalama kümeleme metodu ve gradyant azaltma algoritması sırası ile RBFN'in merkezi ve

çıkış katman ağırlıklarının eğitimi için kullanılmıştır. Ölçülen veri ile RBFN modellerinin bu öngördüğü verilerin düşük hata payıyla (%1) aynı oranda olduğu görülmüştür.

Yang ve ark. (2002) hidrojen yakıtlı motorlarda optimum yanma zamanı ve püskürtme sistemi kontrolü için çalışma yapmışlardır. Yapılan bu çalışmada hidrojeni silindirin içine sıkıştırma sürecinin sonuna doğru püskürtmüşler ve bir test motorunda elektrik kıvılcımı ile yanmasını sağlamışlardır. Hidrojen yakıtlı motorun performansı üzerine araştırma için farklı yanma ve püskürtme zamanları kullanılmıştır. Solenoid sürücü tipli silindir hidrojen püskürtme sistemi tasarlanmıştır. Püskürtme sistemi elektronik tabanlı bir kontrol mekanizması kullanılmakta olup hidrojen ile çalışacak şekilde değiştirilerek dizel motora monte edilmiştir. Hidrojen yakıtı çıkış basıncı 15mpa ve saflığı %98 olan bir hidrojen gaz şişesinden sağlanmıştır. Geleneksel açık-döngülü kontrol sistemleri ki bunlardan en etkilisi "tablo-inceleme" olup dizel ve gazolin motorlarda yaygın olarak kullanılmaktadır. ANFIS kontrolörü bulanık YSA (BYSA) ile birleştirilerek çalışmada bir alternatif kontrol aracı olarak sunulmuştur. İki kontrolörün bulunması kontrol sisteminin açık veya kapalı döngü olarak çalışmasına imkan vermektedir. Kontrol sisteminin girişleri hız, yük, TDC (En üst ölü nokta), soğutma sistemi su sıcaklığı ve hava akışıdır. Çıkışlar ise yanma zamanı, püskürtme zamanı ve püskürtülecek hidrojen miktarıdır.

Hiroyaşu ve arkd (2005) HIDECS olarak isimlendirilen ve dizel motor performansını modellemek için kullanılan sprey (püskürtme) analiz metodu ve çok amaçlı GA kullanarak NO_x için %60 ve yakıt tüketimi için %3'lük düşüş sağlamışlardır. HIDECS ile farklı devirlerdeki EGR ve çoklu enjeksiyon değerleri ve bu değerlere karşılık gelen yakıt tüketimi ve NO_x değerlerini üreterek modelleme yapmışlardır. Sonrasında bu model üzerinde komşu geliştirmeli genetik algoritma (NCGA), kuvvet pareto evrimsel algoritma (SPEA), SPEA+ ve bastırılmamış sınıflandırmalı genetik algoritma (NSGA II) kullanarak optmizasyonu sağlamışlardır. Tüm çok amaçlı genetik algoritmalar için optimize edilecek olan yakıt tüketimi ve NO_x parametrelerinde yeni popülasyon üretimi için HIDECS kullanılmıştır.

Kesgin (2004) YSA ve GA kullanarak NO_x optimizasyonunu gerçekleştirmiştir. Kinetik reaksiyon baz alınarak yapılan performans ve emisyon

modellemesinde YSA kullanılmıştır. Giriş değerleri olarak denklik-oranı, yük basıncı, yük sıcaklığı, yanmanın başlama ve süreç zamanı ve form parametresi gibi silindirde meydana gelen reaksiyon parametreleri kullanılmıştır. YSA çıkış parametresi de NO_x ve özgül yakıt tüketimidir. Modelleme sonrasında GA kullanarak yaktı tüketiminin %3 artmasına karşın NO_x değerini uluslar arası standart değer oran 250mg/Nm3 altına indirmiştir.

Alonso ve ark (2007) YSA ve GA kullanarak emisyon ve yakıt tüketimi optimizasyonu gerçekleştirmişlerdir. Öncelikle dizel motor üzerinde yapılan deneylerden elde ettikleri verileri kullanarak 9 girişli bir YSA oluşturmuşlardır. Bu girişler devir, EGR, hava miktarı, yakıt miktarı, soğutma suyu sıcaklığı, pilot enjeksiyon başlangıcı, ana enjeksiyon başlangıcı, enjeksiyon basıncı ve silindir içi sıcaklıktır. NO_x, CO, HC ve özgül yakıt tüketimi çıkış parametresi olup her bir çıkış parametresi için 9 girişli YSA oluşturulmuştur. YSA eğitilip test hatası kabul edilebilir sınırların altına indirildikten sonra simülasyon amaçlı olarak kullanılmıştır. GA emisyonlar ve yakıt tüketimini optimize ederken ihtiyaç duyduğu popülasyon oluşturma işlemini YSA ile sağlamıştır. NO_x için %4,4 ve yakıt tüketimi için %2.9'luk azalma sağlanmıştır.

Vossogi ve ark (2005) dizel motor deneylerinden elde ettikleri verileri kullanarak lagrang yöntemi ile öncelikle motor modellemesini gerçekleştirmişlerdir. Sonrasında yine bu modelleme kullanılarak bastırılmamış sınıflandırmalı genetik algoritma (NSGA) ve uzaklık tabanlı pareto genetik algoritma (DBPGA) ile emisyon ve yakıt tüketimi optmizasyonu gerçekleştirmişlerdir. Yakıt tüketimi optimizasyonunda lagrange-NSGA ve NO_x ile HC (emisyon) optimizasyonunda lagrange-DBPGA ikilisinin daha iyi sonuç verdiğini belirtmişlerdir. NO_x ve HC için toplamda %20'lik bir iyileştirme sağlarken yakıt tüketiminde %0.5'lik iyileştirme sağlamışlardır.

Obodeh ve ark (2008) 1000 ile 5000 rpm devir arasında çeyrek, yarım, üç çeyrek ve tam yükte gerçekleştirdikleri motor ölçüm deneyleri sonrası elde ettikleri verileri kullanarak optmizasyon çalışması gerçekleştirmişlerdir. Öncelikli olarak girişi devir ve yakıt tüketimi çıkışı ise her biri için ayrı bir YSA tasarlanmak üzere NOx, PM, CO ve özgül yakıt tüketimi olan YSA'ları eğitip test etmişlerdir. Dizel motorun simülasyonu için kullanılan bu YSA'larıda GA için gerekli popülasyonun

sağlanmasında kullanmışlardır. Yapılan çalışma sonucu NOx, PM, CO ve özgül yakıt tüketimi için sırasıyla 39.3%, 69.2%, 39.3% ve 2.5% iyileştirme elde etmişlerdir.

Kaji ve ark (2008) bir dizel motor için modelleme amaçlı olarak döngüdeki donanım simülasyonunu (hardware in loop simulation) kullanmışlardır. Elde ettikleri modelin doğruluğunu deneysel olarak tasarlanan set üzerinde gerçekleştirmişlerdir. Bu model çok amaçlı genetik algoritma tekniklerinden MOPA, NSGA, NPGA vb kullanarak motorun kalibrasyonu için kullanılmıştır. Tork ve yakıt tüketimi arasında optimizasyon sağlanırken emisyondaki değişimlerde incelenmiştir.

Bir dizel motorun performans ve emisyon karakteritiğinin belirlenmesi için yapılmış olan çalışma sayısı oldukça kısıtlıdır. Literatürde çoğunlukla benzinli motor ve hibrid motorlar için yapılmış çalışmalar mevcuttur (Howlett ve ark.(1996), Heister ve Froehlich (2001), Park ve ark. (2001), Li ve Yurkovich (2000), Thompson ve ark. (2001), Ortmann ve Glesner (1998), DeNicolao ve ark. (1996), Taşdemir ve ark. (2004)).

Dizel motor performans modellemesi için gerçekleştirilen çalışmalarda ise matematiksel modelleme sayısı az olup yoğunluklu olarak YZ tekniklerinin içeren modellemeler görülmektedir. Bu çalışmalardan dizel motor modellemesinde en yüksek doğruluk oranı YSA kullanılarak Hafner ve ark. (2000) ile Arcaklıoğlu ve Çelikten (2005) tarafından elde edilmiştir. Lokal lineer radyal tabanlı fonksiyon ağı (LOLIMOT) kullanarak yaptıkları modelleme ile Hafner ve ark (2000) çıkış değerlerini ortalama %3 hata ile modellemişlerdir. ÇKP kullanarak elde ettikleri modellemede ile Arcaklıoğlu ve Çelikten (2005) elde ettikleri çıkış değerleri deneysel verilere göre % 99.00 yaklaşık sonuç vermiştir.

Bu tez çalışmasında dizel ve benzinli motorun yanma karakteristiğinin belirlenmesinde farklı YSA mimarileri ve eğitim algoritmaları en iyi sonuç alınıncaya kadar denenmiştir. Modellemede YSA ile dizel motor deneysel verilere göre eğitim setinde %99.77, doğrulama setinde %99.59, test setinde %99.51 ve tüm noktalarda %99.62 uyumlu sonuçlar üretilmiştir. YSA ile gerçekleştirilen benzinli motor modellemesinde yapılan motor deneyinde elde edilen sonuçlara göre eğitim setinde %98,56 doğrulama setinde %98.18, test setinde %97.43 ve tüm noktalarda %98.28 uyumlu sonuçlar ürettiğini göstermektedir. Motorların performans ve emisyon karakteristiği noktasal olarak belirlendikten sonra ileri ve geri yönlü

optimum aralıksal modelleme gerçekleştirilmiştir. Bulanık c-ortalamalar ve ANFIS kullanılarak gerçekleştirilen optmimum aralıksal modelleme de (ileri ve geri yönlü) dizel ve benzinli motor için %100'lük başarı oranı sağlanmıştır. Son olarak veri kümesi kullanılan her iki motor veri türü içinde yakıt optimizasyonu için tek amaçlı ve çok amaçlı GA optimizasyon teknikleri ilk defa bir çalışmada birlikte kullanılmış ve uygulama sonucunda istenilen yakıt optimizasyonu ve düşük emisyon değerleri dizel motor verisi için ulaşılmıştır. Tek amaçlı GA'da özgül yakıt tüketimi %7.7, NO_x %8.51, güç %30, tork %4 ve afr %7.4 azalırken HC %10.5 artmıştır. NSGA II ile gerçekleştirilen çok amaçlı GA'da HC, CO_2 , güç ve özgül yakıt tüketimi sırasıyla %17.6, %30.05, %31.8 ve %14.5 azalırken NO_x değeri %13 artmıştır. Ayrıca YSA ve NSGA II'nin optmizasyon amaçlı olarak birlikte kullanıldığı ilk çalışmadır.

1.5. Tezin Organizasyonu

Dizel motorun performans ve emisyon karakteristiğinin modellenmesi, kontrolü ve yakıt optimizasyonuna dayalı bu tez çalışmasının ana hatları aşağıdaki gibidir:

Birinci bölüm giriş bölümü olup, tez çalışmasının konusuna genel bir bakış açısı verilmeye çalışılmıştır. Bu bölümde konuyla ilgili literatür taraması yapılmıştır. Çalışmanın amacı, çerçevesi ve mevcut çalışmalara göre yerine kısaca değinilmiştir.

İkinci bölümde, dizel motorlar ve çalışma prensipleri üzerinde durulmuştur. Ayrıca yine dizel motor performansı ve emisyon karkteristiği ile bunların modellenmesi üzerinde kullanılan teknikler anlatılmıştır.

Üçüncü bölümde, bu çalışmada kullanılna materyaller ve izlenilen metotlar hakkında bilgi verilmiştir.

Dördüncü bölümde, bu çalışmada dizel motor performansı ve emisyon karakteristiğinin belirlenmesi (modellenmesi) için yapılan matematiksel modelleme (çoklu regresyon analizi) sunulmuştur. İki ayrı motordan deneysel çalışma sonucu

elde edilen veriler üzerinde deneme yapılmıştır. Motorlardan birisi yüksek torklu dizel motor olup diğeri benzinli motordur. Böylelikle uygulanan yöntemlerin her iki tür motor tipi içinde geçerliliği incelenmiştir.

Beşinci bölümde, bu çalışmada gerçekleştirilen dizel motor performansı ve emisyon karakteristiğini belirlenmesi (modellenmesi) için yapılan uygulamalar sunulmuştur. Gerçekleştirilen en iyi modelleme önceki çalışmalardan elde edilen sonuçlarla karşılaştırılmıştır. Yine bu bölüm için iki ayrı motordan elde edilen deneysel veriler üzerinde uygulamalar yapılmış ve uygulamaların her iki tür (dizel ve benzinli) motor için geçerliliği sağlanmaya çalışılmıştır.

Altıncı bölümde, motor performans ve emisyon karakteristiğinin noktasal değerler yerine optimum aralıksal değerlerde modellenmesi sunulmuştur. Çift yönlü modelleme ile verilen çıkış parametreleri değerine göre giriş parametreleri ya da giriş parametrelerine göre çıkış parametreleri optimum olarak hangi değerleri almalıdır sorusuna cevap aranmıştır. Dizel ve benzinli motor verisi üzerinde yapılan uygulamalar sunulmuştur.

Yedinci bölümde tek amaçlı ve çok amaçlı GA tekniği kullanılarak yakıt optimizasyonu yine iki ayrı motordan elde edilen deneysel veriler üzerinde gerçekleştirilmiştir.

Sekizinci bölümde, tezle ilgili genel sonuç ve önerilere yer verilmiştir.

Kaynaklar bölümünde ise bu tez çalışmasında faydalanılan kaynaklar ve referanslara yer verilmiştir.

2. DİZEL MOTORLAR VE PERFORMANS KARAKTERİSTİKLERİ

Motorlu taşıtların fonksiyonlarını yerine getirebilmeleri için gerekli olan enerji bugün için büyük ölçüde petrole bağımlıdır. Bundan dolayı yakıt tüketimindeki hızlı artışa bağlı olarak yakıt temininde karşılaşılan güçlükler de giderek artmaktadır. Ayrıca motorlu taşıtlardan kaynaklanan hava kirliliği ve gürültü düzeyi özellikle büyük şehirlerimizde ciddi bir problem olarak insan sağlığını tehdit edecek boyutlara ulaşmıştır. Hava kirliliğinin ortadan kaldırılması veya minimum düzeye indirilmesi, yakıt tüketimini azaltmakla ve motorlu taşıtların verimliliğini artırmakla mümkündür.

Yakıt ekonomisini iyileştirmek için; motor, taşıt ve taşıtın kullanımı ile ilgili olarak birçok araştırmalar yapılmaktadır. Yakıt tüketimine etki eden parametrelerin motor ve taşıt kullanım şartlarına göre değiştirilmesi ile yakıt sarfiyatının azaltılmasına çalışılmaktadır.

Yapılan bu çalışmalar sonucu yakıt ekonomisine etki eden şu faktörler göz önüne alınmıştır:

Motora ait parametreler; Sıkıştırma oranı, hava-yakıt oranı, özgül yakıt tüketimi, motor taşıt uyumu, yakıt kalitesi, alev hızı, motor sürtünmesi, motorda kullanılan yardımcı sistemler, gaz değişim süreçleri, yanma odası tasarımı, motor bakımı ve ayarları, motordaki sistemlerin yönetim ve denetimleridir.

Taşıta ait parametreler; Taşıt tasarımı, taşıt aerodinamiği, güç aktarma sistemleri, tekerlek ve lastikler, taşıt kütlesi.

Taşıta etki eden hareket dirençleri; Transmisyon direnci, ivme direnci, hava ve rüzgar direnci, tekerlek yuvarlanma direnci, yokuş direnci.

Taşıtların çalışma şartlarının etkisi; İlk çalışma ve ısınma durumu, seyir çevrim karakteristikleri, taşıt performansı, çevre koşulları, yolların etkisi, bakım ve onarımların etkisi, taşıt sürücüsünün davranışı.

Motorlu taşıtlarda yakıt ekonomisi ve egzoz gazındaki zararlı emisyonların azaltılması; motor ve taşıt tasarımına, taşıtların uygun hızlarda kullanılmasına ve periyodik bakımlarının zamanında yapılmasına bağlıdır.

Ülkemizin milli gelirinin üçte birinin petrol ithalatına ayrıldığı göz önüne alınırsa yakıt ekonomisindeki gelişmeler ülkemize önemli ölçüde katkı sağlayacaktır. Ülkemizde ve dünyada petrol fiyatlarının hızla artması ve kaynakların giderek azalması dikkate alınırsa hem motor gücünü ve verimini artıran, hem de egzoz emisyonlarındaki zararlı konsantrasyonları azaltıcı çalışmalara önem verilmesi kaçınılmazdır.

Bu çalışmada kullanılan dizel motorun özelliklerine geçmeden önce motorlar ve mortolarda performansı belirleyen yanma olayları hakkında kısaca değinilecektir. Bilindiği üzere yakıttan elde ettiği ısı enerjisini mekanik enerjiye çeviren makinelere motor denir. Motorlarlar;

Zamanlarına Göre:

1- Dört zamanlı motorlar
2- İki zamanlı motorlar

Kullanılan Yakıtlara Göre:

1- Benzinli motorlar
2- Dizel motorlar
3- LPG motorlar

Yakıtın Yanma Yerine Göre:

1- İçten yanmalı motorlar
2- Dıştan yanmalı motorlar

Yapım Özelliklerine Göre:

1- Sıra tipi
2- Birbirlerinin karşılarına yatık (Düz, hafif, eğik, boksör tipi)
3- Sıra halinde bir açı ile birleştirilmiş (V tipi)
4- Daire şeklinde (Yıldız tipi)

Silindir Sayılarına Göre:

1- Tek silindirli
2- Çok silindirli

Soğutma Sistemlerine Göre:

1- Su soğutmalı
2- Hava soğutmalı olarak adlandırılırlar.

Bu çalışmada kullanılan veriler ise içten yanmalı, çok silindirli ve dört zamanlı bir dizel motordur. Motor parçalarına biraz daha yakından bakacak olursak;

1- Silindir Bloğu: İçinde silindirlerin bulunduğu ve motor parçalarını üzerinde taşıyan ana parçadır.
2- Silindir Kapağı: Silindir bloğu üzerini kapatan ve yanma odalarını meydana getiren kapaktır.
3- Karter: Motor yağına depoluk görevi gören, silindir bloğunun altındaki parçadır.
4- Subap Kapağı: Motor üzerindeki supap (külbütör) mekanizmasını dış etkilerden korur.
5- Radyatör: Soğutma suyunun bulunduğu depo.
6- Karbüratör: Benzin-hava karışımını sağlayan parça.
7- Hava Filitresi: Siilndirlere giren havayı temizler.

8- Manifoldlar (emme-egzoz): Hava yakıt karışımını silindirlere, yanmış gazları dışarıya taşıyan borulardır.

9- Yağ Filitresi: Motor yağı içindeki yabancı maddeleri temizler.

10- Endüksiyon Bobini (Ateşleme): Aküden gelen akımı 15.000-25,000 volta yükselten parçadır.

11- Buji: Benzin-hava karışımını tutuşturan parçadır.

12- Konjektör (regülatör): Şarj dinamosunun ürettiği elektriği doğru akıma çeviren ve 12 volt değerinde düzenleyen parçadır.

13- Enjektör: Dizel motorlarda yakıt püskürten parçadır.

14- Krank Mili: Pistonların bağlı olduğu, motorun çalışması sonucu elde edilen hareketin ve gücün motordan alınmasına yarayan mildir.

15- Piston: Silindir içersinde hareket eden ve hareketi krank miline iletmesine yardımcı olan parçadır.

16- Piston (biyel) Kolu: Pistonun doğrusal hareketini krank miline ileten parçadır.

17- Yağ Pompası: Karterdeki yağı basınçla hareketleri parçalara gönderir.

18- Yakıt Pompası (benzin otomatiği): Yakıtı basınçla karbüratöre gönderen parça:

19- Distribütör: Benzinli motorlarda ateşleme sırasına göre bujilere elektrik enerjisi gönderen parçadır.

20- Marş Motoru: Motora ilk hareket veren parçadır. Elektrik enerjisini hareket enerjisine çevirir.

21- Alternatör (şarj dinomosu): Araç için gerekli elektrik enerjisini üreten parçadır. Hareket enerjisini elektrik enerjisine çevirir.

22- Su Pompası (devirdaim): Suyun silindir içindeki kanallarda dolaşmasını sağlar.

23- Enjektör Pompası: Dizel motorlarda yakıtı basınçla enjektörlere gönderen parçadır.

2.1. Dört Zamanlı Motorların Çalışma Sıralaması

İçten yanmalı motorlar, yakıtın motor içinde yanma odası adı verilen sınırlanmış bir alan içinde yakılması ile enerji elde edilen motorlardır. Bu motorlara

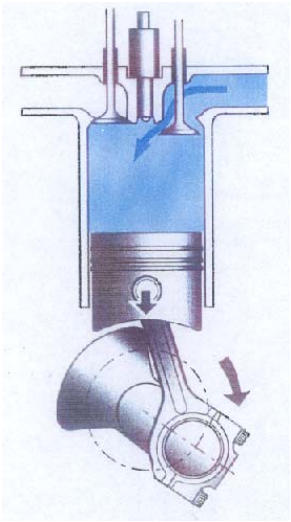
bu ismin verilmesinin sebebi, bu motorlardan önceki motorlarda yani dıştan yanmalı motorlarda (örneğin; buhar makinesi, Stirling motoru) yakıtın motor dışında bulunan başka bir ortamda yakılması ile enerji elde edilmesidir. Buhar makinelerinde yakıtın motorun dışında bir bölümde yakılması ile elde edilen ısı enerjisi suyun buharlaştırılmasında kullanılıyordu. Buhar basıncı ile hareket ettirilen pistonlardan da mekanik enerji elde ediliyordu (AS 2008).

İçten yanmalı motorlarda yanma odasının motorun içine taşınmasıyla birlikte oldukça kompakt motorlar üretilebilmiştir ve otomobillerin oluşması sağlanmıştır.

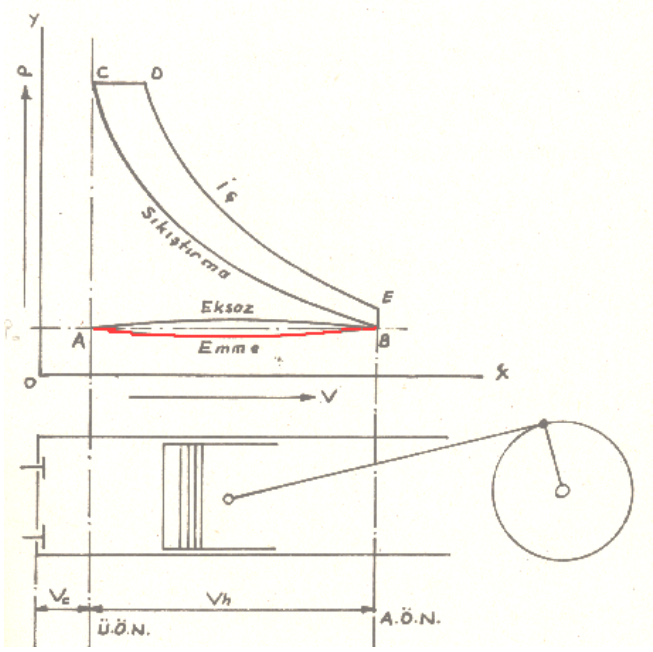
Yakıt, karbüratör veya yakıt enjeksiyonu sistemiyle belli bir oranda hava ile karıştırılarak yanma odası denilen silindirin içine gönderilir. Karışım piston tarafından sıkıştırılarak buji yardımıyla ateşlenir. Dizel motorlarda ateşleme buji yerine yüksek basıç altında sıkıştırmayla yapılır. Karışım CO_2 ve CO'e dönüşür. Bu reaksiyon hacim ve ısı yaratır. Buda pistonların salınım hareketi krank mili yardımıyla mekanik enerjiye dönüştürülerek iş yapılmış olur.

Tipik bir dizel motorda yanma dört zamanlı olarak gerçekleşir. Bunlar sırasıyla emme, sıkıştırma, ateşleme ve egzoz zamanıdır (Borat ve ark. 2000).

1. Emme Zamanı: Silindire temiz havanın alınmasını içeren zaman periyodudur. Emme sübabının açılmasıyla hava silindirin içine dolar. Bu sırada piston Şekil 2.1'de görüldüğü üzere aşağı doğru inmektedir. Dolayısıyla silindirde yanma odası hacmi artmakta ve basınç Şekil 2.2'den de görüleceği üzere azalmatadır (OBITET 2008).

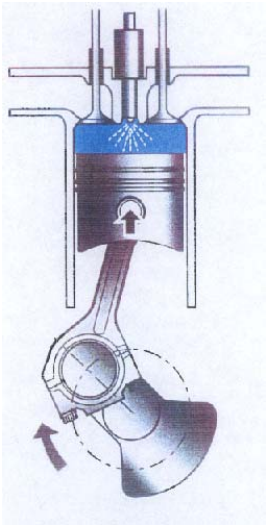


Şekil 2.1. Motorda emme zamanı esnasında piston görüntüsü

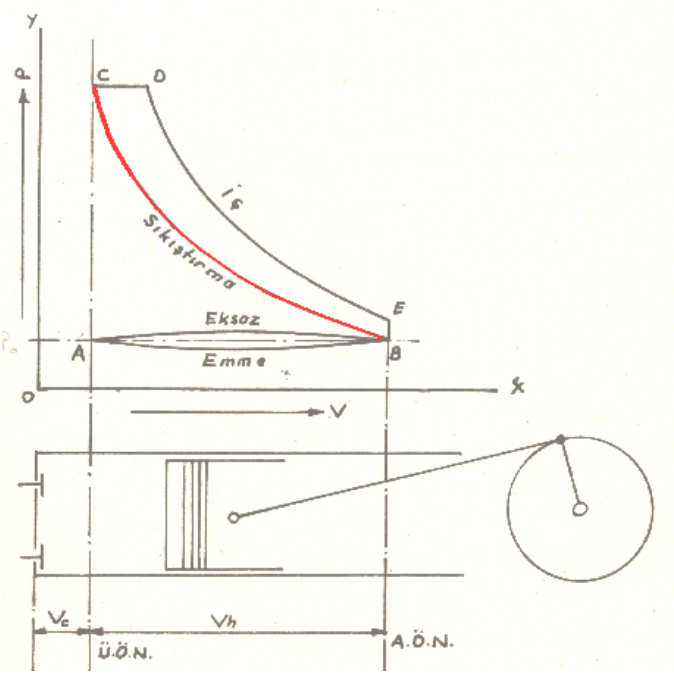


Şekil 2.2. Motorda emme zamanı esansında hacim basınç ilişkisi

2. Sıkıştırma Zamanı: Silindire alınan havanın sıkıştırılması periyodudur. Emme ve egzoz sübaplarının her ikisi Şekil 2.3'de görüleceği üzere kapalı durumdadır ve piston yukarı doğru çıkar. Bu sayede silindire alınan hava sıkıştırılır ve hacmi küçülür. Bu hacim küçülmesi aynı zamanda silindire alınan havanın Şekil 2.4'de görüldüğü üzere ısınmasına sebep olur.

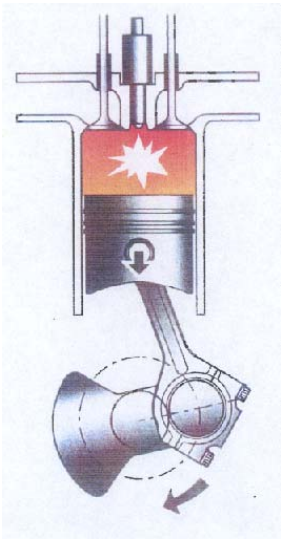


Şekil 2.3. Motorda sıkıştırma zamanı esnasında piston görüntüsü

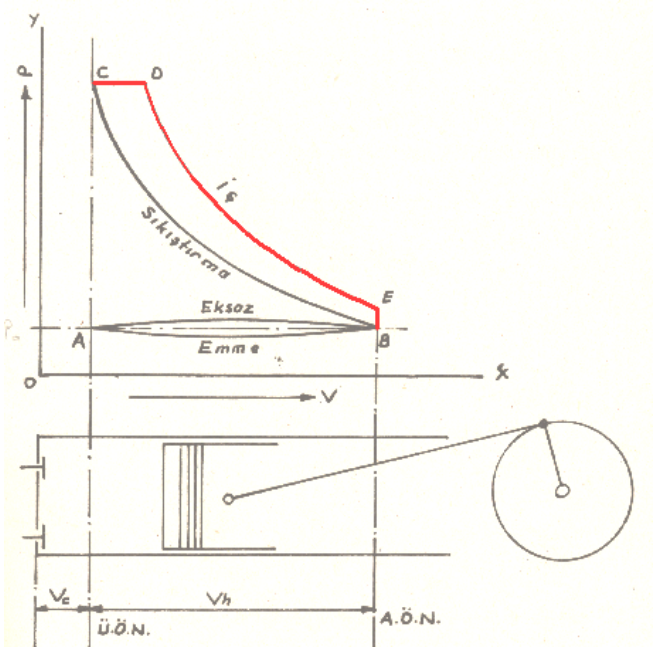


Şekil 2.4. Motorda sıkıştırma zamanı esansında hacim basınç ilişkisi

3- Ateşleme: Sıkıştırılan havanın üzerine yakıtın enjektörle püskürtülerek yanması periyodudur. Sıkışan ve ısınan hava yüksek basınçal püskürtülen dizel yakıtı ile kimyasal tepkimeye girer ve yanma olayı gerçekleşir. Yanma Şekil 2.5'de gösterildiği üzere ufak bir patlama şeklindedir. Patlamayla genişleyen karışım pistonu aşağı doğru iter. Motorun güç üretme zamanı bu periyot olup yanma odasındaki hacim basınç ilişkisi Şekil 2.6'da gösterilmiştir.

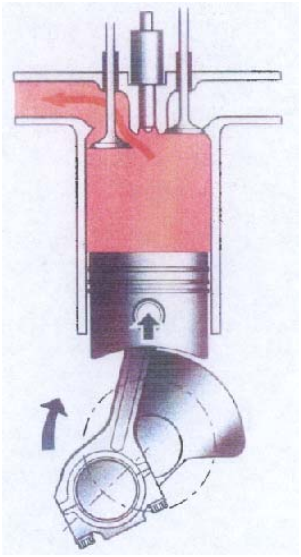


Şekil 2.5. Motorda yanma zamanı esnasında piston görüntüsü

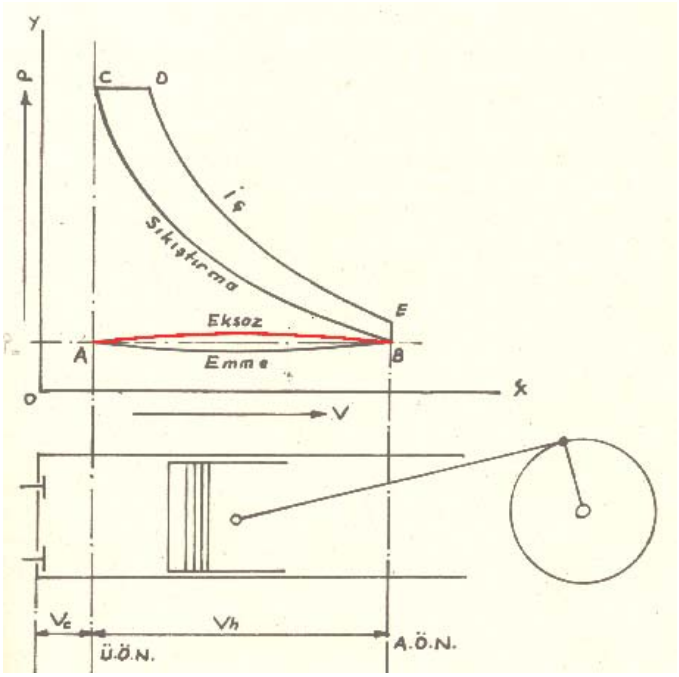


Şekil 2.6. Motorda yanma zamanı esansında hacim basınç ilişkisi

4. Egzoz Zamanı: Silindir içinde kalan artık gazların dışarıya atılması periyodudur. Patlamayla aşağı inen piston, bu aşamada Şekil 2.7'de görüldüğü üzere yukarı doğru hareket etmeye başlar. Yanmış gazların dışarı atılması zamanı olarak bilinen bu periyotta piston yukarı çıkarken egzoz sübabıda açılır. Bu sayede yanmış gazlar dışarı atılır. Yanma odasındaki hacim basınç ilişkisi Şekil 2.8'de gösterilmiştir. Bundan sonra motor yeni bir çevrime başlar.

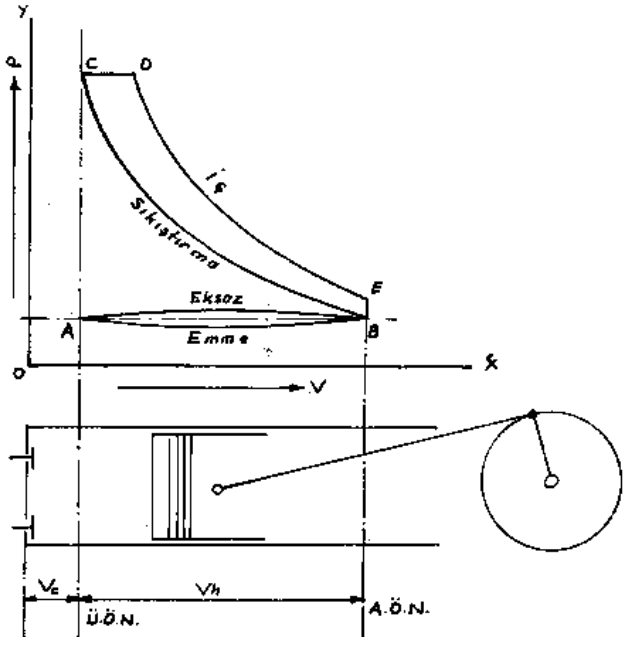


Şekil 2.7. Motorda egzoz zamanı esnasında piston görünütüsü



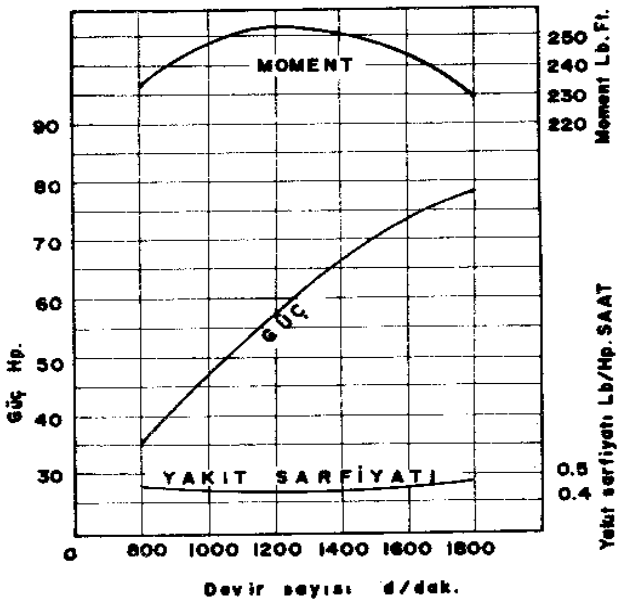
Şekil 2.8. Motorda egzoz zamanı esansında hacim basınç ilişkisi

Yukarıda gösterilen yanma zamanı grafiklerinden elde edilen değerler kullanılarak bir dizel motorun torik diyagramı aşağıdaki gibi olacaktır.



Şekil 2.9. Bir dizel motorun teorik diyagramı

Ayrıca bir dizel motorda elde edilen güç, moment ve yakıt sarfiyatı arasında ilişki de aşağıda gösterilmiştir (SN 2008.).



Şekil 2.10. Bir dizel motorun güç, moment ve yakıt sarfiyatı diyagramı

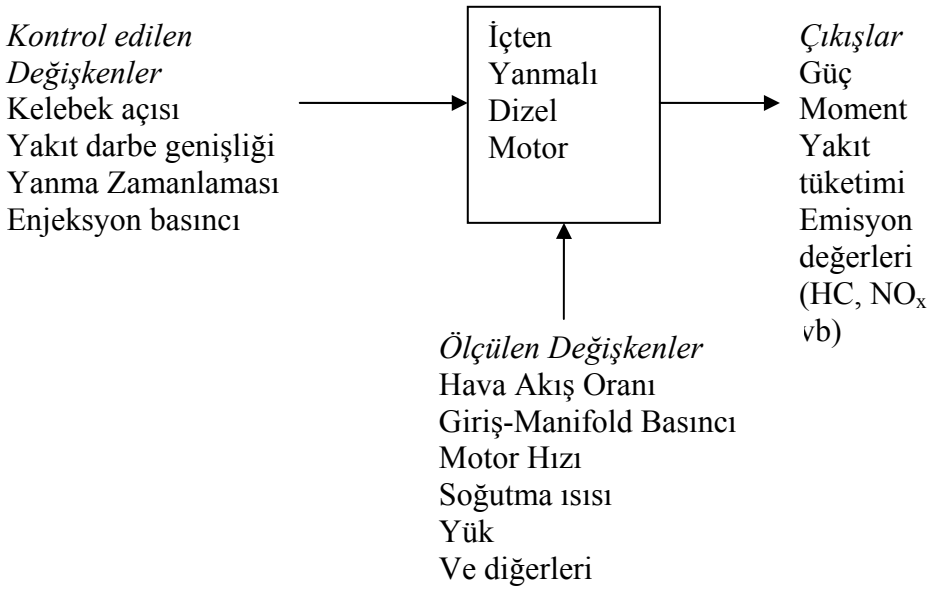
Motor performansı ve emisyon karakteristiğini belirleyen bir çok faktör mevcuttur. Bunlar arasında yukarıda bahsedilen yanma olayında da görüleceği üzere motor silindirinin yapısı, silindire alınan hava ve yakıt miktarı, yanma odası sıcaklığı, pistonların sürtünme katsayısı, silindir basıncı ve kelebek açısı bulunmaktadır. Ayrıca motor hızı, enjeksiyonlu motorlarda enjeksiyon basıncı, arazi durumu (viraj, eğim vb) ile hava şartlarıda motor performans ve emisyonunun belirleyicileri arasındadır.

Tüm motor perfromans ve emisyon karakteristiği modelleme çalışmalarında tork, moment, yakıt tüketimi ve emisyon parametrelerinin (NO_x, HC vb.) ölçülen değişkenlere (enjeksiyon basıncı, hava akış oranı, manifold basıncı, motor hızı, giriş hava ısısı, soğutma ısısı vb.) göre belirlenmesini içermektedir. Yanma işlemi termodinamik ve ısı transferi açısından oldukça karmaşık bir süreçtir. Buna ek olarak emisyon da yanma işleminin sonucu oluşmaktadır. Bir dizel motorun performans ve emisyonunun belirlenmesi için yapılan deneysel çalışmalar oldukça karmaşık,

maliyetli ve uzun zaman alıcı bir süreçtir. Bunun için kullanılan yaklaşımlardan bir taneside matematiksel modellenmedir. Ve modelleme sonucu elde edilen doğruluk oranıda istenilen yükseklikte değildir (Massie 2001). Matematiksel modelleme ideal şartlar kabul edilmekte ve bu şartlara göre termodinamik ve ısı transferi alanları kullanılarak motor perfromansı ve emisyon değerleri belirlenmektedir (Balcı 1986, Çetinkaya 1987, Öğüçlü 1998). Bu çalışmalar esnasında motorun silindirin tam olarak doldurulduğu ısı vb kayıpların olmadığı varsayıldığından elde edilen performans ve emisyon değerleri istenilen doğruluk oranından oldukça uzaktır (Sekmen ve ark. 2004).

Yanma olayının doğrusal olmaması, matematiksel modelinin elde edilememesi ve motor deneylerinin uzun zaman alıp maliyetinin yüksek olmasından ötürü bu alanda uygulanacak yeni yeknikler oldukça önem arz etmektedir. Bu tekniklerin başında da motorda ek sensör gerektirmeyen, her hangi bir motor parçasında değişikiliğe gidilmesine gerek duymayan YZ teknikleri oldukça yaygın olarak kullanılmaya başlanmıştır. YZ teknikleri sayesinde Şekil 2.11'de gösterilen motor performans ve emisyon değerleri ölçülen değişkenlere göre modellenip kontrol edilen değişkenler üzerinde gerekli ayarlamaların yapılması ile kontrol ve optimizasyon çalışmaları yapılmıştır (Yang ve ark. 1996, Yang ve ark. 1997, Kılıçaslan 2001, Lucas ve ark. 2001, Palau ve ark. 1999, Nakakita ve ark. 1994, Howlett 1998, Hamosfakidis ve ark.2003).

Yapılan bu tez çalışmasında yakıt optimizasyonu için sürücü isteği, hava şartları, lastik ve yol durumu gibi etkenler göz önüne alınmamıştır. Bunun sebebi ise çalışmada kullanılan her iki motor verisininde deneysel olarak elde edilip tarafımıza ulaştırılması ve bu etkenleri dahil edebilecek dizel bir motorun bulunmamasıdır. Buna ek olarak motor performans ve emisyon karakteristiğinin belirlenmesinde Şekil 2.11'de bir kısmı verilen parametrelerden yük, hız, boost basıncı, yakıt miktarı ve hava miktarı giriş parametresi olarak seçilirken güç, tork ve spesifik yakıt tüketimi performans HC, CO_2 ve NO_x ise emisyon parametresi olarak seçilmiştir.



Şekil 2.11. Dizel motorda performans ve emisyon karakteristiğini belirleyen parametreler

3. MATERYAL VE METOT

3.1. Materyal

P4 3.2 GHz Bilgisayar, Matlab 7.4 SP 3, Alyuda Neuro-Intelligence, Minitab14 ve SPSS 13.0 yazılımı kullanılmıştır. Dizel ve benzinli motor deneysel verileri üzerinde çalışma yapılmıştır. İkinci bölümde ifade edildiği üzere yapılan uygulama ve izlenen metotların her iki tür motor verileri üzerinde istenilen sonuçları verip vermediğini gözlemlemek amacıyla iki farklı tür motor verisi kullanılmıştır. Kullanılan deneysel motor verileri ise;

1) Bursa-Ford fabrikasında 300PS E1 J1 yüksek torklu dizel motor üzerinde yapılan deneylerden elde edilen veriler birinci uygulama verisi olarak kullanılmıştır. Motorun teknik özellikleri ise aşağıdaki gibidir.

Hacim: 7.3L

Silindir Sayısı:6

Strok: 124 mm

Max güç/devir: 300PS / 2400 rpm

Max tork/devir: 1100 Nm / 1400-1800 Rpm

Turbocharger: fix geometry

Intercooler: var

2) Briggs ve Stratton Vanguard benzinli motor olup daha önce doktora tezinde (Taşdemir 2004) bu motor üzerinde yapılan deneylerden elde edilen veri kümesi kullanılmıştır. Motorun teknik özellikleri aşağıdaki gibidir.

Silindir Sayısı: 1

Silindir çapı x kurs: 68 x 50 mm

Silindir Hacmi: 182 cm^3

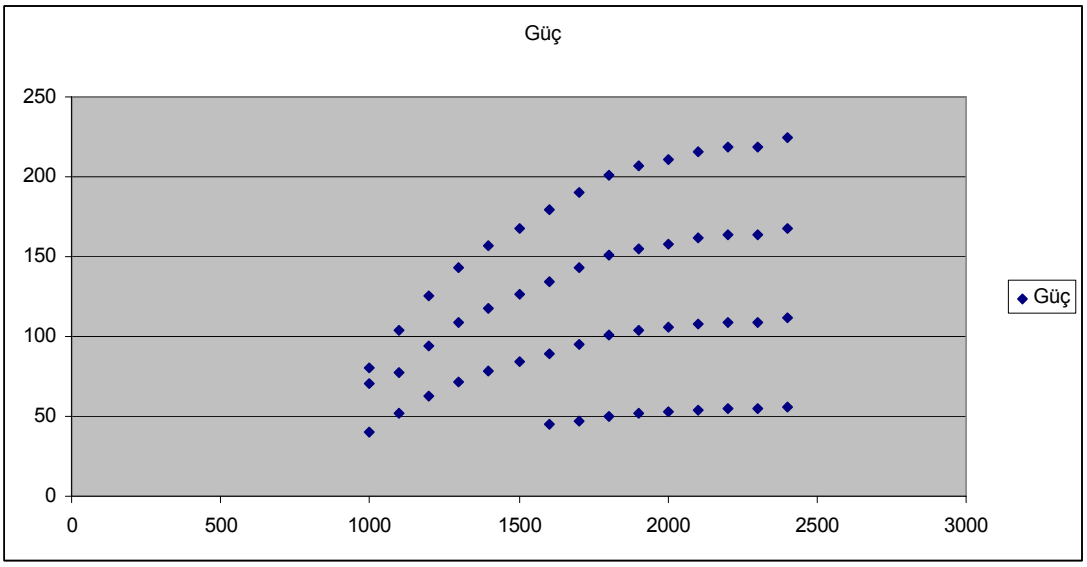
Emme açılma vanası: 16^0 önce ÜÖN

Emme kapanma gecikmesi: 44^0 sonra AÖN

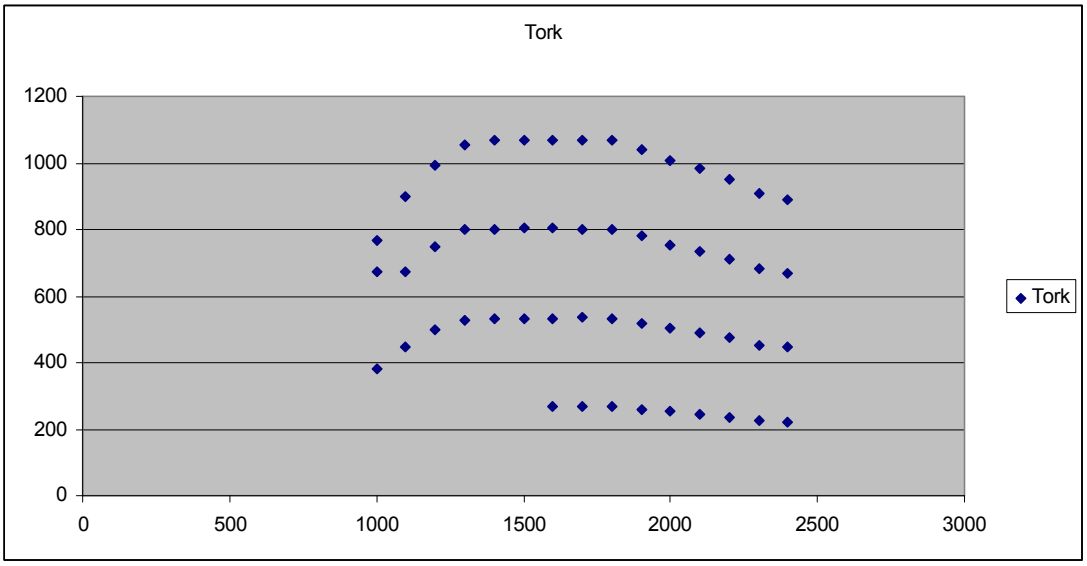
Egzoz açılma avansı: 45^0önce AÖN

Egzoz kapanma gecikmesi: 15^0 sonra ÜÖN

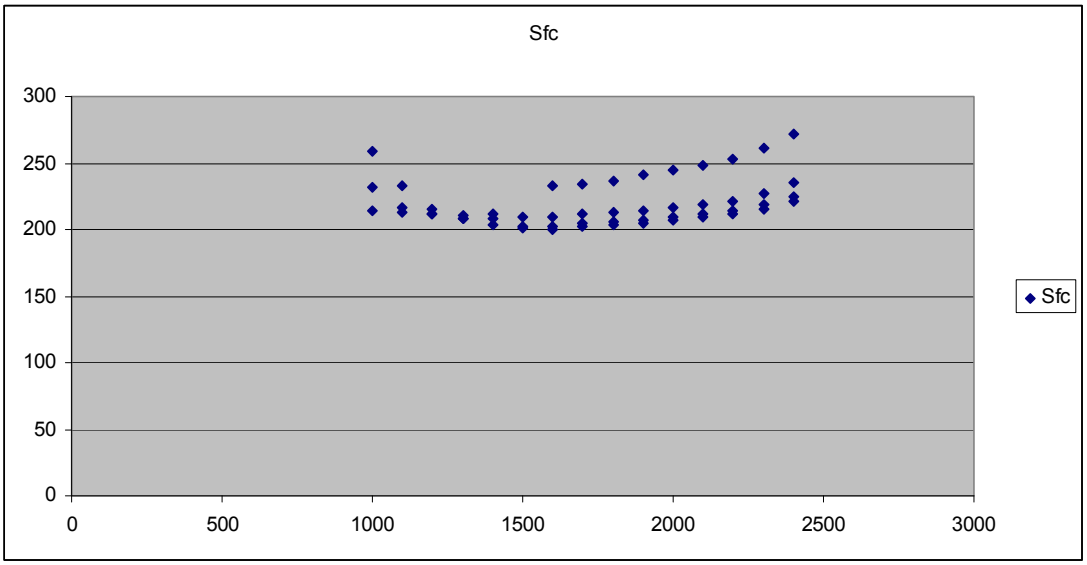
Ayrıca her iki motor üzerinde yapılan deneyler sonucu elde edilen ve tez çalışmasında kullanılan veriler Ek 1 ve Ek 2'de sunulmuştur. Verilerin doğruluğunun sağlanması ise veriler kullanılarak elde edilen grafiklerin (hız-güç, hız-moment ve hız-yakıt sarfiyatı) dizel motor performans karakteristiği grafiklerine uygun olmasından ve alan uzmanlarının görüşünün alınmasından sonra gerçekleştirilmiştir. Şekil 3.1 ve Şekil 3.3 arası bu tezde kullanılan 300PS E1 J1 yüksek torklu dizel motor için deneysel verilerin devir-güç, devir-tork ve devir- özgül yakıt sarfiyatı grafiklerini göstermektedir. Şekil 3.4 ve Şekil 3.6 arası ise Briggs ve Stratton Vanguard benzinli motor için deneysel verilerin devir-güç, devir-tork ve devir- özgül yakıt sarfiyatı grafiklerini göstermektedir.



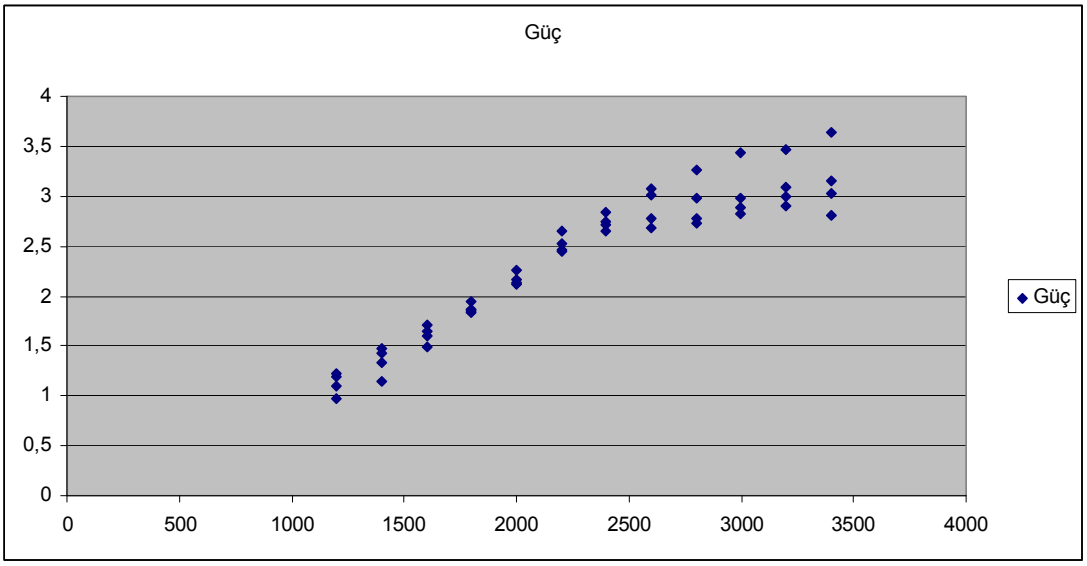
Şekil 3.1. 300PS E1 J1 dizel motor verisi için devir-güç grafiği



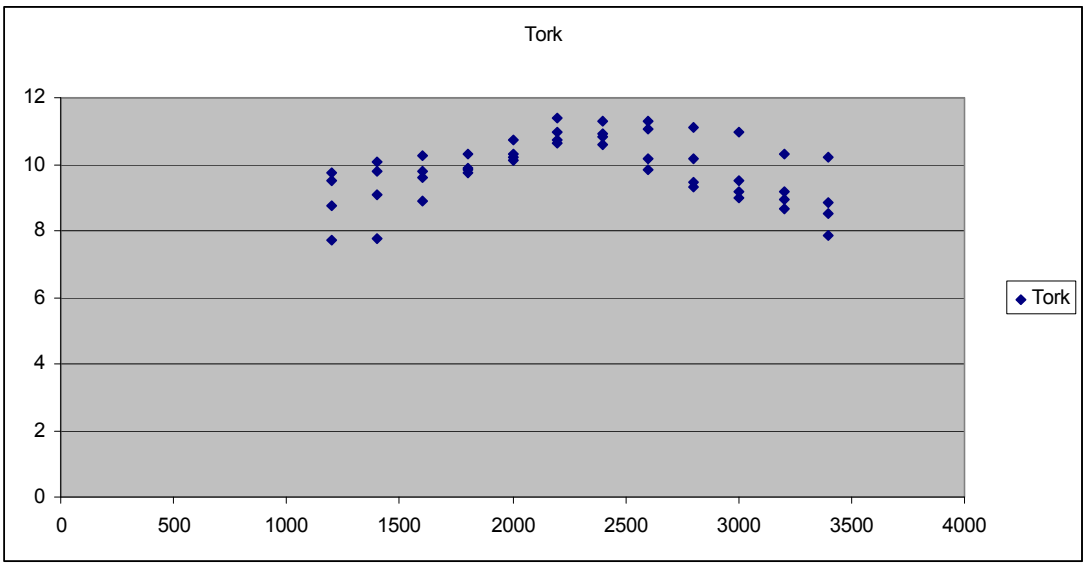
Şekil 3.2. 300PS E1 J1 dizel motor verisi için devir-tork grafiği



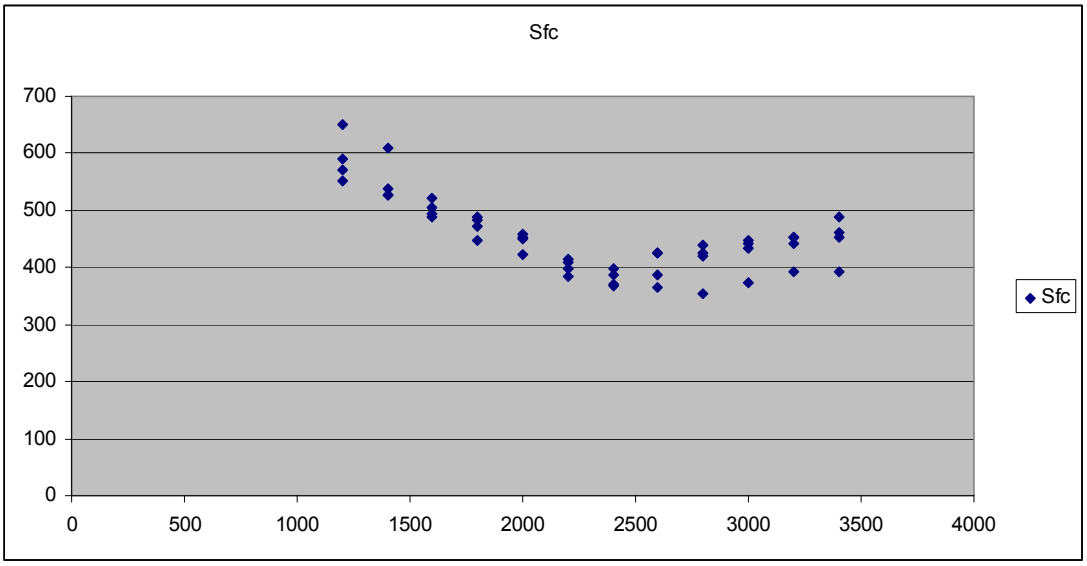
Şekil 3.3. 300PS E1 J1 dizel motor verisi için devir-özgül yakıt tüketimi (Sfc) grafiği



Şekil 3.4. Briggs ve Stratton Vanguard benzinli motor verisi için devir-güç grafiği



Şekil 3.5. Briggs ve Stratton Vanguard benzinli motor verisi için devir-tork grafiği



Şekil 3.6. Briggs ve Stratton Vanguard benzinli motor verisi için devir-özgül yakıt tüketimi (Sfc) grafiği

3.2. Metot

Bu tez çalışması 3 ana uygulamadan oluşmaktadır. Bunlar sırası ile motor performans ve emisyonunun noktasal modellemesi, optimum aralıksal modellemesi ve yakıt optimizasyonudur. Motor performans ve emisyon modellemesinde YSA, Regresyon ve ANFIS metotları kullanılmıştır. Aralıksal modelleme yönteminde ise *k*-ortalamalar, bulanık *c*-ortalamalar ve ANFIS kullanılmıştır. Modellenen motorun yakıt optimizasyonu için tek amaçlı ve çok amaçlı GA kullanılmıştır.

3.2.1 Çoklu- Regresyon

İstatistik biliminin en önemli konularından birisini regresyon analizi oluşturmaktadır. Regresyon analizi, araştırma, matematik, finans, ekonomi, tıp gibi bilim alanlarında yoğun olarak kullanılmaktadır. Regresyon analizinin temelinde;

gözlenen bir olayın değerlendirilirken, hangi olayların etkisi içinde olduğunun araştırılması yatmaktadır. Bu olaylar bir veya birden çok olacağı gibi dolaylı veya direkt etkileniyor da olabilirler. Regresyon analizi yapılırken, gözlem değerlerinin ve etkilenilen olayların bir matemetiksel gösterimle yani bir fonksiyon yardımıyla ifadesi gerekmektedir. Kurulan bu modele regresyon modeli denilmektedir (NC 2008).

Regresyon analizi incelenirken, genellikle konusunu oluşturan, etkilendiği olaylara değişkenler adı verilir bu değişkenlerin yer alacağı matematiksel model incelenir. Değişken, belirli bir zaman aralığı gözönüne alınıp, o zaman aralığında bir kütleyi oluşturan belli birimdeki olayları içeren örneklerdir. Sayılabilir veya ölçülebilir nitelikte olmalıdır. Örneğin 50 günlük (t…..t+49) zaman diliminde değişen TCMB Döviz Kurları değişken olarak nitelendirilebilir. Bir hissenin fiyatını bir değişken alırsak, ona dolaylı olarak veya direkt etkili bir veya birden çok değişken alabiliriz (Örneğin: Faiz oranları, enflasyon, ekonomik, politik, finansal olaylar vs.). Sadece faiz oranlarının etkisi ile ilgileniyorsak, tek değişkenli bir matematiksel model, faiz oranları ile birlikte enflasyon oranı ile de ilgileniyorsak, iki değişkenli bir matematiksel modelden söz ediyoruzdur. Faiz oranları hisse senedinin fiyatını direkt etkileyen bir unsur olmadığı halde faiz oranlarının yükseldiği durumda hisse senedinin fiyatının düşüyor olmasının gözlemlenmesi bir etkileşim olduğunun göstergesidir.

Öncelikle Regresyon modelinin kullanılması, ilgilenilen olayla ilgili olarak, bir sebep-sonuç ilişkisi bulunması gerekmektedir. Örneğin 1990-1997 yılları arasındaki hisse senedi fiyatlarını incelersek, seçilen zaman aralığında bir matematiksel model kurma gereği vardır ve bu modelde bir sebep, sonuç ilişkisi aranmaktadır. Sebep, hisse senedinin fiyatını yükselten veya düşüren unsurlardır. Faiz oranları, ekonomik nedenler, enflasyon oranları vs. olarak incelenebilir. Sonuç ise hisse senedinin fiyatının değişmesidir. Sebep-sonuç ilişkisi, regresyon modeli kurulurken, bağımlı ve bağımsız değişkenler olarak anlatılmaktadır. Yukarıdaki hisse senedi fiyatı sonuç olan bağımlı değişken, faiz oranları, ekonomik nedenler, enflasyon oranları vs. sebep olan bağımsız değişkenlerdir. Regresyon analizi yapılırken kurulan matematiksel modelde yer alan değişkenler bir bağımlı değişken ve bir veya birden çok bağımsız değişkenden oluşmaktadır. Bağımsız değişkenler

kurulacak modelde bir değişkenli olarak ele alınırsa, basit doğrusal regresyon, birden fazla bağımsız değişkenli olarak alınırsa, çoklu regresyon modeli konusunu oluşturmaktadır.

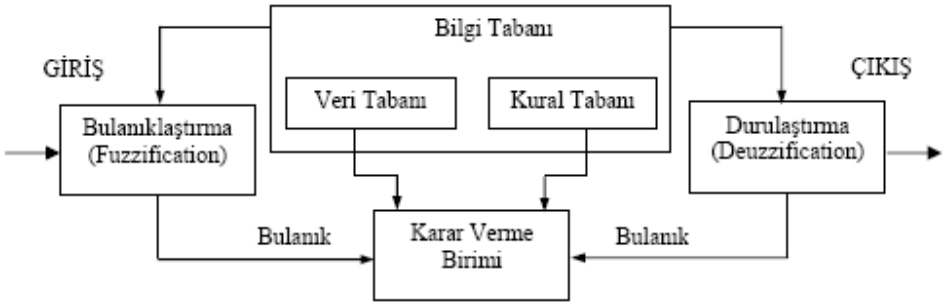
Model

Basit Doğrusal Regresyon Modeli:	$Y = a + bc + e_i$
Çoklu Regresyon Modeli:	$Y = a + bX_1 + cX_2 + dX_3 + ... + e_i$
Y :	Bağımlı değişken
X_1 , X_2 , X_3 , ... :	Bağımsız değişkenler
$a, b, c, d, ...$:	Katsayılar
e_i :	Hata terimi

3.2.2. Uyarlamalı bulanık uzman sistem (ANFIS)

Bulanık çıkarım sistemi, temel olarak üç kavramsal bileşenden oluşmaktadır. Bunlar; bulanık kurallarının toplamından oluşan *kural tabanı*, üyelik derecelerin tanımlanmasında kullanılan *veri tabanı,* sistem giriş ve çıkışlarından, kuralların toplanması ve uygun sonuçların üretilmesi işlevini gören *çıkarım mekanizması*dır (Chang ve ark. 2006, Şen ve ark. 2004). BM ile modellemede işleyiş, giriş değişkenlerinin üyelik derecelerinin belirlenmesi, kuralların oluşturulması, bu kurallardan çıkış karakteristiklerinin belirlenmesi, çıkış üyelik fonksiyonlarına geçiş ve en son adım olarak bu sistem çıkışının elde edilmesi şeklindedir. BM ile modellemede en önemli adım giriş/çıkış değişkenlerinin üyelik derecelerinin belirlenmesidir. Son yıllarda, YSA ve BM yöntemlerinin birlikte kullanılmasından oluşan Uyarlamalı Bulanık Uzman Sistem (ANFIS) yöntemi kullanılmaktadır. ANFIS, YSA'ın öğrenme yeteneğini kullanarak giriş ve çıkış değişkenlerini ilişkilendirmekte ve bulanık kurallar oluşturulmaktadır. Model parametrelerinin belirlenmesinde "*eğim düşümü*" yöntemi ve "*en küçük kareler*" yöntemlerinin birleşiminden oluşan *Hybrid öğrenme algoritması* gibi algoritmalar mevcuttur. Eğim düşümü yöntemi, lineer olmayan giriş parametrelerinin düzenlenmesinde, en küçük

kareler yöntemi ise lineer çıkış parametrelerinin düzenlenmesinde kullanılmaktadır (Firat ve ark. 2008). Eğim düşümü yöntemi, modellemede ağ hatasını en küçük yapacak şekilde ağırlık katsayılarının değiştirilmesi ve güncelleştirilmesi için kullanılmaktadır. Hybrid öğrenme algoritması yardımıyla, giriş üyelik fonksiyonu parametrelerinin ve çıkış üyelik fonksiyon parametreleri güncellenmekte ve ve en uygun değerler elde edilmektedir. Literatürde en çok bulanık mantık çıkarım sistemi, *Mamdani* çıkarım sistemi ve *Sugeno* bulanık çıkarım sistemidir. İki sistemi birbirinden ayıran en önemli özellik çıkış değişkenlerinin tanımlanmasıdır. Bulanık çıkarım sisteminin genel yapısı Şekil 3.7'deki gibi verilmektedir. Bulanık çıkarım sisteminde çıkış değişkeni iki şekilde tanımlanır. Bunlar, "*sabit bir katsayı- 0. dereceden Sugeno model*" yada giriş değişkenlerine bağlı "*bir fonksiyon 1. dereceden Sugeno model*" dir.

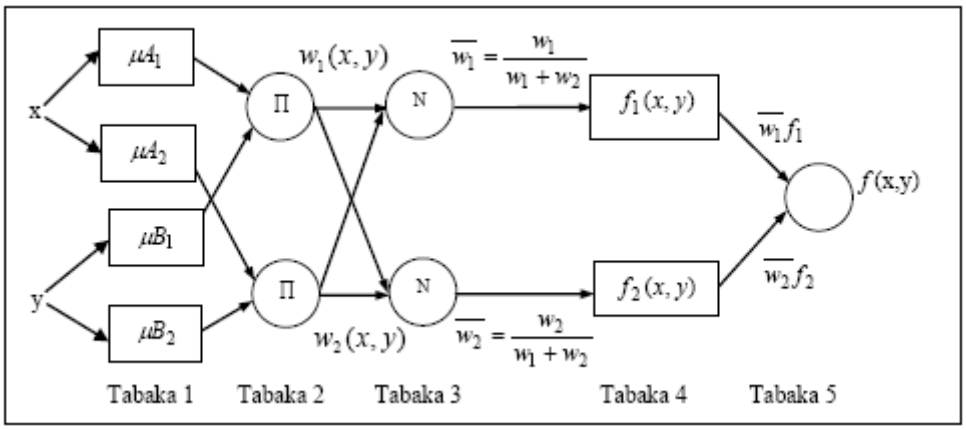


Şekil 3.7. Bulanık uzman sisteminin genel yapısı

Şekil 3.8'de iki giriş ve 1 çıkış değişkenine sahip ANFIS sisteminin yapısı gösterilmektedir. İki girişli bir yapı için 1. dereceden ANFIS sisteminin kuralları aşağıdaki gibi yazılabilir.

Kural 1: **EĞER** x is A_1 **ve** y is B_1 **İSE**
$f_1 = p_1 * x + q_1 * y + r_1$
Kural 2: **EĞER** x is A_2 **ve** y is B_2 **İSE**
$f_2 = p_2 * x + q_2 * y + r_2$

Burada, x ve y; bulanık olmayan giriş değerleri, $\boldsymbol{p_1, q_1, r_1, p_2, q_2}$ **ve** $\boldsymbol{r_2}$ ise çıkarım sisteminin çıkış fonksiyonunun parametreleridir. ANFIS genel olarak aşağıdaki adımlardan oluşmaktadır.



Şekil 3.8. ANFIS sisteminin genel yapısı

Giriş düğümü (Tabaka 1): Bu tabakadaki her bir düğüm, giriş değişkenlerinin üyelik fonksiyonlarını göstermekte ve her bir düğüm çıkışı Oi^1

$$O_i^1 = \mu_A(x) \qquad i = 1,2$$
$$O_i^1 = \mu_{Bi-2}(y) \qquad i = 3,4 \tag{3.1}$$

Burada, μ_{Ai} ve μ_{Bi} ; A_i ve B_i bulanık setlerinin üyelik fonksiyonları göstermektedir.

Kural düğümü (Tabaka 2): Bu tabakadaki her bir düğüm AND/OR operatörleri kullanılarak Π ile gösterilen giriş sinyalleri çarpılır ve ateşleme kuvveti Oi^2 elde edilir.

$$O_i^2 = w_i = \mu_{Ai}(x)\mu_{Bi}(y), \qquad i = 1,2 \tag{3.2}$$

Ortalama düğüm (Tabaka 3): Bu tabakada her bir düğümden elde ateşleme kuvvetleri toplanır ve denklem (3.3) yardımıyla normalize edilir.

$$O_i^3 = \overline{w_i} = \frac{w_i}{w_1 + w_2}, \qquad i = 1,2 \tag{3.3}$$

Tabaka 4: Bu tabakada, her bir düğümün model çıktısına katkısı hesaplanır.

$$O_i^4 = \overline{w_i}.f_i = \overline{w_i}.(p_i x + q_i y + r_i) \qquad (3.4)$$

Çıkış düğümü (Tabaka 5): Bu tabakada, sistemin genel çıkışı hesaplanır ve durulaştırma işlemi ile bulanık değerden kesin değere dönüştürülür.

$$f(x,y) = \frac{w_1(x,y)f_1(x,y) + w_2(x,y)f_2(x,y)}{w_1(x,y) + w_2(x,y)}$$
$$= \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2}$$
$$O_i^5 = f(x,y) = \sum_i \overline{w_i}.f_i = \overline{w_1}f_1 + \overline{w_2}f_2 = \frac{\sum_i w_i f_i}{\sum_i w_i} \qquad (3.5)$$

3.2.3. Yapay zeka (YZ) ve Yapay sinir ağları (YSA)

YZ, bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır (Nabiyev 2005).

3.2.3.1 YSA

Yapay Sinir Ağları, insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışılan yaklaşımlardır. Beynimizdeki biyolojik sinir hücrelerinin yapısı temel alınarak YSA yapısı oluşturulur. YSA'nda aynen beynimizde olduğu gibi öğrenme ve öğrenilen bilgilere göre karar verme mekanizmaları bulunur (Öztemel 2003, Sağıroğlu ve ark. 2003, Allahverdi 2002).

YSA konusunda ilk çalışma McCulloch ve Pitts tarafından 1940'lı yıllarda yapılmıştır. Bu araştırmacılar 1943 yılında yapay sinir sisteminin ilk matematiksel modelini geliştirmişlerdir (McCulloch ve Pitts 1943). Bu araştırmacıların yayınladığı "Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap" başlıklı makalede YSA konusunda ilk adım atılmıştır. Çalışmalarında herhangi bir hesaplanabilir fonksiyonun sinir hücrelerinden oluşan ağlarla hesaplanabileceğini göstermişlerdir. İlerleyen zamanlarda Hebb (1949), Rosenblatt (1958), Widrow ve Hoff (1960), Hopfield (1982), Kohonen (1982), Rumelhart ve ark. (1986) ve daha birçok araştırmacı farklı YSA öğrenme algoritmaları geliştirmişlerdir.

Yapay Sinir Ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) meydana gelmektedir. Temel olarak bir YSA'nın görevi, kendisine gösterilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur. Literatürde birçok öğrenme algoritması ve sinir ağı modeli mevcuttur. Bu algoritmalar ve modeller bu bölümde ayrıntılı olarak anlatılacaktır.

3.2.3.2 YSA'nın genel özellikleri

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Bu değişik ağ modelleri ilerleyen kısımlarda anlatılacaktır. Genel karakteristik özellikler şunlardır (Öztemel 2003, Sağıroğlu ve ark. 2003, Allahverdi 2002):

- YSA öğrenme gerçekleştiririler. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.
- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veritabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.

- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dahil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilir.
- Hata toleransına sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık belleğe sahiptirler. YSA'nda bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir.

3.2.3.3. YSA'nın dezavantajları

YSA'nın birçok önemli dezavantajı vardır (Sağıroğlu ve ark. 2003, Haykin 1999). Bunlar:

- Probleme uygun ağ yapısının belirlenmesi zor bir süreçtir. Genellikle ağ yapısı belirlenirken deneme-yanılma metodu kullanılır. Bu da bazen çok uzun zaman almaktadır. Eğer problem için uygun ağ yapısı belirlenemezse, çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olmaktadır. Aynı zamanda bu durum bulunan çözümün en doğru çözüm olduğunun garantisini de vermez.
- Bazı ağlarda ağın parametre değerlerinin (örneğin öğrenme katsayısı, hücre sayısı v.b.) belirlenmesinde bir kural olmaması, çözümlere ulaşmada sorun oluşturur. Bu değerler kullanıcının tecrübesine bağlıdır ve her problem için farklı etkenlere dikkat etmek gerekir.
- Problemin ağa gösterimi çok önemli bir etkendir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının

becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulmamış olması problemin çözümünü engelleyebilir.

- Ağın eğitiminin ne zaman bitirileceğine dair kesin kurallar yoktur. Eğitimde hata toleransının belli bir değerin altına inmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede en iyi öğrenmenin gerçekleştiği söylenememektedir.

3.2.3.4. YSA'nın temel yapısı

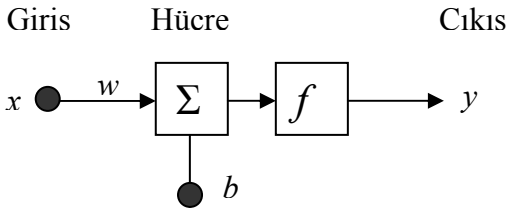
YSA sinir hücrelerinin bir araya gelmesiyle oluşurlar. Tabi bu işlem rasgele olarak yapılmamaktadır. Genelde hücreler, 3 katman halindedir ve her katman içinde paralel halde ağı oluştururlar (Koçer 2007). Bu katmanlar;

- Giriş Katmanı: Bu katmandaki hücreler giriş bilgilerini gizli katmana ulaştırmakla görevlidir.
- Gizli Katman: Giriş katmanından gelen bilgiler işlenerek çıkış katmanına gönderilir. Bir ağda problemin durumuna göre, birden fazla gizli katman olabilmektedir.
- Çıkış Katmanı: Bu katmandaki hücreler gizli katmandan gelen bilgiyi çıkış katmanına gönderirler. Üretilen çıkışlar problemin çözümünü içermektedir.

3.2.3.5. Yapay sinir ağı hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli Şekil 8.1'de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron

çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlineer) bir fonksiyondur (Haykin 1999).



Şekil 3.9. Temel yapay sinir ağı hücresi

Burada *b* bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir.

Çıkış;

$$y = f(w.x + b) \tag{3.6}$$

şeklinde nöron çıkışı hesaplanır. Buradaki w ağırlıklar matrisi, x ise girişler matrisidir. n giriş sayısı olmak üzere;

$$w = w_1, w_2, w_3, \ldots, w_n \tag{3.7}$$

$$x = x_1, x_2, x_3, \ldots, x_n$$

şeklinde yazılabilir. Buradan;

$$net = \sum_{i=1}^{n} w_i x_i + b \quad \text{ve} \quad y = f(net)$$

$$y = f\left(\sum_{i=1}^{n} w_i x_i + b\right) \tag{3.8}$$

şeklinde de yazılabilir. Yukarıdaki formülde görülen f aktivasyon fonksiyonudur. Genelde lineer olmayan olan aktivasyon fonksiyonunun çeşitli tipleri vardır. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun –1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse –1, sıfıra eşitse sıfır değerini verir. Lineer aktivasyon fonksiyonunun çıkışı girişine

eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir (Bishop 1995).

$$f(x) = x \tag{3.9}$$

şeklinde ifade edilir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir. Böylece daha sonraki bölümlerde görülecek olan geri yayılımlı ağlarda kullanmak mümkün olabilmektedir (Bishop 1995).

Fonksiyonu tanımlarsak,

$$f(x) = lojistik(x) = \frac{1}{1 + exp(-\beta x)} \tag{3.10}$$

şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile –1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir (Haykin 1999, Bishop 1995).

$$f(x) = tanh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}} \tag{3.11}$$

3.2.3.6. YSA öğrenme algoritmaları

Bugüne kadar geliştirilmiş birçok öğrenme algoritması mevcuttur. Bunların büyük çoğunluğu matematik tabanlıdır ve ağırlıkların güncelleştirilmesi için kullanılırlar. Mevcut öğrenme algoritmaları Hebb (1949), Delta, Kohonen (1982) ve Hopfield (1982) olmak üzere 4 öğrenme algoritması temel alınarak geliştirilmiştir (Sağıroğlu ve ark. 2003, Haykin 1999, Bishop 1995).

Hebb Öğrenme Kuralı: Bilinen en eski öğrenme kuralıdır. Hebb'in (1949) geliştirdiği bu öğrenme algoritması, "bir nöron diğer bir nörondan giriş alıyorsa ve her iki nöronda aktif ise (matematiksel olarak aynı işarete sahip ise), nöronlar

arasındaki ağırlık kuvvetlendirilir" esasına göre çalışır. Diğer bir deyişle, bir hücrenin kendisi aktif ise, bağlı olduğu hücreyi aktif yapmaya çalışır. Tersi durumda pasif yapmaya çalışır. Diğer birçok öğrenme kuralı bu felsefeyi baz alarak geliştirilmiştir.

Delta Öğrenme Kuralı: Bu kural Hebb kuralının biraz daha geliştirilmiş şeklidir. Bu kurala göre, beklenen çıkış ile gerçekleşen çıkış arasındaki farklılığı azaltmak için ağırlık değerleri sürekli değiştirilmelidir. Ağın ürettiği çıkış ile üretilmesi beklenen çıkış arasındaki hatanın karelerinin ortalamasını en aza indirmek hedeflenmektedir. Hata aynı zamanda bir katmandan bir önceki katmanlara geriye yayılarak azaltılır. Bu kural geri yayılım, Widrow-Hoff (1960) veya en küçük ortalama karesel öğrenme kuralı olarak da bilinir.

Kohonen Öğrenme Kuralı: Kohonen (1982) tarafından geliştirilmiş olan bu kurala göre ağın hücreleri ağırlıklarını değiştirmek için birbirleriyle yarışırlar. En büyük çıkışı veren yani kazanan hücre ağırlığını değiştirir. Bu, o hücrenin diğer hücrelere karşı daha kuvvetli hale gelmesi anlamını taşır. Kohonen kuralı hedef çıkışa gereksinim duymaz ve dolayısıyla danışmansız bir öğrenme metodudur.

Hopfield Öğrenme Kuralı: Bu kural da Hebb kuralına benzer. Hopfield (1982) kuralında hücreler arası bağlantıların ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Eğer beklenen çıkış ve girişlerin ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendirilir/zayıflandırılır. Öğrenme katsayısı 0 ile 1 arasında bir değer alır.

3.2.3.7. Performans fonksiyonun seçimi

Performans fonksiyonu YSA'nın öğrenme performansını ölçmede kullanılan bir ölçüttür. (Rumelhart ve ark. 1986). İleri beslemeli ağlarda genellikle ortalama karesel hata (Mean Square Error - MSE) performans fonksiyonu olarak kullanılır. MSE fonksiyonu istenen sonuç ile hesaplanan sistem çıkışı arasındaki farkın kareleri toplamının ortalaması olup aşağıdaki formülle hesaplanır:

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i^{'} - y_i)^2 \qquad (3.12)$$

Burada *y*, istenen çıkış değerini; *y'* ise sistem tarafından hesaplanan çıkış değerini ifade eder. *N* ise çıkış sayısını belirtmektedir. Hatanın sıfıra yaklaşması istenen çıkış değerine yakın çıkış değeri elde edilmiş olması demektir.

İleri beslemeli ağlarda kullanılan bir diğer performans fonksiyonu toplam karesel hata (Sum Square Error – SSE)'dır (Sağıroğlu ve ark. 2003). (3.13)'de verilen denklem kullanılarak toplam karesel hata hesaplanır:

$$SSE = \sum_{i=1}^{N}(y_i^{'} - y_i)^2 \qquad (3.13)$$

Bunlardan başka performans fonksiyonu olarak kullanılan bir diğer hata hesaplama yöntemi ortalama karesel hatanın karekökü (Root Mean Square – RMS) fonksiyonudur ve aşağıdaki formül ile hesaplanır:

$$RMS = \sqrt{\frac{1}{N}}\sqrt{\sum_{i=1}^{N}(y_i^{'} - y_i)^2} \qquad (3.14)$$

Sağıroğlu ve ark. (2003) 'na göre performans fonksiyonuna ağın biaslarının ve ağırlıklarının kareleri toplamının ortalama değerini ifade eden bir terim eklenerek genelleştirme daha da iyileştirilebilir. Böylece ağ daha hassas hale getirilir ve ağın, eğitim kümesi haricindeki veriler için sağlıklı bir genelleme yapmasını engelleyebilir. Bunun yanı sıra genelleştirmeyi iyileştirmek için kullanılan yöntemlerden birisi de öğrenmeyi erken sonlandırmaktır (Sağıroğlu ve ark. 2003). Bu yöntemde, YSA'ya uygulanacak veri kümesi üç bölüme ayrılır. İlk küme YSA'nın eğitiminde kullanılarak ağırlıkların, biasın ve eğimin güncelleştirilmesinde kullanılır. İkinci bölüm veri kümesi ise doğrulama verisi olarak kullanılır. Eğitim süresince, eğitim verilerinden hesaplanan hata oranı düştüğü gibi test veri kümesine ait hata da normal şartlarda düşer. YSA, eğitim veri kümesi üzerinde bir aşırı öğrenme eğilimine girerse, doğrulama veri kümesinden hesaplanan hata değeri artmaya başlar (Sağıroğlu ve ark. 2003). Bu çalışmada doğrulama veri kümesinden hesaplanan hata değeri belirlenmiş bir eşik değerini aştığı durumlarda eğitim

durdurulmuştur ve ağırlık ve bias değerleri, doğrulama veri kümesinden elde edilen hataların minimum olduğu andaki değerlerine geri döndürülmüştür.

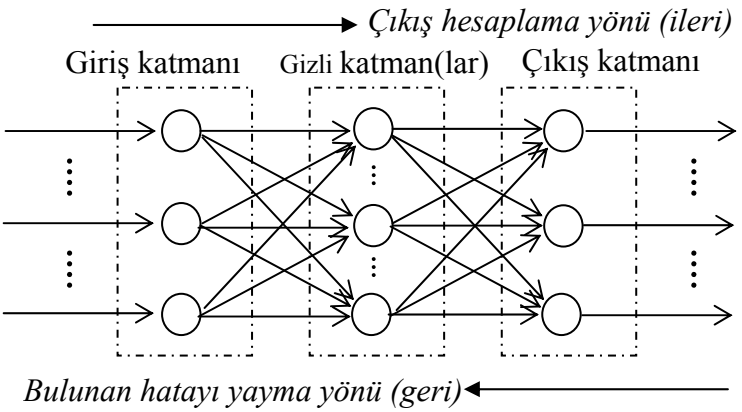
3.2.3.8. YSA modelleri

Yapay sinir ağları yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde modellenebilir. İleri beslemeli modelde, bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Özbay ve Karlık 2001). Katmanlardaki hücrelerin sayısı tamamen uygulanan probleme bağlıdır. Hücreler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Giriş bilgileri, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Türkoğlu ve Arslan 1996). İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perseptron – MLP), modüler sinir ağları (Modular Neural Networks – MNN), vektör kuantalamalı öğrenme (Learning Vector Quantization – LVQ), radyal tabanlı fonksiyon (Radial Basis Function – RBF) ve olasılık tabanlı (Probabilistic Neural Netwrok – PNN) sinir ağları verilebilir.

Geri beslemeli sinir ağı modelinde ise çıkış katmanındaki ve gizli katmandaki çıkışlar, giriş katmanındaki hücrelere veya bir önceki gizli katmanlara geri besleme şeklinde iletilir (Öztemel 2003). Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip sinir ağlarının hafızaları dinamiktir ve çıkış hem anlık hem de önceki girişleri yansıtır. Bundan dolayı, bu tip sinir ağı modeli önceden tahmin uygulamaları için daha uygundurlar (Haykin 1999). Geri beslemeli ağ modeline örnek olarak Hopfield, adaptif rezonans teori (ART), kendi kendine organize olabilen harita (Self Organizing Map – SOM) ağları, Elman ve Jordan ağları verilebilir.

3.2.3.9. Çok katmanlı perseptron (ÇKP) modeli

Çok katmanlı perseptron (ÇKP), giriş, gizli ve çıkış katmanından oluşmuş ileri beslemeli bir ağdır (Şekil 3.7) (Haykin 1999). Katmanlardaki nöronlar arasında ve bir katmandan önceki katmana geriye doğru bağlantı yoktur.



Şekil 3.10. Çok katmanlı perseptron ağ yapısı

Herhangi bir katmandaki *j.* birime gelen toplam giriş, önce k_i katmandaki birimlerin y_i çıkışlarının (l. katman için girişlerin) bağlantılar üzerindeki w_{ij} ağırlıkları ile hesaplanmış bir ağırlıklı toplamıdır.

$$x_j = \sum w_{ij} \cdot y_i \tag{3.15}$$

Birimin çıkışı, bu toplam girişi bir lineer olmayan fonksiyondan geçirerek belirlenir. Bunun için birçok fonksiyon teklif edilmiştir. Ancak en çok kullanım göreni aşağıdaki sigmoid fonksiyondur.

$$y_j = \frac{1}{1+e^{-x_j}} \tag{3.16}$$

Bu fonksiyon yakınsama şartını, yani "her birimin çıkışı, toplam girişin devamlı artan, türevi sınırlı bir fonksiyonu olmalıdır" şartını sağlar. Bu fonksiyon y_j çıkışını 0 ve 1 değerleri arasına sınırlar.

MLP'de, ilk katmana bir giriş vektör uygulanır. Daha sonra giriş ve l. Katman arasındaki ağırlıklar yardımıyla 1. katmandaki her birimin aldığı toplam giriş belirlenir. Her birim girişini bir lineer olmayan fonksiyondan geçirerek bir sonraki katmana göndereceği çıkış işaretini belirler. Bir katmandaki tüm birimlerin durumları paralel olarak belirlenir. Bu işlem çıkış katmanındaki birimlerin durumları belirleninceye kadar sırayla tekrar edilir.

MLP ağının eğitilmesi danışmanlı öğrenmeye bir örnek oluşturabilir. Bu ağda girişe bir giriş vektörü uygular ve bir çıkış vektörü elde eder. Daha sonra bu çıkış vektörünü istenilen bir "hedef" vektörü ile karşılaştırır ve bu iki vektör arasındaki fark en küçük olacak şekilde ağ ağırlıklarını ayarlar. Amaç her giriş vektörü için, ağın üreteceği cevabın istenilen çıkış vektörünün aynısı (veya yeterince yakını) olmasını sağlayan bir ağırlık kümesi bulmaktır.

Eğitme iki adımlı bir işlemdir. İlk adımda bir giriş vektörü uygulanır, ağ içindeki her birim için toplam giriş ve çıkış hesaplanır ve her birimin çıkışı daha sonra ağırlık ayarlamasında kullanılmak üzere saklanır. Çıkış vektörü oluşturulduktan sonra, eğitme işlemi çıkış hatasını hesaplar ve bu hatanın geriye doğru yayılımını sağlar. Birimlerin ağırlıkları bu hata işaretine göre ayarlanır. Bu iki adımlı işlem ağ istenilen cevapları üretinceye kadar, eğitme vektör çiftleri ile tekrar edilir (Bishop 1995, Haykin 1999).

Çıkış katmanını eğitmek bağıl olarak daha basittir. Sorun bir hedef vektörünün olmadığı ara katman ağırlıklarını eğitirken ortaya çıkar. Bunun çözümü, hata işaretinin çıkıştan daha iç katmanlar doğru yayılımını sağlamakla bulunur. Yani bir iç veya ara katman birimi, kendisinden sonraki katmanın hata işaretlerinin ağırlaştırmış toplamı olan bir hata işareti alır. Bu hata işareti her birim ağırlıklarını eğitmek için kullanıldıktan sonra; eğitme işlemi, oluşturulan yeni hata işaretinin daha önceki katmanlara doğru yayılımını sağlar.

Önceden belli, sonlu sayıda giriş-çıkış çifti için, belli bir ağırlık kümesine sahip ağın davranışındaki hata, her çift gerçek ve istenilen çıkış vektörlerini karşılaştırarak hesaplanabilir. E toplam hatası aşağıdaki şekilde tanımlanabilir.

$$E = \frac{1}{2} \cdot \sum_{j} \sum_{k} (y_{j,k} - d_{j,k})^2 \qquad (3.17)$$

Burada *k* giriş-çıkış çiftlerinin, *j* çıkış birimlerinin indisidir *y* bir çıkış biriminin gerçek durumunu, *d* ise istenen durumunu göstermektedir. Verilen bir giriş-çıkış çifti için hata her ağırlığa göre iki adımda hesaplanır. Geri yön adımı, her çıkış birimi için $\partial E / \partial y$ büyüklüğünü hesaplayarak başlar. Belli bir k çifti için denklem 3.18 türetilirse ve *k* indisi yazılmazsa,

$$\frac{\partial E}{\partial y_j} = y_j - d_j \qquad (3.18)$$

elde edilir. Daha sonra $\partial E/\partial x$ 'yi hesaplamak için aşağıdaki zincir kuralı kullanılabilir.

$$\frac{\partial E}{\partial y_j} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{dx_j} \qquad (3.19)$$

dy/dx'nin değerini bulmak için (3.17) denklemi türetilerek yukarıda yerine konursa,

$$\frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \cdot y_j \cdot (1 - y_j) = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \qquad (3.20)$$

ifadesi elde edilir. Bu da, *j.* çıkış birimine toplam giriş büyüklüğündeki (X_j) bir değişimin hatayı nasıl etkilediğini bildiğiniz anlamına gelir. Bu ifade çıkış katmanından bir birimden geriye doğru yayılımı yapılacak hata işaretidir. Bu toplam giriş, alçak katman birimlerinin y_i çıkışlarının bir lineer fonksiyonudur. x_j girişi aynı zamandaki ağırlıkların da bir lineer fonksiyonudur. Dolayısıyla ara katman çıkışlarındaki veya ağırlardaki bir değişimin hatayı nasıl etkileyeceğini hesaplamak kolaydır. *i.* birimden, *j.* birime bir w_{ij} ağılığındaki değişimin hataya etkisi,

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dw_j} = \frac{\partial E}{\partial x_j} \cdot y_i = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot y_i \qquad (3.21)$$

ifadesinden bulunabilir. Sondan bir önceki katmandaki *i.* birimin çıkışı için, *i*'nin *J* üzerindeki etkisi nedeniyle ortaya çıkan $\partial E/\partial y_i$ katkısı,

$$\frac{\partial E}{\partial y_i} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dy_i} = \frac{\partial E}{\partial x_j} \cdot w_{ij} \qquad (3.22)$$

şeklindedir. Bu şekilde *i*. birimden çıkan tüm bağlantıları göz önüne alarak,

$$\frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \cdot w_{ij} = \sum_j (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot w_{ij} \qquad (3.23)$$

elde edilir. Bu şekilde son katmandaki bu birimler için *∂E/∂y* verildiğinde, sondan bir önceki katmandaki herhangi bir birim için *∂E/∂y*'nin nasıl hesaplanacağı gösterilmiş olmaktadır. Bu ifade sondan bir önceki katmandaki *i*. birime gelen hata işaretidir. Daha önceki katmanlarda bu terimi hesaplamak için burada yapılan işlem tekrar edilebilir

Ağırlıkları ayarlamak için *ij ∂E/∂w* türevsel bilgisi kullanılır. Bu bilgiyi kullanmanın bir yolu ağırlıkları her giriş çıkış çiftinin uygulanmasından sonra değiştirmektir. Bu yöntemin *ij ∂E/∂w* türevlerini saklamak için hiç ayrı bellek ihtiyacı göstermemesi gibi bir avantajı vardır. Öte yandan ağırlıkları ayarlamanın bir başka yolu, tüm giriş-çıkış çiftlerinin uygulanması ile elde edilen *ij ∂E/∂w* değerlerini toplamak ve daha sonra bu bilgiyi w_{ij} ağırlığının değişiminde kullanmaktır. Eğim azalmasının en basit şekli, her w_{ij} ağırlığını *ij ∂E/∂w* değerine orantılı olacak şekilde değiştirmektir.

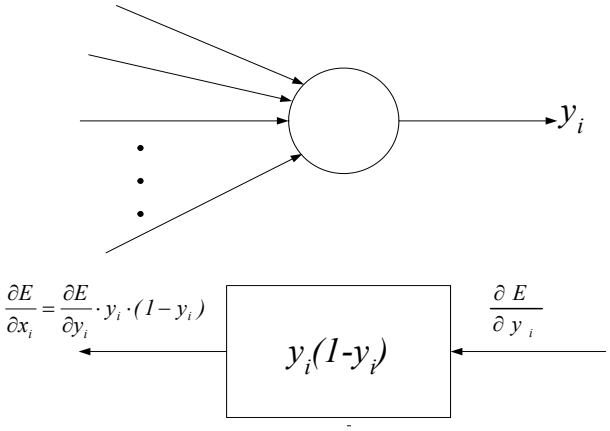
$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} \qquad (3.24)$$

Burada $w_{ij}(n)$ *i*. birimden *j*. birime olan ağırlığın hesaplamanın *n*. adımındaki değerini göstermektedir. ε ise 0 ile 1 arasında (tipik olarak 0, 1'ler mertebesinde) değer alan bir kazanç terimidir.

Ağırlık değişimindeki bu yöntem, ikinci türevleri kullanan yöntemler gibi hızlı yakınsamaz, fakat daha basittir ve paralel donanımda lokal hesaplamalar ile kolayca gerçeklenebilir. Bu yöntem aşağıdaki şekilde geliştirilebilir.

$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} + \alpha \cdot (w_{ij}(n) - w_{ij}(n--1)) \qquad (3.25)$$

Burada α ağırlıktaki değişimi önceki demişimin değerine bağlayan bir katsayıdır (0<α <1). Bu yeni öğrenme denklemi, ε'nun daha büyük değerlerine imkan sağlayarak yakınsamayı hızlandırır. Geri yayılım algoritmasında çıkışın hesaplanması işlemi ileri yönde gerçekleşir. Ancak eğitim sırasında hatanın bulunması ve değiştirilmesi geri doğru gerçekleştirilir (Şekil 3.8).



Şekil 3.11. Eğitme İşlemi

Geri yayılım algoritması uygulamada oldukça sık rastlanan bir algoritmadır. Bu algoritmada, hataların çıkıştan girişe geriye doğru azaltılmaya çalışılmasından dolayı geri yayılım ismini almıştır.

MLP sinir ağında eğitme aşamasında en sık kullanılan algoritmalardan Hızlı Yayılım (Quick-Propagation) ve Eşleştirmeli Eğim Algoritması (Conjugate Gradient Descent) aşağıda açıklanmıştır.

Hızlı yayılım algoritması (Quick-Propagation): Hızlı yayılım algoritması, Newton metoduna dayanan, çok katlı algılayıcıların eğitilmesi için kullanılan ve Newton metoduna dayanan sezgisel bir öğretme algoritmasıdır. Bu algoritmalar optimum çözümü garanti edemeyip sadece ona yakın çözümü bulmaktadırlar. Ayrıca bu algoritmada tecrübeye ve eğitilmiş tahmine dayalı kurallar bulunmaktadır (Fahlman 1988).

Hızlı yayılım algoritmasının sağladığı bazı önemli avantajlar şöyledir (Sağıroğlu ve ark. 2003):

• Herhangi bir tam yöntemin parçası olarak öğrenme amacıyla kullanılabilir.

• Gerçek dünya problemleri için her zaman matematiksel formülasyon kurmak çok kolay olmayabilir. Bu basitleştirme sonucu oluşan hata, bir hızlı yayılım algoritmasının sağladığı en iyi çözümün sahip olduğu hatadan daha büyük olabilir.

Hızlı yayılım algoritmasında çözümden fazla uzaklaşmaksızın mümkün olan en büyük adımlarla kısa sürede çözüme ulaşmak arzu edilir (Fausett 1994). Bu algoritmada iki geleneksel yaklaşım birleştirilerek çözülmüştür (Sağıroğlu ve ark. 2003). İlk yaklaşımda, hesaplamanın geçmişteki durumu ile bağlantılı genel veya her bir ağırlık için ayrı sezgilere dayanan dinamik olarak ağırlıkların ayarlanır. Diğer yaklaşımda ise her bir ağırlığa göre hatanın ikinci türevi kullanılır. Bunun yanı sıra bu algoritmada her bir ağırlık için hata eğrisi kolları yukarı doğru açık bir parabole yaklaştırılır. Hata eğrisinin açısal değişimi, diğer tüm ağırlıkların değişiminden etkilenmez (Sağıroğlu ve ark. 2003). Bahsedilen bu parabol, birbirinden bağımsız her bir ağırlık için mevcut ve önceki hata eğimleri ve bu eğimlerin ölçüldüğü noktalar arasındaki değişim kullanılarak belirlenir. Bu işlemin ardından algoritma doğrudan bu parabolün minimum noktasına dallanır. Hızlı yayılım algoritması üzerinde yapılan performans testlerine bakıldığında diğer tekniklere oranla, genelde daha iyi olduğu gözlenmektedir (Sağıroğlu ve ark. 1999). Bu algoritma giriş verilerinde mevcut olan gürültülerin fazla olduğu durumlarda çok daha iyi çalışmaktadır.

Bu algoritmada ağırlık hızlandırma ve kırpılması ihmal edilerek t-1 den t'ye kadar ağırlıklardaki değişim eşitlik (3.26) ile ifade edilir (Fausett 1994).

$$\Delta w(t) = \varepsilon L(t) + \alpha Q(t) \qquad (3.26)$$

Burada ε, öğrenme katsayısıdır.

eğer $h(t)h(t\text{-}1)\geq 0$
diğer durumlarda

$$L(t) = \begin{cases} h(t) \\ 0 \end{cases} \tag{3.27}$$

ve

$$Q(t) = \begin{cases} \mu \Delta w(t-1) & \text{eğer } h(t)\left(h(t) - \left(\frac{\mu}{\mu+1} \right) h(t-1) \right) \geq 0 \\ \Delta q(t) & \text{diğer durumlarda} \end{cases} \tag{3.28}$$

eşitlikleri ile verilir. Bu eşitliklerde μ, momentum büyüme faktörünü; $h(t) = \frac{\partial E}{\partial w(t)}$, eğimi ve $\Delta q(t) = \frac{\Delta w(t) h(t)}{h(t-1) h(t)}$ ise minimum adım miktarını göstermektedir (Haykin 1999). Buradan ağırlık fonksiyonunu güncelleştirmek için, delta ağırlık fonksiyonu ve ağırlık hızlandırma katsayısı işleme dahil edilirse;

$$w(t) = (1-\delta) w(t-1) + \Delta w(t) \tag{3.29}$$

eşitliği elde edilir. Burada δ, hızlandırma katsayısıdır. Son olarak ağırlık çok küçük ise, 0 alınarak kırpılır (Haykin 1999). Yani, I$w(t)$I <κ ise $w(t)$=0 alınır. Burada, κ ağırlık kırpma faktörüdür.

3.2.4. Bulanık Mantık

1965 yılında Lotfi A. Zadeh yayınlanan bir makalesinde doğru ve yanlış arasındaki sonsuz farklı değerleri [0,1] aralığındaki sayılarla ifade etmiş, ilk kez bu makalesinde sembolik ifadelerin makinelere aktarılmasının matematiksel bir temele dayandığından bahsetmiştir. Zadeh bu çalışmasında insan düşüncesinin büyük çoğunluğunun bulanık olduğunu, kesin olmadığını belirtmiştir. Bu yüzden 0 ve 1 ile

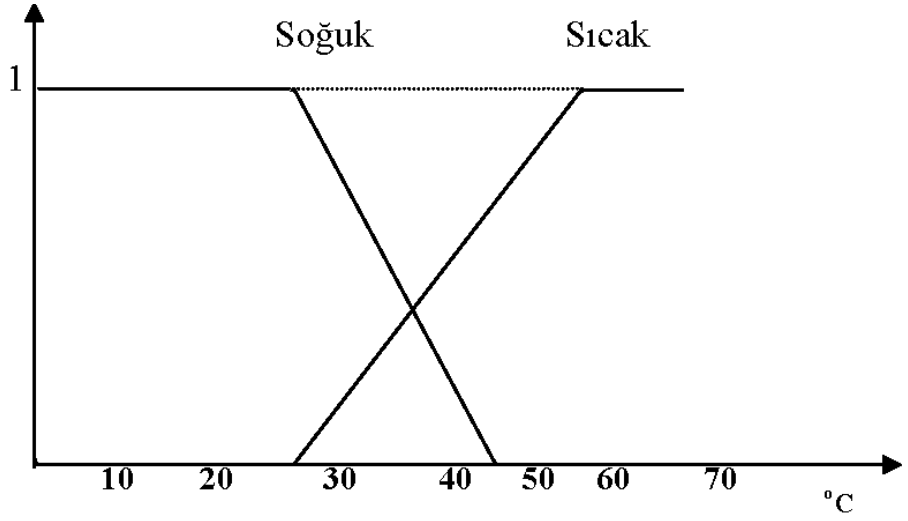
temsil edilen klasik mantık bu düşünce işlemini yeterli bir şekilde ifade edememektedir. Zadeh daha sonra [0,1] aralığındaki sayılarla ifade ettiği teorisini "Bulanık Mantık" adlı çalışmasında tanımlamıştır. Zadeh'in çalışmalarının ardından uygulamalar artarak devam etmiş; gelişmiş bilgisayarların kullanımı ile uygulama alanları genişlemiştir.

Bulanık mantık, bir şey hakkında yargı ortaya atarken, aynı anda, bu yargıyı oluştururken dayandığı matematiksel sınıflandırmaların ne kadar içinde, ne kadar dışında olduğundan bahseder. Verinin ne kadar o yargı kümesine ait, ne kadar ait olmadığı bilgisine dayanarak o veriye yeni bir tanım getirir.

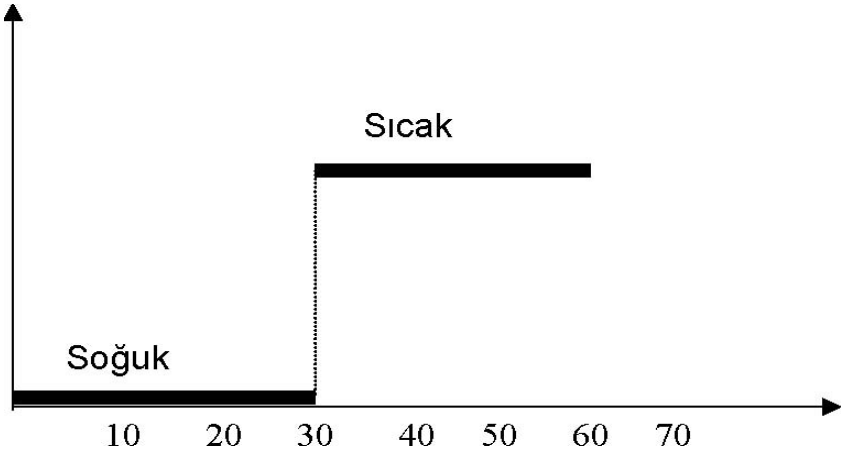
Bulanık mantık, klasik mantığın aksine iki seviyeli değil, çok seviyeli işlemleri kullanmaktadır. Bulanık mantık yaklaşımı, makinelere insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsezilerinden yararlanarak çalışabilme yeteneği verir. Klasik matematiksel yöntemlerle karmaşık sistemleri modellemek ve kontrol etmek zordur, çünkü veriler tam olmalıdır. Bulanık mantık kişiyi bu zorunluluktan kurtarır ve daha niteliksel bir tanımlama olanağı sağlar. Bir kişi için 37,5 yaşında demektense sadece orta yaşlı demek birçok uygulama için yeterli bir veridir. Böylece azımsanamayacak ölçüde bir bilgi indirgenmesi söz konusu olacak ve matematiksel bir tanımlama yerine daha kolay anlaşılabilen niteliksel bir tanımlama yapılabilecektir.

Modern teknolojinin kullandığı kodlama biçimi olan 0 ve 1 mantığına karşın bulanık mantık, 0 ile 1 arasındaki değerlerin varlığından bahseder. Klasik mantık 30 C^0' yi "sıcak" kümesinin sınırı olarak kabul ediyorsa, 29,9 C^0 'yi sıcak olarak kabul etme hakkını kaybeder. Aradaki bu küçük fiziksel fark, klasik mantık için hayati anlam ifade etmektedir. Çünkü bu değerin üyelik kümesi değişmiştir artık. 30 C^0, 29,9 C^0 olmakla, "sıcak" olmayı reddetmiş ve bunun sonunda "sıcak" olma kümesinden dışlanmıştır. Fiziksel dünyada 30 C^0yi sıcak kabul edilirken, 29,9 C^0 'nin sıcak olmadığı iddia edilmez. Oysaki bulanık mantık bu tür keskin sınırları kaldırarak, 29,9 C^0 'yi neredeyse (1'e yakın bir değerle) sıcak olarak kabul eder. Klasik mantık için "soğuk" ya da "sıcak" olma vardır. Oysaki Bulanık Mantık "soğuk-sıcak" gibi kavramların yanında, "az soğuk", "çok sıcak", biraz sıcak" gibi

söylemleri de kabullenir ve bunları matematiksel olarak tanımlamaya çalışır (Allahverdi 2002).



Şekil 3.12. Bulanık Mantık modeli



Şekil 3.13. Klasik Mantık Modeli

Dilsel değişken "sıcak" veya "soğuk" gibi kelimeler ve ifadelerle tanımlanabilen değişkenlerdir. Bir dilsel değişkenin değerleri bulanık kümeleri ile ifade edilir. Örneğin oda sıcaklığı dilsel değişken için "sıcak" ve "soğuk" ifadelerini alabilir. Bu iki ifadenin her biri ayrı bulanık kümeler ile modellenir. Bununla ilgili bir örnek Şekil 3.9 ve Şekil 3.10'da görülmektedir.

Bulanık mantık ve bulanık yaklaşımı daha iyi açıklamak için ilerleyen kısımda kesin ve bulanık yaklaşımla ele alınan iki kümeleme yaklaşımına yer verilmiştir.

3.2.4.1. *K*-ortalamalar

K-ortalamalar (MacQueen, 1967) kümeleme problemi çözümü için ortaya atılan en basit danışmansız eğitim algoritmalarından birisidir. Yöntem veriyi önceden belirlenmiş bir sayıda (*k* adet) kümeye sınıflandırmak için basit ve kolay bir yol takip eder. Ana fikir, her biri bir kümeyi ifade eden *k* tane merkez belirlemekten ibarettir. Farklı yerleşimler farklı sonuçlar ortaya çıkaracağından bu merkezler akılcı bir yolla yerleştirilmeleri gerekmektedir. Bu yüzden en iyi çözüm ise bu merkezlerin mümkün olduğunca birbirlerinden uzağa yerleştirilmesidir. Bir sonraki adım ise her veri noktasının en yakın olduğu merkezle ilişkilendirilmesi olacaktır. İlişkilendirilmemiş veri noktası kalmadığında ilk adım tamamlanmış ve bir gruplama yapılmıştır. Bu noktada ise bir önceki adımda yapılan kümelemeye bağlı olarak küme merkezlerinin yeniden belirlenmesi gerekmektedir. Böylece *k* tane yeni küme merkezi oluşacaktır. Tekrar her bir veri noktası bu yeni merkezlere göre en yakın olan ile ilişkilendirilecektir. Böylece bir döngü oluştuğu görülebilir. Bu döngü esnasında *k* tane merkez adım adım yer değiştirecektir. Bu yer değiştirme durduğu adımda ise döngü sonlandırır.

Sonuç olarak bu algoritma bir karesel hata fonksiyonu şeklindeki amaç fonksiyonunu (*objective function*) minimumlaştırır. Bu amaç fonksiyonu aşağıda görülmektedir.

$$J = \sum_{j=1}^{k} \sum_{i=1}^{n} \left\| x_i^{(j)} - c_j \right\|^2 \qquad (3.30)$$

Burada $\left\| x_i^{(j)} - c_j \right\|^2$ ifadesi $x_i^{(j)}$ veri noktası ile c_j küme merkezi arasındaki seçilmiş bir mesafe ölçümüdür. Bu ölçüm her bir veri noktası ile ilişkili olduğu merkez arasında yapılır.

Algoritma aşağıdaki adımlardan oluşmaktadır.

1. Kümelenecek nesnelerden oluşan uzaya *k* tane nokta yerleştirilir. Bu noktalar kümeleri ifade eder.
2. Her bir nesne en yakındaki merkeze atanır.
3. Bütün nesneler atandıktan sonra *k* tane merkezin yeri yeniden belirlenir.
4. 2. ve 3. adımlar *k* tane merkezin yeri değişmeyene kadar tekrar edilir.

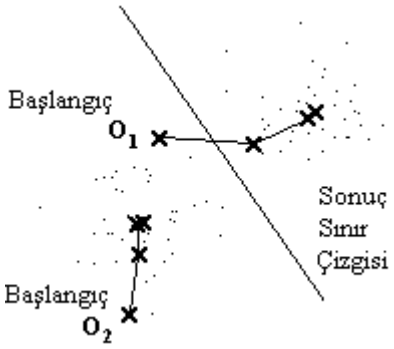
Prosedürün her zaman sonlanmasına karşı bu algoritma genel amaç fonksiyonuna karşılık gelen en iyi çözümü bulmada yeterli değildir. Algoritma, küme merkezlerinin rasgele olan başlangıç değerlerine duyarlıdır. Bu etkiyi azaltmak için defalarca çalıştırılması gerekebilir.

K-ortalamalar birçok probleme adapte edilebilir.

Bir Örnek:

x_1, x_2, ..., x_n *n* tane örnek özellik vektörü olsun ve $k<n$ olmak üzere *k* tane kümeye ayrılsın. O_i ise *i* kümesinin merkezi olsun. Kümeler iyi bir şekilde ayrılırsa, minimum mesafe sınıflandırması uygulanabilir. Yani yeni bir noktanın tüm merkezlere olan mesafeleri karşılaştırılarak minimum olan kümeye ait olduğu söylenebilir. Bir *x* özellik vektörü için $\left\| x - O_i \right\|$ değeri *k* mesafe içinde minimum ise *x* vektörü *i* kümesindedir.

Aşağıdaki şekilde örnek olarak iki küme için küme merkezi O_1 ve O_2 nin hareketi gösterilmiştir.



Şekil 3.14. Örnek *k*-ortalamalar kümelemesi (*k*=2)

3.2.4.2. Bulanık *c*-ortalamalar

Bulanık c-ortalamalar, verinin bir kısmının birden fazla kümeye ait olmasına izin veren bir kümeleme yöntemidir. Bu yöntem 1973'te Dunn tarafından ortaya konmuş ve 1981'de Bezdek tarafından geliştirilmiştir ve desen tanımada (pattern recognition) sıkça kullanılmaktadır. Bu yöntem aşağıdaki amaç fonksiyonunun minimumlaştırılmasına dayalıdır (Bezdek, 1981).

$$J = \sum_{i=1}^{N}\sum_{j=1}^{C} u_{ij} \left\| x_i - c_j \right\|^2 \qquad , 1 \le m \le \infty \qquad (3.31)$$

Burada m 1'den büyük herhangi bir reel sayıdır. x_i i numaralı ve d boyutlu veridir, c_j yine d boyutlu küme merkezidir, u_{ij} ise x_i verisinin j kümesine üyelik derecesidir. ||*|| herhangi bir veri ile küme merkezi arasındaki benzerliğin bir ölçümüdür. u_{ij} üyeliklerinin ve c_j küme merkezlerinin aşağıdaki gibi güncellenmesi yoluyla yukarıdaki amaç fonksiyonu tekrarlı bir şekilde en iyi şekle getirilir ve bu sayede bulanık bölümleme sağlanmış olur.

$$u_{ij} = \frac{1}{\sum_{k=1}^{C} \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \tag{3.32}$$

$$c_j = \frac{\sum_{i=1}^{N} u_{ij}^m \cdot x_i}{\sum_{i=1}^{N} u_{ij}^m} \tag{3.33}$$

Ayrıca aşağıdaki şart sağlandığında döngü duracaktır:

$$\max_{ij} \left\{ \left| u_{ij}^{(k+1)} - u_{ij}^{(k)} \right| \right\} < \varepsilon \tag{3.34}$$

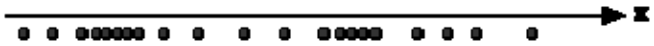
Burada k tekrar sayısı ve ε 0 ile 1 arasında değer alan bir sonlandırma ölçütüdür. Bu sayede J_m yerel bir minimuma yakınsar.

Yöntem aşağıdaki adımlardan oluşmaktadır.

1. $U=[u_{ij}]$ matrisinin başlangıç değerlerini atanır, $U^{(0)}$
2. k numaralı adımda: $U^{(k)}$ ile $C^{(k)}=[c_j]$ küme merkezleri formül 3.33'e göre hesaplanır.
3. $U^{(k)}$, $U^{(k+1)}$ olarak Formül 3.32'ye göre güncellenir.
4. Eğer || $U^{(k+1)}$ - $U^{(k)}$||< ε ise durur, değil ise 2. adıma döner.

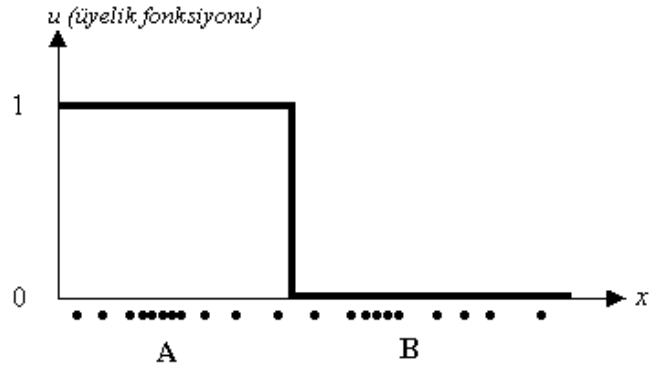
Veriler yöntemin bulanık yaklaşımını ortaya koyan üyelik fonksiyonunun ortalaması vasıtasıyla küme merkezleri belirlenir. Bunun için 0 ile 1 arasında değer alan ve her bir verilerin her bir küme merkezine olan üyelik derecesini belirleyen bir U üyelik fonksiyonu bulunmaktadır.

Tek boyutlu bir veri üzerinde konuyu açıklanacak olursa aşağıdaki gibi bir veri seti olsun.



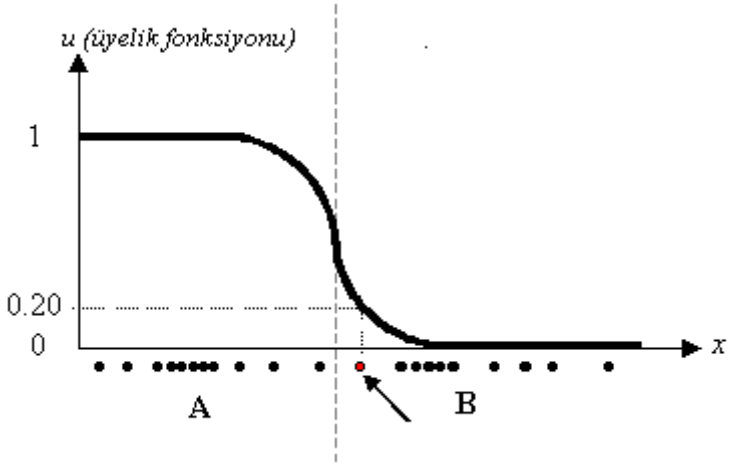
Şekil 3.15. Tek boyutlu örnek bir veri seti

Şekil 3.12'ye bakıldığında verinin iki merkezde yoğunlaştığı görülebilir. Bunlar 'A' ve 'B' kümeleri olarak adlandırılsın. İlk yaklaşımda (*k*-ortalamalar) her bir veri sadece bir küme merkezi ile ilişkilendirilecek üyelik fonksiyonu aşağıdaki gibi olacaktır:



Şekil 3.16. Kesin üyelik eğrisi

Bulanık *c*-ortalamalar yönteminde ise her bir nokta sadece bir kümeye ait değildir. Bazı noktalar belirli bir üyelik değeri ile birkaç kümeye ait olabilmektedir.



Şekil 3.17. Bulanık üyelik eğrisi

Şekil 3.14'de A kümesinden çok B kümesine ait olan bir veri noktası ok ile işaret edilmiştir. Bu noktanın A kümesine aitlik derecesinin 0.2 olduğu görülmektedir. Grafik gösterim yerine matris şeklinde gösterilecek olursa *U* üyelik fonksiyonu matrisleri aşağıdaki gibi olacaktır.

$$U_{kkc} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 0 \\ .. & .. \\ 0 & 1 \end{bmatrix} \qquad U_{bkc} = \begin{bmatrix} 0.8 & 0.2 \\ 0.3 & 0.7 \\ 0.6 & 0.4 \\ .. & .. \\ 0.9 & 0.1 \end{bmatrix}$$

(a) (b)

Şekil 3.18. Kesin ve bulanık üyelik matrisleri

Şekil 3.15'de ise *k*-ortalamalar (a) ve bulanık *c*-ortalamalar (b) durumları için üyelik matrisi görülmektedir. Matristeki satır ve sütun sayısı kaç veri noktası ve kaç küme olduğuna bağlıdır. Yukarıdaki şekilde küme sayısının C=2 ve veri noktası sayısının N olduğu görülmektedir. Matrisin elemanlarının genelleştirilmiş şekli ise $u_{i,j}$ şeklinde olacaktır.

Bu matrisin bazı özelliklerine ise aşağıda yer verilmiştir.

- $u_{ij} \in [0,1] \quad \forall i, j$
- $\sum_{j=1}^{c} u_{ij} = 1 \quad \forall i$
- $0 < \sum_{i=1}^{N} u_{ij} < N \quad \forall N$

4. DİZEL MOTOR PERFORMANSI VE EMİSYON KARAKTERİSTİĞİNİN ÇOKLU-REGRESYON ANALİZİ İLE BELİRLENMESİ

Dizel ve benzinli motor performans ve emisyon modellemesi için kullanılan matematiksel yöntemler genellikle istenilen doğrulukta modellemeye imkan kılmamıştır. Kullanılan teknikler termodinamik ya da dizilere dayalı olmuştur. (Yücesu (1999), Sekmen ve ark. (2004), Öğüçlü (1998), Iserman ve ark (2001)). Matematiksel modellemenin dezavantajı teorik olarak düşünülen yanma denklemlerinin gerçek ortamda çevresel şartlardan etkilenmesidir (Çelik ve ark. 2005). Bunların dışında çoklu giriş ve çıkış parametrelerine sahip olan dizel motor performansı ve emisyonunun modellenmesi ancak sayısal analiz yöntemlerinden farklı eğri uydurma metotları kullanılarak gerçekleştirilebilir. Lagrange, Taylor serisi vb eğri uydurma yöntemleri ise tek giriş tek çıkış modeline dayandığı için tez çalışmasının amacı olan modelleme için kullanılamaz. Sayısal analiz yöntemlerinden sadece çoklu giriş ve tekli çıkış modelini de içeren regresyon analizi dizel motorun performans ve emisyonunu modellemek için uygundur. Bu çalışmada daha önce performans ve emisyon modellenmesinde hiç denenmemiş olan çoklu-regresyon tekniği kullanılmıştır. Amaç sayısal analiz metoduyla performans ve emisyon modellemede yüksek doğruluk oranına sahip ya da en az daha önceki çalışmalarda farklı metotlarla elde edilen doğruluk oranı ve ya üzerinde orana sahip modellemenin gerçekleşip gerçekleşmeyeceğini görmektir.

4.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Uygulama

Hava-akış oranı (Afr), Boost basıncı (Pb), Yakıt oranı (Fr), Devir (Cy) ve Yük (L) giriş parametreleri olarak alınmış ve bunlara bağlı olarak Tork (Tq), Güç (P), Özel yakıt tüketimi (Sfc) ve emisyon değerleri (Hc, CO_2 ve NO_x) çoklu-regresyon tekniği ile modellenmiştir. Minitab14 yazılımı modelleme amaçlı olarak kullanılmıştır. Minitab14'de modelleme yapmak için öncelikle giriş parametreleri Minitab 14 çalışma sayfasına her biri ayrı sütüna gelecek şekilde yerleştirilir.

Sonrasında bu çoklu parametrelere bağlı olarak modellenmesi istenen parametre son sütuna yerleştirilir. Sonrasında Menü'den regresyon seçilerek Minitab14'ün son sütuna yerleştirilen parametrenin kendinden önce gelen sütünlarda bulunan parametrelere bağlı olarak formüle etmesi sağlanır. Sırasıyla tüm çıkış parametreleri için yukarıda bahsi geçen yöntem izlenerek Tablo 4.1.'de gösterilen çıkışların girişlere bağlı olarak çoklu regresyon formulleri elde edilmiştir.

Tablo 4.1. 300PS E1 J1 **ç**ıkış parametrelerinin girişlere bağlı olarak Çoklu-regresyon denklemleri

Çıkışlar Parametresi	**Çoklu Regresyon Denklemi**
CO_2	33,9 - 0,0132 x Cy - 0,0248 x Afr + 3,56 x Fr - 0,300 x L+ 0,0679 x Pb
P	5,46 + 0,000578xCy - 0,00894 x Afr + 0,325 x Fr + 0,0389 x L - 0,00303 x Pb
HC	146 - 0,0116 x Cy + 0,0817 x Afr – 4,61 x Fr 3 - 0,530 x L + 0,0421 x Pb
NOx	1287 - 0,444 x Cy - 0,270 x Afr - 17,3 x Fr + 0,42 x L + 0,827 x Pb
Sfc	126 + 0,0577 x Cy - 0,0003 x Afr + 0,39 x Fr + 0,878 x L - 0,0906 x Pb
Tq	302 + 0,122 xCy - 1,19 x Afr + 15,4 x Fr + 1,93 x L + 0,692 x Pb

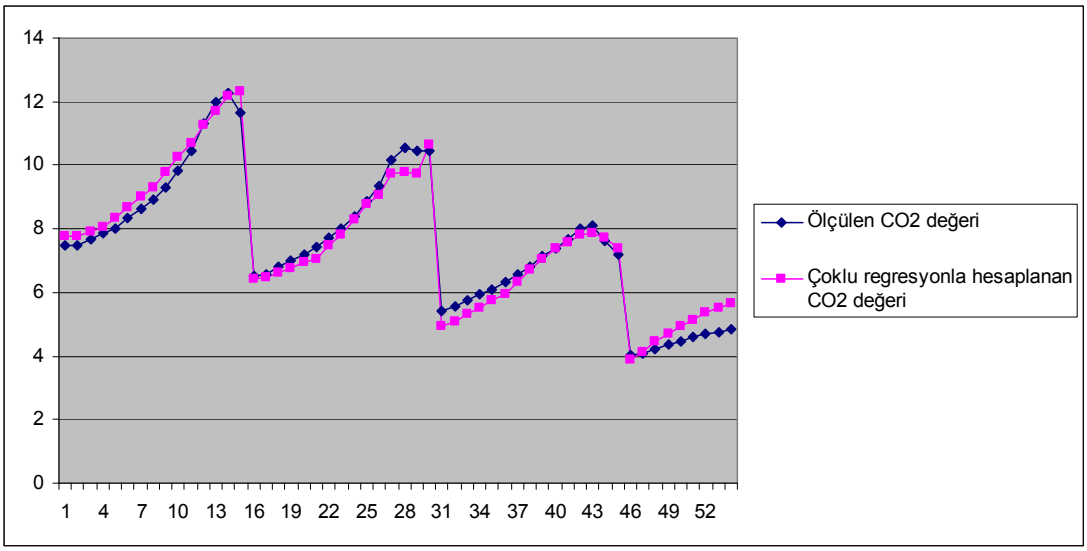
Sonrasında sırasıyla tüm çıkış parametreleri için Microsoft Excel'de Tablo 4.1'deki formüller kullanılarak her bir çıkış parametresi için çıkış değerleri 54 farklı giriş değerlerine karşılık elde edilmiştir. SPSS 13 yazılım paketi kullanılarak ölçülen çıkış parametreleri ile çoklu regresyon analizi sonucu elde edilen çıkış parametreleri bağımsız T-testine tabi tutulmuşlardır. Bu testlerin sonucu Tablo 4.2'de gösterilmiştir.

Tablo 4.2'dende anlaşılacağı üzere R-kare (karesel hata) değeri CO_2, güç (P) veTork (T) değerleri için sırasıyla %97, %99,92 ve %99,3 oranında deneyde elde edilen ölçüm sonuçlarına yakın değerler elde edilmiştir. Diğer tüm çıkış parametrelerinin R-kare değer sonuçları kabul edilebilir sınırların altındadır.

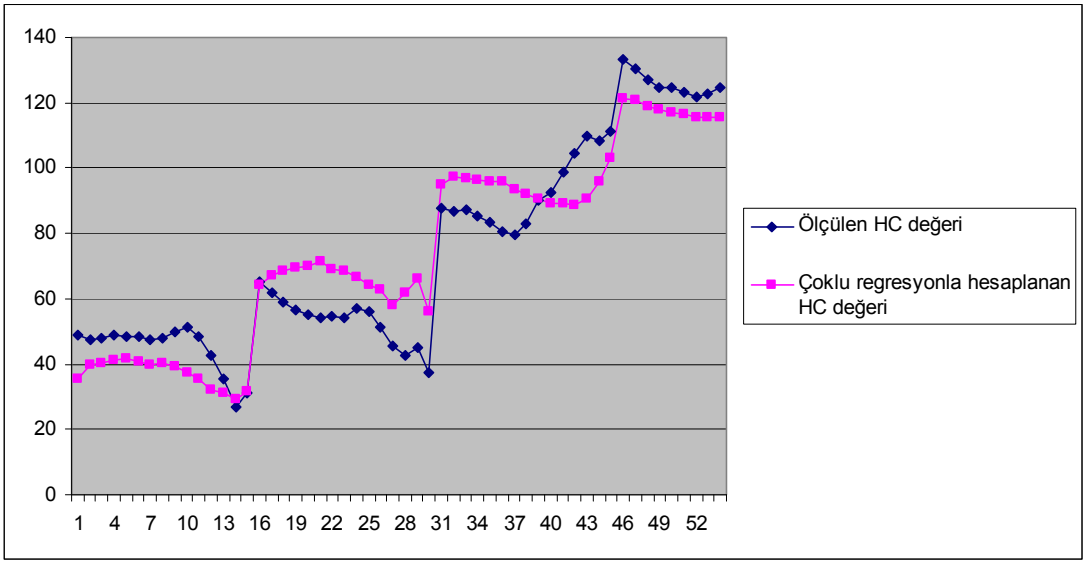
Tablo 4.2. 300PS E1 J1 çıkış parametrelerinin çoklu-regresyonla modellenmesi test hatası

Değişken ismi	**Ölçülen standart sapma**	**Hesaplanan standart sapma**	**R-kare**	**T-testi**
CO_2	2,14	2,10	97	98,5
HC	31,34	29,28	87,32	94,7
NO_x	215,73	199,9	85,84	94,7
P	54,62	54,62	99,92	99,75
Tq	269,76	268,98	99,73	95,4
Sfc	16,74	15,34	84,07	96,3

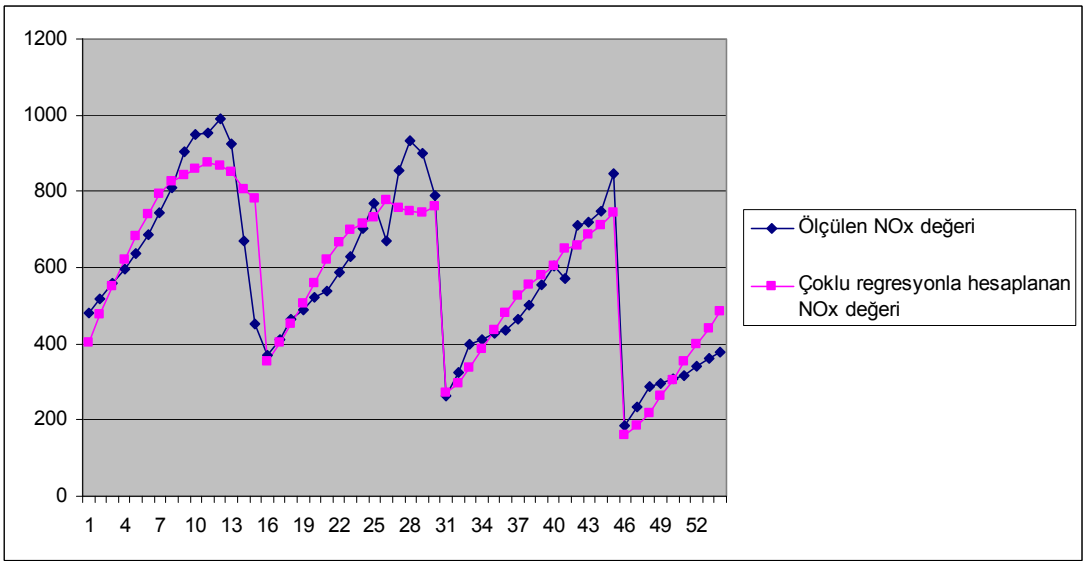
Şekil 4.1 ile Şekil 4.6 arasında ölçülen ve çoklu regresyonla hesaplanan çıkış parametre değerleri grafiksel olarak gösterilmiştir.



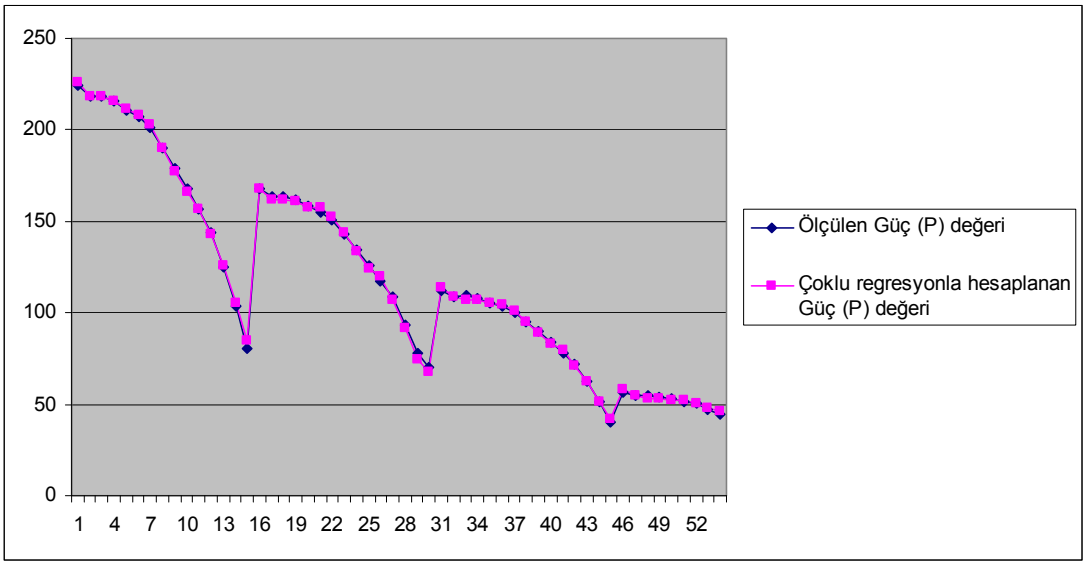
Şekil 4.1. 300PS E1 J1 deneysel (ölçülen) CO_2 ve çoklu-regresyonla hesaplanan CO_2



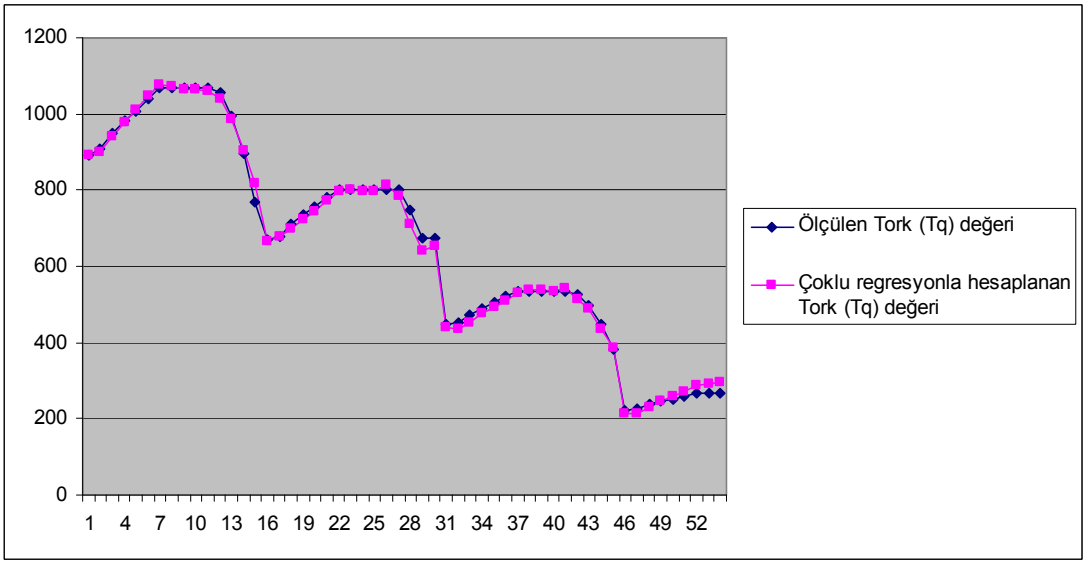
Şekil 4.2. 300PS E1 J1 deneysel (ölçülen) HC ve çoklu-regresyonla hesaplanan HC



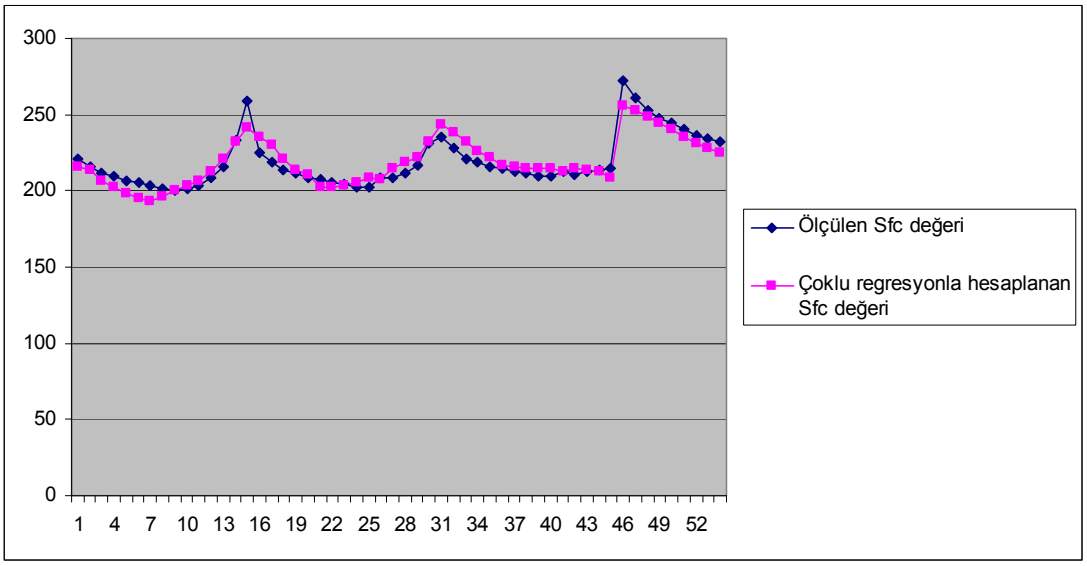
Şekil 4.3. 300PS E1 J1 deneysel (ölçülen) NO_x ve çoklu-regresyonla hesaplanan NO_x



Şekil 4.4. 300PS E1 J1 deneysel (ölçülen) Güç (P) ve çoklu-regresyonla hesaplanan P



Şekil 4.5. 300PS E1 J1 deneysel (ölçülen) Tork (Tq) ve çoklu-regresyonla hesaplanan Tq



Şekil 4.6. 300PS E1 J1 deneysel (ölçülen) Sfc ve çoklu-regresyonla hesaplanan Sfc

Grafiklerden de görüleceği üzere çoklu regresyonla hesaplanan x çıkış parametre değerleri CO_2, güç (P) ve Tork (T) için deneyde ölçülen değerlerlerle örtüşmekte ve bu değerleri temsil edebilmektedir. Diğer grafiklerde ölçülen ve hesaplanan değerler arasındaki sapma rahatlıkla görülmektedir.

Dolayısıyla matematiksel ve daha özelde istatistiksel bir tekniği olan Çoklu-regresyon yönteminin doğrusal olmayan dizel motor performans ve emisyon karakteristiğini modellemede yetersiz kaldığı görülmüştür.

4.2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Uygulama

Devir (D) ve Avans (Av) giriş parametreleri olarak alınmış ve bunlara bağlı olarak Tork (Tq), Güç (P), Özgül yakıt tüketimi (Sfc) ve Hc çoklu-regresyon tekniği ile modellenmiştir. Modelleme için izlenilen metot 4.1'deki ile aynıdır. Sırasıyla tüm çıkış parametreleri için Tablo 4.3.'de gösterilen çıkışların girişlere bağlı olarak çoklu regresyon formulleri elde edilmiştir.

Tablo 4.3. Briggs ve Stratton Vanguard çıkış parametrelerinin girişlere bağlı olarak Çoklu-regresyon denklemleri

Çıkış Parametresi	**Çoklu Regresyon Denklemi**
HC	207 - 0,0371 x D - 0,218 x Av
P	0,195 + 0,000977 x D - 0,00452 x Av
Tq	9,86 + 0,000027 x D - 0,0044 x Av
Sfc	589 - 0,0632 x D + 0,784 x Av

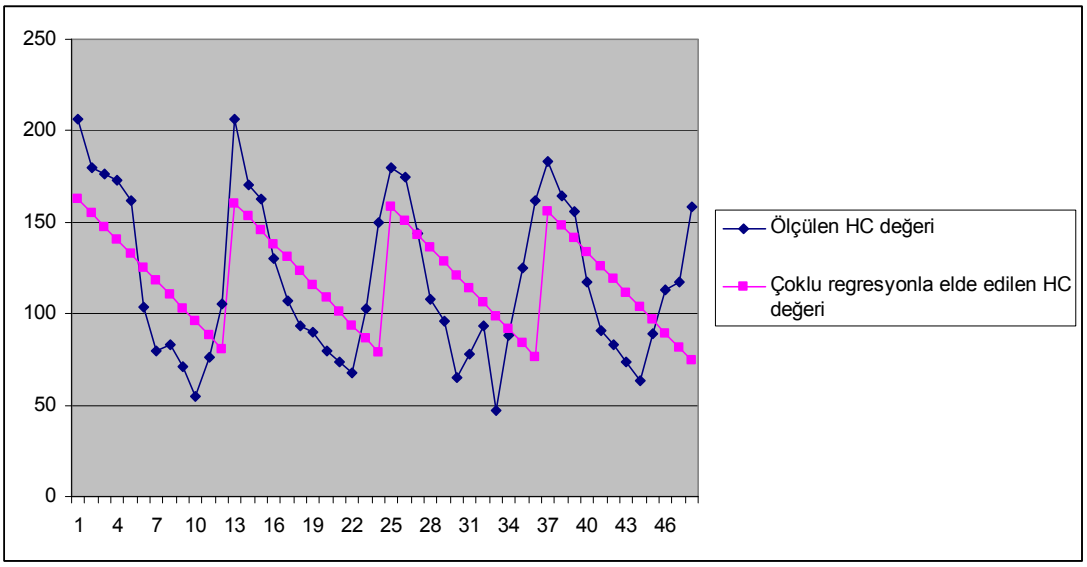
Sonrasında sırasıyla tüm çıkış parametreleri için Microsoft Excel'de Tablo 4.1'deki formüller kullanılarak her bir çıkış parametresi için çıkış değerleri 54 farklı giriş değerlerine karşılık elde edilmiştir. SPSS 13 yazılım paketi kullanılarak ölçülen çıkış parametreleri ile çoklu regresyon analizi sonucu elde edilen çıkış parametreleri bağımsız T-testine tabi tutulmuşlardır. Bu testlerin sonucu Tablo 4.2'de gösterilmiştir.

Tablo 4.4. Briggs ve Stratton Vanguard çıkış parametrelerinin çoklu-regresyonla modellenmesi test hatası

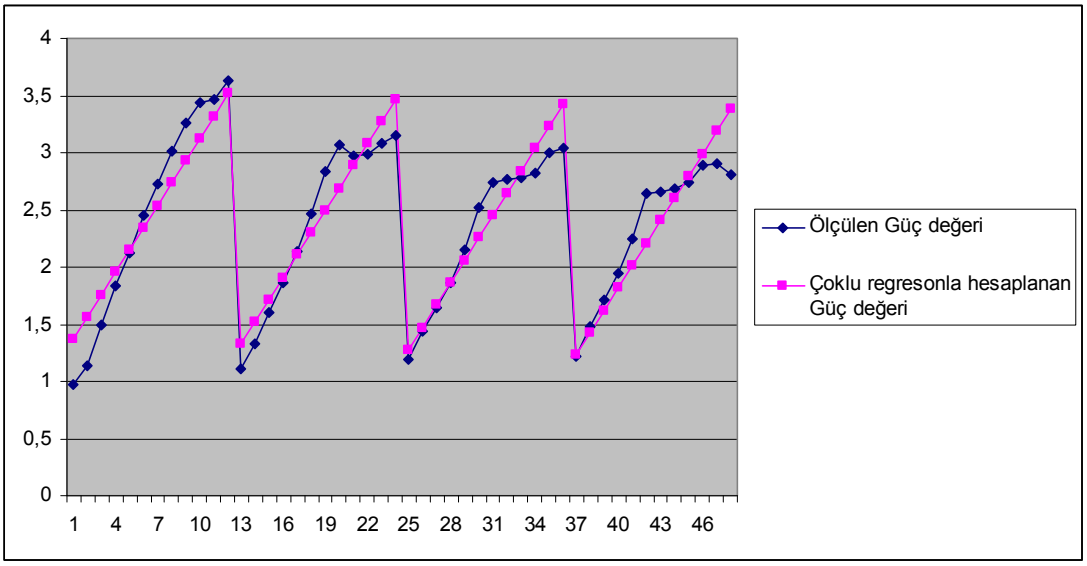
Değişken ismi	**Ölçülen standart sapma**	**Hesaplanan standart sapma**	**R-kare**	**T-testi**
HC	43,91	26	35	97,9
P	0,72	0,68	89,6	99,6
Tq	0,93	0,053	0,3	99,2
Sfc	66,91	44,97	45,42	99,5

Tablo 4.2'dende anlaşılacağı R-kare (karesel hata) değeri sadece güç (P) için yüksek değerde olup diğer tüm çıkışlar için düşüktür. Şekil 4.7 ile Şekil 4.10 arasında ölçülen ve çoklu regresyonla hesaplanan çıkış parametre değerleri grafiksel olarak gösterilmiştir. Bu grafiklerden de çoklu regresyon sonucu elde edilen çıkış parametrelerinin motor deneyi sonucu ölçülen çıkış parametre değerlerini temsil edemiyeceği gözükmektedir. Kısacası ölçülen ve hesaplanan değerler arasındaki sapma ve hata oranının yüksek olmasından ötürü benzinli motor içinde çoklu regresyon analizinin modelleme konusunda yetersiz kaldığı görülmektedir.

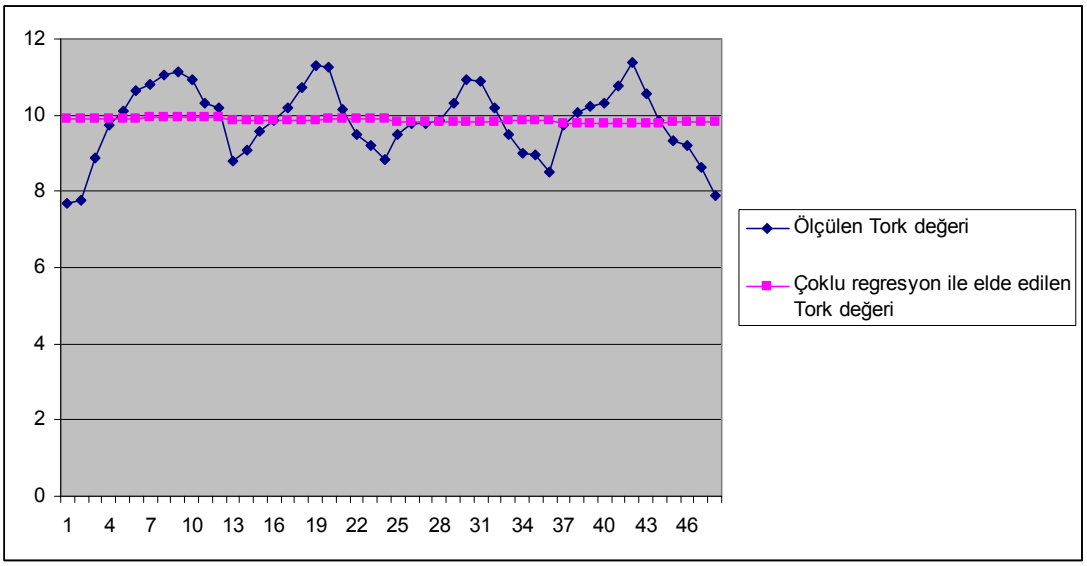
Şekil 4.7'den Şekil 4.10'a kadar görüleceği üzere matematiksel ve daha özelde istatistiksel bir tekniği olan Çoklu-regresyon yönteminin doğrusal olmayan motor performans ve emisyon karakteristiğini modellemede yetersiz kaldığı görülmüştür. Yalnızca Şekil 4.7'de sunulan ve R-kare değeri %89.6 olan güç (P) için ölçülen ve hesaplanan sonuçlar birbirine yakın çıkmış ve sapma az olmuştur.



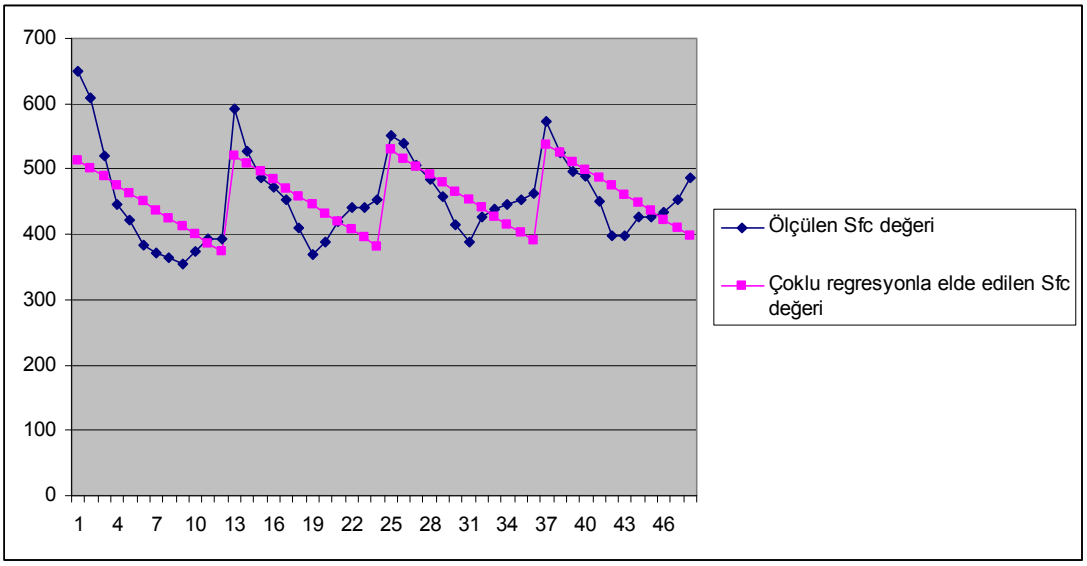
Şekil 4.7. Briggs ve Stratton Vanguard deneysel (ölçülen) HC ve çoklu-regresyonla hesaplanan HC



Şekil 4.8. Briggs ve Stratton Vanguard deneysel (ölçülen) güç (P) ve çoklu-regresyonla hesaplanan P



Şekil 4.9. Briggs ve Stratton Vanguard deneysel (ölçülen) tork (T) ve çoklu-regresyonla hesaplanan T



Şekil 4.10. Briggs ve Stratton Vanguard deneysel (ölçülen) özgül yakıt tüketimi (Sfc) ve çoklu-regresyonla hesaplanan Sfc

SONUÇ: Matematiğin bir alt bilim dalı olan istatistik biliminin çoklu-regresyon analizi kullanılarak gerçekleştirilen modellemede hata oranının hem dizel hem de benzinli motor için yüksek olması bu alanda yapılan çalışmaların YZ tekniklerine yoğunlaşmasını desteklemektedir. Dolayısıyla bu çalışmada ilerleyen bölümlerde YZ teknikleri kullanılarak yapılan modellemeler ve bu modellemelerde elde edilen yüksek doğruluk oranları yer almıştır.

5. DİZEL MOTOR PERFORMANSI VE EMİSYON KARAKTERİSTİĞİNİN YAPAY ZEKA TEKNİKLERİ İLE BELİRLENMESİ

5.1. ANFIS ile modelleme

Tez çalışmasının amaçlarından birisi olan dizel motorun performansını ve emisyon karakteristiğinin belirlenmesi amacıyla 4. bölümde sayısal analiz metodu denenmiş ve istenilen yüksek doğrulukta modelleme elde edilememiştir. Dizel ve benzinli motor performansı ve emisyon karakteristiği doğrusal olmayan bir yapıya sahip olup çoklu giriş ve çoklu çıkış parametrelerine dayanmaktadır. Doğrusal olmayan karakteristiğe sahip problem alanlarında yaygın olarak kullanılan ve iyi sonuçlar veren YZ tekniklerinin tez konusu alanda yoğunlukla kullanılmasının sebebide budur. Bu bölümde ise yine 300PS E1 J1 yüksek torklu dizel motor ve Briggs ve Stratton Vanguard benzinli motor üzerinde YZ tekniklerinden birisi olan ANFIS tekniği uygulanacaktır. Amaç ise her iki motor türününde deneylerden elde edilen veri kümeleri kullanılarak giriş parametrelerine karşılık çıkış parametrelerinin modellenmesi yani değerlerinin ANFIS ile belirlenmesidir. Deneylerde sadece belirli devirler için ölçüm yapılabildiğinden tüm devirlerde motor çıkış parametreleri ölçülememektedir. Yapılabilecek doğru bir modelleme ile tüm ara devir değerler için çıkış parametreleri bulunabilecektir.

5.1.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde ANFIS Uygulaması

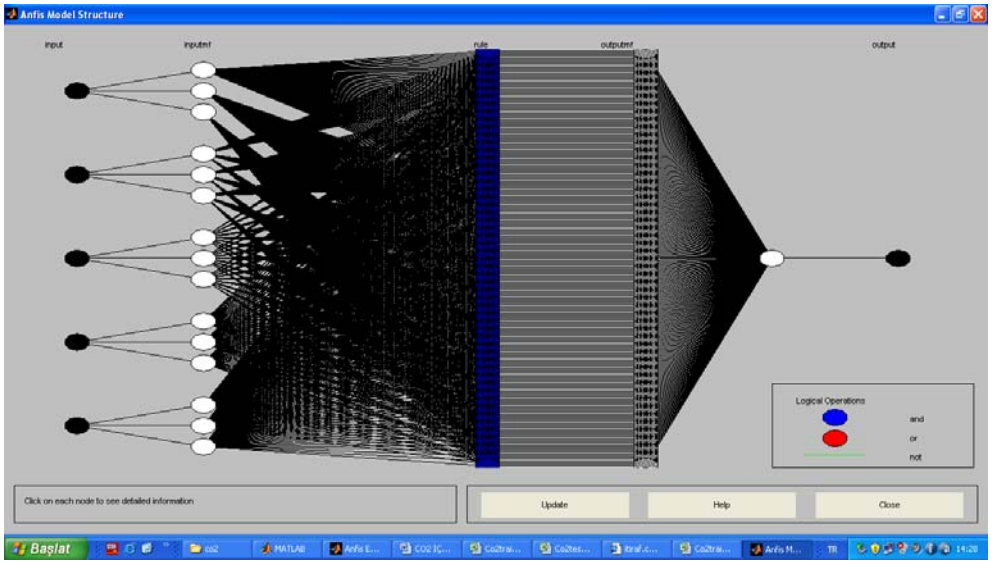
Ek 1'de verilen ve her biri 54 noktadan oluşan 5 giriş parametresi ve 6 çıkış parametresi 9 noktası test ve 45 noktası eğitim amaçlı olarak 6 ayrı eğitim ve test verilerine bölünmüştür. Matlab ANFIS Toolbox kullanılarak, Sugeno FIS yöntemi ile 300 epok ta her bir çıkış parametresi için 6 ayrı eğitim ve test seti olduğu için 6 ayrı eğitim yapılmıştır. Eğitime sonrası ilgili test setleri kullanılarak test hatası

hesaplanmıştır. Toplam 6 çıkış parametresi olduğu için 6*6=36 kez 300 epokluk eğitim çalışması ve sonrasında ilgili test çalışması yapılmıştır. Böylelikle tüm veri setinin eğitim ve testte kullanılması sağlanmıştır. Tablo 5.1'de CO_2 için 6 farklı eğitim ve test kümesi için elde edilen eğitim ve test hatası ile bu setler için ANFIS tarafından belirlenen bulanık küme üye sayısı sunulmuştur.

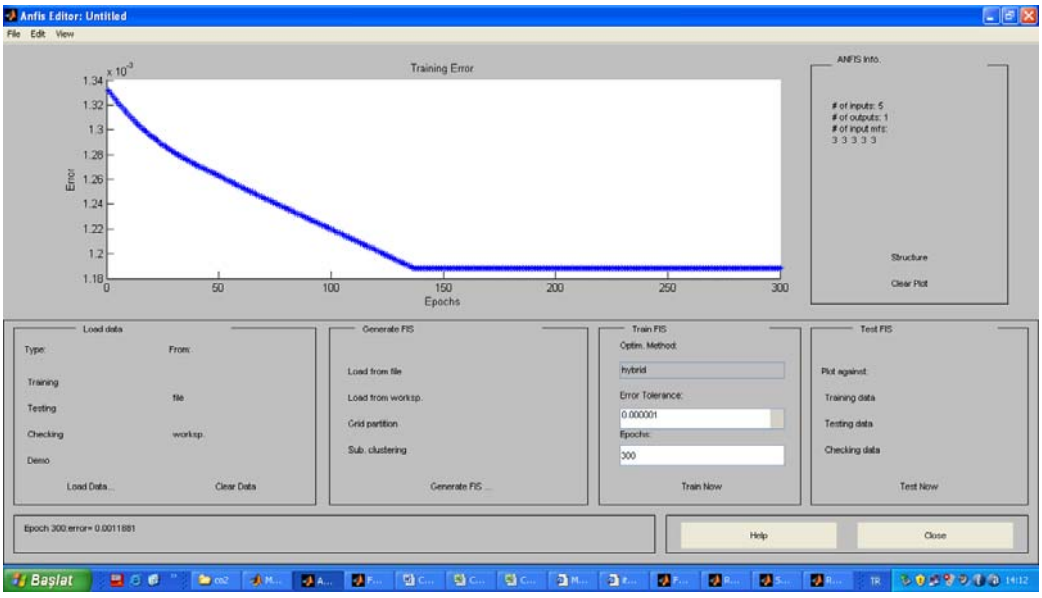
Tablo 5.1. 300PS E1 J1 CO_2 çıkış parametresi için 6 farklı eğitim ve test seti ANFIS hata sonuçları

Eğitim Set numarası	**Eğitim Hatası**	**Test Hatası**	**Üyelik Sayısı**	**Epok**
1	0.0017868	0.66797	11	300
2	0.0027714	0.44143	11	300
3	0.0022891	0.35712	14	300
4	0.0013806	0.50632	13	300
5	0.0023671	2.2684	11	300
6	0.0028536	1.0271	10	300
Toplam Eğitim Hatası	**0,0134486**			
Ortalama Eğitim Hatası	**0.00224143**			
Toplam Test Hatası		**5,26834**		
Ortalama Test Hatası		**0.878056**		

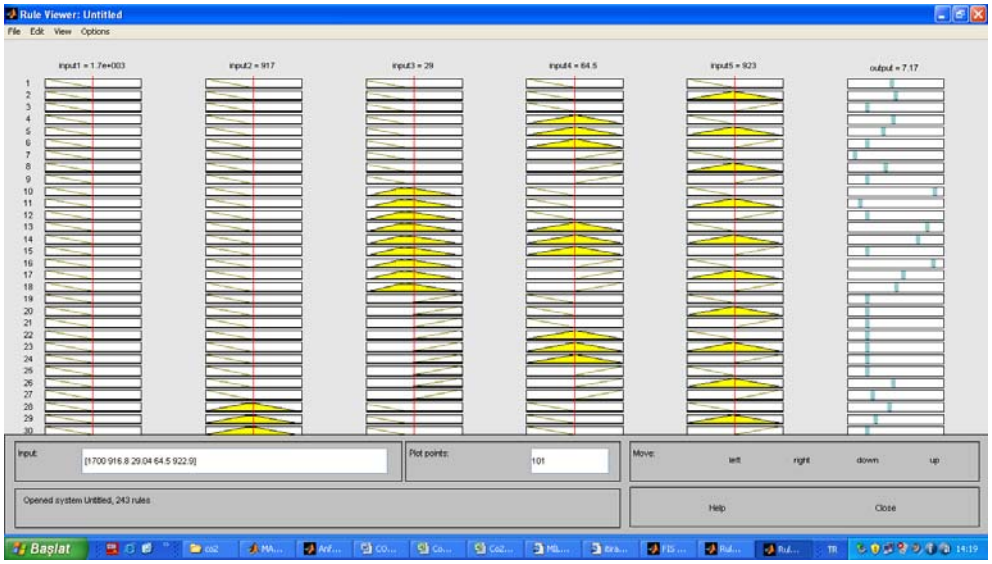
Her bir çıkış parametresi için çaprazlama yöntemi ile (6 ayrı eğitim ve test seti) Matlab ANFIS Toolbox'ta eğitim ve test işlemi yapılmıştır. Şekil 5.1 ve Şekil 5.3 arasında sırasıyla 3 nolu CO_2 eğitim ve test seti için oluşturulan ANFIS mimarisi, eğitimi ve kurallardan bazılarını içeren görüntüler yapılan çalışmanın bir parçası olarak sunulmuştur. ANFIS'de kurallar RBF tabanlı YSA'da olduğu gibi küme merkezlerine noktaların yakınlaşmasını sağlamak üzere oluşturulan üyelik fonksyonlarına göre Toolbox'ta otomatik olarak oluşturulmuştur.



Şekil 5.1. 300PS E1 J1 CO_2 çıkış parametresi için oluşturulan ANFIS mimarisi



Şekil 5.2. 300PS E1 J1 CO_2 çıkış parametresinin tamamlanmış ANFIS eğitiminden bir görüntü



Şekil 5.3. 300PS E1 J1 CO_2 çıkış parametresi için oluşturulan ANFIS'den kurallardan bazıları

Diğer tüm çıkış parametreleri de aynı işleme tabi tutulmuştur. Elde edilen ortalama test ve eğitim hatası Tablo 5.2'de sunulmuştur. Ayrıca her bir çıkış parametresi için 6 ayrı eğitim ve test sonucu elde edilen ANFIS modelleri kullanılarak istatistiksel yöntemlerle (R-kare ve T-testi) çıkışların girişlere olan uygunluğu saptanmıştır. Tablo 5.2'den görüleceği gerek R-kare testi gerekse de T-testi güç hariç (P) diğer çıkış parametrelerde %90'nın altında kalmıştır. Özellikle R-kare değeri iki veri kümesi birbirine çok yakın değerler ifade ediyorsa 100'e yakın bir değerdir. Bu değer 100'den uzaklaştıkça veriler arasında sapmanın çoğaldığı anlamına gelmektedir. Buda 2 farklı metotdan (deneysel ve modelleme) elde edilen veri setleri arasındaki uyumsuzluğu ve dolayısıyla modelleme yapılmış ise modellemenin başarısızlığını gösterir. Tablo 5.2'de ortalama test ve eğitim hatası CO_2 için düşük değerlde çıkmasına rağmen R-kare değerinin %88.6 olması Ek'1 de sunulan 300PS E1 J1 deneysel motor verisinden de görüleceği üzere 54 farklı CO_2 ölçüm değerinin 4,04 ve 12,27 arasında değişmesi olup birbirine çok yakın değerde noktalar bulunmasıdır. Örneğin yarım yükte 2400 devirde ölçülen CO_2 değeri 4.04 iken 2300 devirde ölçülen CO_2 değeri 4.09'dur. Arada 0.05'lik bir fark vardır. Yani noktaların değişim aralığı için ANFIS sonucu bulunan test hatası ise 0,878 olup bu değişim aralığından fazladır. Dolayısıyla R-kare değerinin düşmesine ve ANFIS ile elde edilen CO_2 çıkış

parametre değerlerinin deneysel olarak elde edilen değerlere göre farklı olmasına ve istenilen modellemenin yapılabilmesine imkan sağlamamaktadır. Dolayısıyla ANFIS yönteminin doğrusal olmayan dizel motor performans ve emisyon karakteristiğini modellemede yetersiz kaldığı görülmüştür.

Tablo 5.2. 300PS E1 J1 için tüm çıkış parametrelerinin ANFIS uygulaması eğitim ve test hatası

Değişken adı	Ortalam Eğitim hatası	Ortalama Test Hatası	Ortalama R-kare	Ortalama T-testi
CO_2	$2,2x10^{-3}$	0,878	88,6	89,3
HC	$3,2x10^{-2}$	15,31	85,6	86,2
NOx	$1,5x10^{-2}$	300	70,8	71,5
P	$3,9x10^{-2}$	5,3	93,84	94,03
Tq	$6,3x10^{-2}$	40,3	72,5	73,4
Sfc	$4,2x10^{-1}$	10,23	73,8	74,85

5.1.2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde ANFIS Uygulaması

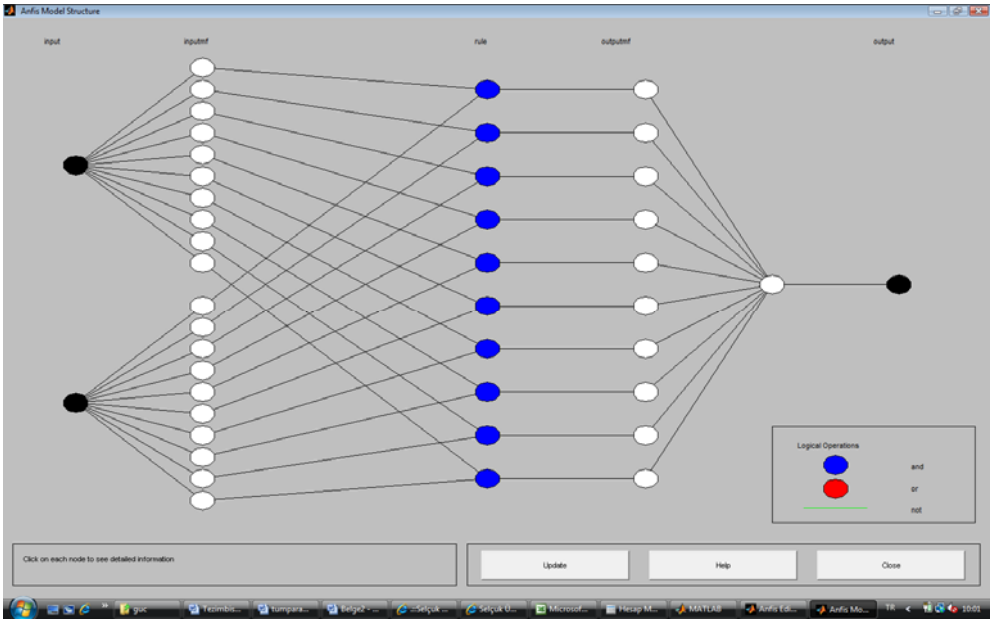
Ek 2'de verilen ve her biri 48 noktadan oluşan 2 giriş parametresi ve 4 çıkış parametresi 12 noktası test ve 36 noktası eğitim amaçlı olarak 4 ayrı eğitim ve test verilerine bölünmüştür. Matlab ANFIS Toolbox kullanılarak, Sugeno FIS yöntemi ile 300 epok ta her bir çıkış parametresi için 4 ayrı eğitim ve test seti olduğu için 4 ayrı eğitim yapılmıştır. Eğitim sonrası ilgili test setleri kullanılarak test hatası hesaplanmıştır. Toplam 4 çıkış parametresi olduğu için 4*4=16 kez 300 epokluk

eğitim çalışması ve sonrasında ilgili test çalışması yapılmıştır. Tablo 5.3'de güç (P) için 4farklı eğitim ve test kümesi için elde edilen eğitim ve test hatası ile bu setler için ANFIS tarafından belirlenen bulanık küme üye sayısı sunulmuştur.

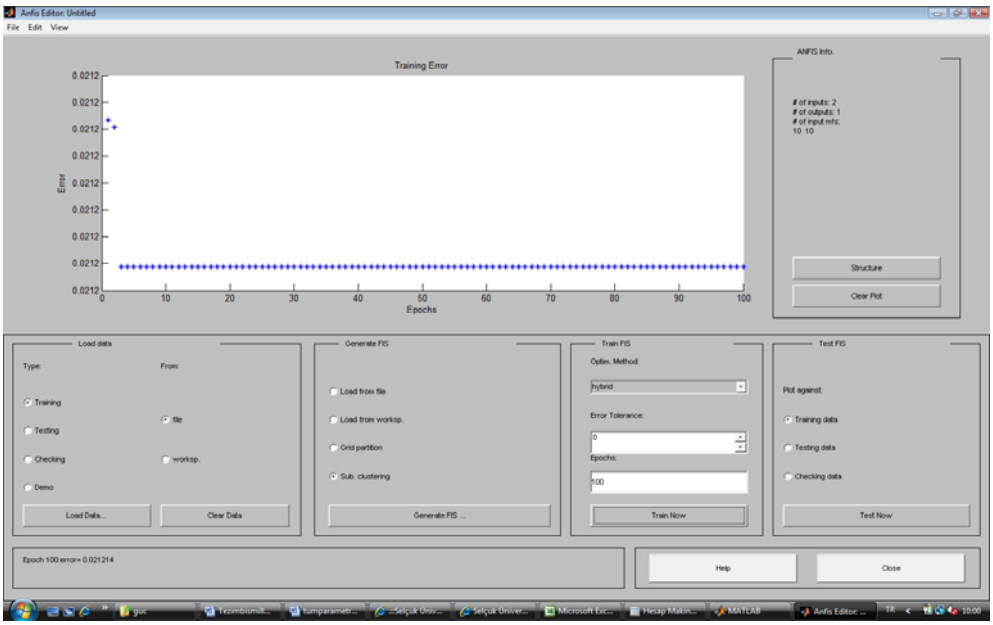
Tablo 5.3. Briggs ve Stratton Vanguard güç (P) çıkış parametresi için 6 farklı eğitim ve test seti ANFIS hata sonuçları

Eğitim Set numarası	**Eğitim Hatası**	**Test Hatası**	**Üyelik Sayısı**	**Epok**
1	0.0021214	0.01053	10	300
2	0.0019469	0.072074	10	300
3	0.0027487	0.062888	9	300
4	0.0014972	0.0052013	10	300
Toplam Eğitim Hatası	**0,0537944**			
Ortalama Eğitim Hatası	**0,02078325**			
Toplam Test Hatası		**0,36536435**		
Ortalama Test Hatası		**0,0730687**		

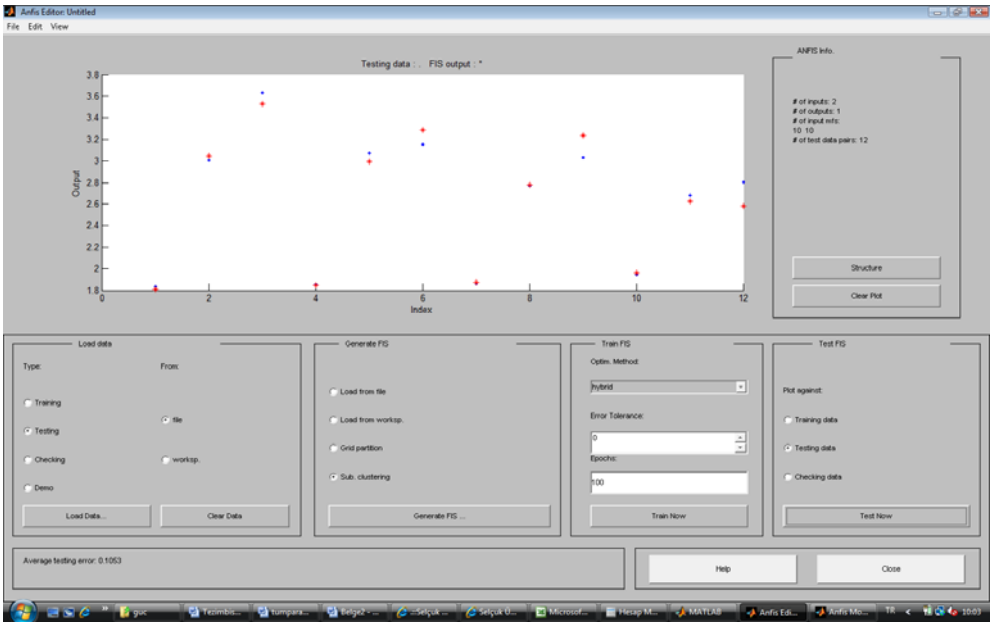
Her bir çıkış parametresi için çaprazlama yöntemi ile (4 ayrı eğitim ve test seti) Matlab ANFIS Toolbox'ta eğitim ve test işlemi yapılmıştır. Şekil 5.4 ve Şekil 5.6 arasında sırasıyla 1 nolu güç (P) eğitim ve test seti için oluşturulan ANFIS mimarisi, eğitimi ve testinden görüntüler yapılan çalışmanın bir parçası olarak sunulmuştur.



Şekil 5.4. Briggs ve Stratton Vanguard güç (P) çıkış parametresi için oluşturulan ANFIS mimarisi



Şekil 5.5. Briggs ve Stratton Vanguard güç (P) çıkış parametresinin tamamlanmış ANFIS eğitiminden bir görüntü



Şekil 5.6. Briggs ve Stratton Vanguard güç (P) çıkış parametresi için oluşturulan ANFIS'tan test aşamasından enstantane

Diğer tüm çıkış parametreleri de aynı işleme tabi tutulmuştur. Elde edilen ortalama test ve eğitim hatası Tablo 5.4'de sunulmuştur. Alt bölüm 5.1.1'de sunulan yöntemler izlenerek tüm çıkış parametreleri için ortalama R-kare ve T-testi değerleri hesaplanmış ve çıkışların girişlere olan uygunluğu saptanmıştır. Tablo 5.4'den görüleceği gerek R-kare testi gerekse de T-testi güç hariç (P) diğer çıkış parametrelerde %90'nın altında kalmıştır. Tablo 5.4'de ortalama test ve eğitim hatası güç (P) için düşük değerlerde çıkmış olup R-kare değerininde %96.6 olması bize ANFIS ile yapılan modellemenin bu çıkış için yüksek doğruluk değerinde sonuç verdiğini göstermektedir. Diğer tüm çıkışlar için elde edilen R-kare değerleri düşüktür. Zaten elde edilen ortalama test hatalarının yüksekliğide buna işaret etmektedir. Tablo 5.4'de tork (Tq) çıkış parametresinde ortalama test hatası iyi düşük olmasına rağmen (0,3476) R-kare değerinin düşük çıkması Ek'2 de sunulan Briggs ve Stratton Vanguard deneysel motor verisinden anlaşılmaktadır. 48 farklı tork (Tq) ölçüm değerinin 7,7 ve 11,4 arasında değişmesi beraberinde birbirine çok yakın değerleri içermesinide getirmektedir. Örneğin avans değeri 20 iken 2200 devirde ölçülen tork (Tq) değeri 10,95 iken 2400 devirde ölçülen tork (Tq) değeri 10,9'dur.

Arada 0.05'lik bir fark vardır. Yani noktaların değişim aralığı için ANFIS sonucu bulunan test hatası ise 0,3476 olup bu değişim aralığından fazladır. Dolayısıyla R-kare değerinin düşmesine ve ANFIS ile elde edilen tork (Tq) çıkış parametre değerlerinin deneysel olarak elde edilen değerlere göre farklı olmasına ve istenilen modellemenin yapılabilmesine imkan sağlamamaktadır.

Tablo 5.4. 300PS E1 J1 için tüm çıkış parametrelerinin ANFIS uygulaması eğitim ve test hatası

Değişken adı	Ortalam Eğitim Hatası	Ortalama Test Hatası	Ortalama R-kare	Ortalama T-testi
HC	5,489475	17,341325	70,6	71,2
P	0,02078325	0,07306875	96,6	97,03
Tq	0,07626175	0,3476	72,5	71,5
Sfc	4,214075	19,850275	73,8	73,85

SONUÇ: ANFIS yönteminin bu çalışmada kullanılan doğrusal olmayan dizel ve benzinli motor veri setleri üzerinde performans ve emisyon karakteristiğini modellemede yetersiz kaldığı görülmüştür.

5.2 YSA ile Modelleme

Bu bölümde YZ tekniklerinden YSA'nın her iki motor veri seti üzerinde verilen her hangi bir devir ve giriş parametre değerinde çıkışların yüksek doğrulukta kestirimi ya da tahmini için kullanılması sunulacaktır. Gerek dizel gerekse benzinli motor verileri için çok giriş-çok çıkışlı ÇKP mimarisi yerine çok giriş ve tek çıkışlı ÇKP mimarisi

kullanılmıştır. Litaeratürde yapılan çalışmaların neredeyse tümü çok giriş ve tek çıkışlı mimarinin kullanılması üzerinedir (Hafner ve ark. (2000), Heister ve Froehlich (2001), Isermann and Hafner (2001), Park ve ark. (2001), Li ve Yurkovich (2000), Sharkey ve ark. (2000), Thompson ve ark. (2001), Sharkey ve ark. (1996), Howlett ve ark. (1996), Arcaklıoğlu ve ark. (2005), Kesgin (2004), Alonso ve ark (2007), Obodeh ve ark (2008)). Her bir çıkış için gerçekleştirilen ayrı YSA mimarisi ile daha iyi yakınsama sağlanmaktadır. Bunun doğruluğunu görebilmek için dizel ve benzinli motor verileri için iki ayrı çok giriş-çok çıkışlı ÇKP mimarisi bu çalışma için tasarlanmıştır. Dizel motor verisi için tasarlanan ÇKP mimarisinde farklı aktivasyon fonksiyonları için elde edilen hata ve doğruluk oranları ise Tablo 5.5 ile Tablo 5.8 arasındaki gibidir. Online-Backpropagation eğitim algoritmasının kullanıldığı 5:12:6 mimarisine ve farklı aktivasyon fonksiyonlarına sahip 4 YSA'nın hiç birisi çok giriş ve tek çıkış ÇKP mimarisine sahip ve her çıkış için ayrı ayrı tasarlanan YSA'ların ortalama eğitim ve test doğruluk oranına (Tablo 5.20) ulaşamamıştır. Tablo 5.5 ile Tablo 5.8 arasında düğüm başlığı altında sunulan 1, 2, 3, 4, 5 ve 6 numaralar sırasıyla CO_2, NO_x, HC, güç (P), yakıt tüketimi (sfc) ve tork (Tq) çıkış düğümlerini temsil etmektedir.

Tablo 5.5. Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Gaussian aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-5:12:6 **Aktivasyon (Gizli katman-Çıkış):** Gaussian **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,12386	-0,00098	0,31605	0,99833
2	31,81333	-0,0695	126,8358	0,98906
3	4,43925	0,02901	14,44099	0,98934
4	1,30975	0,00164	2,65753	0,99968
5	1,54716	-0,0461	5,61176	0,99627
6	10,28468	-0,15135	27,46191	0,99929
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,23477	0,10185	0,64574	0,99486

2	46,66298	-14,1635	102,4227	0,97739
3	5,3591	0,60494	12,85998	0,9865
4	1,74251	-0,44189	2,81345	0,9997
5	2,20035	0,19027	5,0815	0,98438
6	22,94502	6,66192	68,40491	0,99673

Tablo 5.6. Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı HyperSecant aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-5:12:6 **Aktivasyon (Gizli katman-Çıkış):** HyperSecant **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,11275	-0,00089	0,29736	0,99845
2	21,6782	0,13351	69,18719	0,99384
3	3,72565	-0,05305	10,56554	0,99275
4	3,01455	0,00696	6,86446	0,99859
5	1,30992	-0,01623	3,24088	0,99643
6	9,52379	0,08718	21,65411	0,99935
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,23477	0,10185	0,64574	0,99486
2	46,66298	-14,1635	102,4227	0,97739
3	5,3591	0,60494	12,85998	0,9865
4	1,74251	-0,44189	2,81345	0,9997
5	2,20035	0,19027	5,0815	0,98438
6	22,94502	6,66192	68,40491	0,99673

Tablo 5.7. Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Hypertangent aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-5:12:6 **Aktivasyon (Gizli katman-Çıkış):** HyperTangent **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,18298	0,00037	0,54139	0,99608
2	30,09251	-0,03741	135,1938	0,98896
3	4,49024	0,01502	11,53913	0,99034

4	2,78847	-0,06634	7,16849	0,99882
5	2,20405	-0,10811	8,90475	0,99224
6	13,81154	-0,39887	38,48499	0,99874
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,29003	-0,06236	0,65093	0,99293
2	45,91525	-6,09249	84,76862	0,98459
3	8,23197	-0,03518	19,16123	0,95032
4	4,15105	0,40921	10,09349	0,99722
5	2,38324	1,05976	5,38036	0,98813
6	18,31492	-10,9684	26,9527	0,99825

Tablo 5.8. Dizel motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-5:12:6 **Aktivasyon (Gizli katman-Çıkış):** Logsigmoid **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,25414	0,00335	0,74767	0,99233
2	60,63811	-2,75112	203,3461	0,95809
3	6,05679	0,0418	12,36393	0,97739
4	4,86119	-0,38287	14,82307	0,99572
5	2,68773	-0,02639	8,49864	0,98159
6	24,68948	-3,766	52,19684	0,99553
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,2838	0,01	0,59231	0,99171
2	53,4982	4,64673	149,0967	0,96365
3	8,37843	-0,74521	22,43	0,98157
4	7,44886	-1,03202	19,02484	0,99588
5	9,39358	-4,23992	26,93599	0,94877
6	27,54274	2,45141	66,36804	0,99799

Benzer şekilde benzinli motor verisi içinde tasarlanan ÇKP mimarisinde farklı aktivasyon fonksiyonları için elde edilen hata ve doğruluk oranları ise Tablo 5.9 ile Tablo 5.13 arasındaki gibidir. Online-Backpropagation eğitim algoritmasının kullanıldığı 2:6:4 mimarisine, farklı aktivasyon fonksiyonlarına ve çok giriş-tek çıkışlı ÇKP mimarisine sahip 4 YSA'nın hiç birisi çok giriş ve tek çıkış ÇKP mimarisine sahip ve her çıkış için ayrı ayrı tasarlanan YSA'ların ortalama eğitim ve

test hatasına (Tablo 5.31) ulaşamamıştır. Tablo 5.9 ile Tablo 5.13 arasında düğüm başlığı altında sunulan 1, 2, 3, ve 4 numaralar sırasıyla tork, güç, HC ve özgül yakıt tüketimi (sfc) çıkış düğümlerini temsil etmektedir.

Tablo 5.9. Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Hyper-Tangent aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-2:6:4 **Aktivasyon (Gizli katman-Çıkış):** Hyper-Tangent **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,26813	0,00028	0,69796	0,95633
2	0,07417	-0,00132	0,18536	0,99532
3	19,68696	-0,65364	46,25912	0,95854
4	13,4026	0,69485	37,60474	0,95677
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,30116	-0,04148	0,58807	0,94258
2	0,0856	0,00063	0,14304	0,9823
3	15,91205	2,81277	26,64429	0,93987
4	11,84204	-3,38607	17,4232	0,92056

Tablo 5.10. Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Gaussian aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-2:6:4 **Aktivasyon (Gizli katman-Çıkış):** Gaussian **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,26525	-0,00408	0,703	0,95443
2	0,07527	-0,00013	0,19249	0,99444
3	15,22965	0,18699	28,88754	0,97292
4	11,6151	-0,09797	29,55074	0,9645
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,28491	0,19705	0,55501	0,97622
2	0,07721	0,05107	0,15859	0,99698
3	16,03813	-1,12639	27,22812	0,9697
4	13,81436	3,66413	29,75984	0,94793

Tablo 5.11. Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Hyper-Secant aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-2:6:4 **Aktivasyon (Gizli katman-Çıkış):** HyperSecant **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,27585	0,00356	0,67088	0,95544
2	0,11791	0,00435	0,25836	0,98683
3	19,49573	-0,02147	38,66284	0,9589
4	13,71561	0,5266	35,98592	0,94996
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,35536	-0,14906	0,69498	0,92922
2	0,08169	-0,03444	0,17307	0,99359
3	23,32205	14,39017	38,17389	0,94083
4	15,94435	4,49179	28,67136	0,92341

Tablo 5.12. Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-2:6:4 **Aktivasyon (Gizli katman-Çıkış):** Logsigmoid **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation **Öğrenme:** 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,25181	-0,00193	0,57884	0,96691
2	0,06956	-0,00203	0,15401	0,99584
3	17,65707	-0,5713	40,76501	0,96908
4	12,12502	0,50166	34,02354	0,96124
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,36946	0,27486	0,63346	0,92811
2	0,09729	0,07412	0,16311	0,99593
3	23,14556	-9,153	41,09564	0,8185
4	18,64926	6,94244	45,48738	0,86427

Tablo 5.13. Benzinli motor verisi için tasarlanan çok giriş-çok çıkışlı Logsigmoid-Hyper-Tangent aktivasyonlu ÇKP mimarisi sonuçları

Mimari: ÇKP-2:6:4 **Aktivasyon (Gizli katman-Çıkış):** Logsigmoid-HyperTangent **İterasyon sayısı:**10.000 **Eğitim algoritması ve katsayılar:** Online Back-Propagation

Öğrenme: 0,01-0,3 (0,01 değişen aralıkla) **Momentum:** 0,8				
Eğitim Verisi				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,3181	-0,00652	0,7611	0,93938
2	0,0828	-0,00158	0,22575	0,9939
3	20,08166	-0,59097	40,44592	0,9573
4	12,40208	0,54069	34,55573	0,96083
Test Verisi:				
Düğüm	Std Sap	Bias	Maks Hata	Doğruluk oranı
1	0,20481	0,04473	0,34641	0,9788
2	0,07714	0,04016	0,17132	0,99421
3	14,95591	1,84487	21,10464	0,95994
4	19,07205	-13,6566	37,13884	0,9355

Gerek literatürde yaygın olarak kullanılması gerekse de çok giriş ve çok çıkışlı ÇKP modelinin her iki motor türü içinde tek çıkışlı mimariye göre düşük eğitim ve test doğruluk oranı vermesinden ötürü motorların YSA ile modellenmesinde bölüm 5.2.1 ve bölüm 5.2.2'de gösterildiği üzere çok giriş-tek çıkışlı ÇKP mimarisi kullanılmıştır.

5.2.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde ANFIS Uygulaması

ALYUDA NEUROINTELLIGENCE Yazılımı modelleme için kullanılmıştır. Neurointelligence (2003) programı kullanılarak deneme-yanılma yolunun aksine tecrübeye dayalı (heuristic) metot ile nöron sayısı belirlenmiştir. Burada gizli katman nöron sayısı belirli aralıkta aranır. Tecrübeye dayalı arama metodu, her bir adımda başlangıç arama aralığını sınırlar ve arama doğruluğunu son adımda denenen mimari ile bir önceki arasındaki durumda belirler (Breiman 1994). İterasyon sayısı ve yeniden eğitme sayısı dikkate alınarak eğitme işlemi uygulanan YSA için uygunluk kriteri hesaplanır. Uygunluk kriterine göre en iyi performansı veren YSA yapısı bu problem için seçilir. Burada uygunluk kriteri olarak Akaike'nin bilgi kriteri kullanılmıştır. Akaike Bilgi Kriteri (AIC), Hirotsugu Akaike (1974) tarafından geliştirilmiş ve önerilmiş istatistiksel bir modeldir. Bu kriter, gizli katmanda farklı ağırlıklara sahip

farklı ağlar için kullanılır. YSA yapısını belirleme esnasında uygunluk kriteri olarak kullanılan bu ölçüt, basit modellerde tercih edilir. Nöron sayısı ne olursa olsun bir gizli katmanlı YSA yapısı için en uygun nöron sayısını tanımlamada iyi sonuçlar elde edilir. Gizli katman sayısı arttıkça ağırlık sayısı da artacağından dolayı ağ yapısı karmaşık bir hale gelecektir. Bu tür durumlarda AIC ile nöron sayısı belirleme tercih edilmez.

Akaike bilgi kriteri, yapay sinir ağındaki nöronların en uygun sayısını belirler. Bu yöntemde farklı sayıda parametreye sahip olan farklı modeller arasından seçim yapılmaktadır. Bu yöntem, her bir modelin ayrı ayrı en çok olabilirlik fonksiyonunu bulup olabilirlik fonksiyonunun değeri en küçük olan modeli en uygun model olarak seçmektir (Schwarz 1978).

Giriş verileri için uygun ağ mimarisinin bulunması için program 10 kez çalıştırılmış ve 5 kez AIC değeri en düşük ve uygunluk değeri en yüksek olan ağ tipi olarak seçilen 5:12:1 mimarisi çalışma için kullanılmıştır.

Gizlive çıkış katmanı nöron aktivasyonları için;

- Sigmoid, hyperbolic tanjant ve linear aktivasyon fonksiyonları kombinasyonlu olarak CO_2 çıkış parametresinin 7 farklı eğitim algoritması için denenmiştir (Logistic-Logistic-Quick Propagation, Logistic-Hyperbolic tangent- Quick Propagation gibi). Eğitim algoritmaları ise aşağıdaki gibidir;
- -Quick propagation
- -Conjugate Gradient Descent
- -Quasi Newton
- -Limited Memory Quasi Newton
- -Levenberg Marquart
- -Online backpropagation
- -Batch backpropagation

• CO_2 için toplam 63 kez farklı aktivasyon fonksiyonu ve eğitim algoritması için YSA eğitimi yapılmıştır. Her bir eğitim algoritması için 3 farklı aktivasyon fonksiyonu gizli ve çıkış katmanındaki nöronlarda kombinasyonlu olarak 9 farklı şekilde denenmiştir. Toplam 7 eğitim alogritması için 7x9=63 kez eğitim yapılmıştır (Logistic-Logistic-Conjugate Gradient gibi). En düşük

test hatasını veren Hyperbolic tangent -Linear (Online back propagation) 5:12:1 kombinasyonu diğer çıkışlar içinde kullanılmıştır.

- Epok sayısı olarak **10000 epok** belirlenmiştir. Çıkış verilerinini büyüklük ve değişim olarak birbirinden farklı olmasından ötürü hatadaki değişim ve hata oranının eğitim algoritmasını durdurma kriteri olarak kullanılması mümkün olmamıştır.
- Tüm çıkışlar için Hyperbolic tangent-Hyperbolic tangent (Online back propagation) ve 5:12:1 mimarisinde denenmiştir.
- Her biri 54 noktadan oluşan 5 giriş parametresi ve 6 çıkış parametresi 7 noktası test, 7 noktası doğrulama (genellemeyi engelleme ve öğrenmeyi erken sonlandırma için) ve 40 noktası eğitim amaçlı olarak bölünmüştür. Her bir çıkış için tüm verilerin eğitim ve testte kullanılmış olması için 10 kez 5:12:1 mimarisinde **gizli ve çıkış katmanı** için **Hyperbolic-tangent aktivasyonu** ve eğitim için de **Online back propagation** olmak üzere 10 farklı eğitim setiyle eğitim yapılmıştır.
- Öğrenme katsayısı ve momentum değerleri yapılan çalışma ve gözlemler sonucu optimum olarak 0,1 değerinde belirlenmiştir.

CO_2 için ilk eğitim seti ile yapılan eğitim sonucu elde edilen eğitim, doğrulama, test ve tüm noktalar için elde edilen değerler Tablo 5.14 ve Tablo 5.17 arasındaki gibidir.

Tablo 5.14. CO_2 birinci eğitim seti kullanılarak yapılan eğitim sonucu elde edilen eğitim hata, doğruluk ve R-kare değerleri

CO_2 Set 1 Eğitim Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	7,41395	7,416056	0,008325	0,00134
Standart sapma:	1,89051	1,890338	0,009177	0,00167
Minimum:	4,04	4,043816	0,000155	2,2E-05
Maksimum:	11,99	11,99203	0,037841	0,00696
Doğruluk oranı (Korelasyon):	0,99998			
R-kare:	0,99996			

Tablo 5.15. CO_2 birinci test seti kullanılarak yapılan eğitim sonucu elde edilen test hata, doğruluk ve R-kare değerleri

CO_2 Set 1 Doğrulama Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	8,1575	8,20733	0,05688	0,00607
Standart sapma:	2,48625	2,54074	0,07817	0,00719
Minimum:	4,21	4,18176	0,00459	0,00095
Maksimum:	11,63	11,7366	0,24764	0,02368
Doğruluk oranı (Korelasyon):	0,999692			
R-kare:	0,998552			

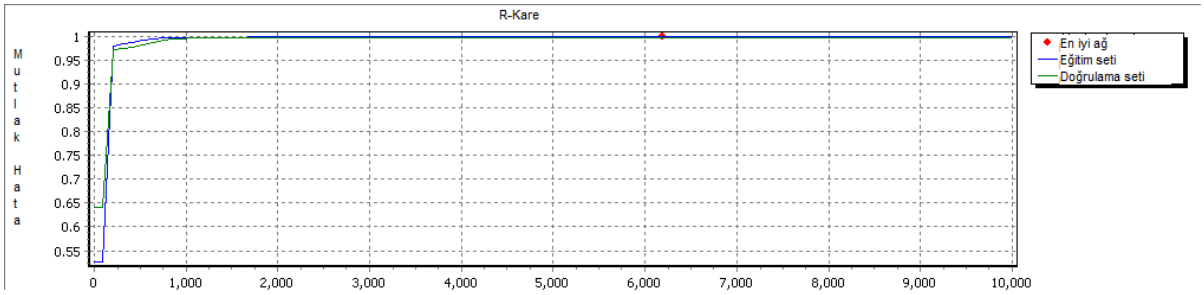
Tablo 5.16. CO_2 birinci validasyon seti kullanılarak yapılan eğitim sonucu elde edilen doğrulama hata, doğruluk ve R-kare değerleri

CO_2 Set 1 Test Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	7,6575	7,62737	0,03267	0,004
Standart sapma:	2,59355	2,56857	0,04932	0,00492
Minimum:	4,09	4,04141	7,8E-05	1,6E-05
Maksimum:	12,27	12,1125	0,15752	0,01284
Doğruluk oranı (Korelasyon):	0,999852			
R-kare:	0,99947			

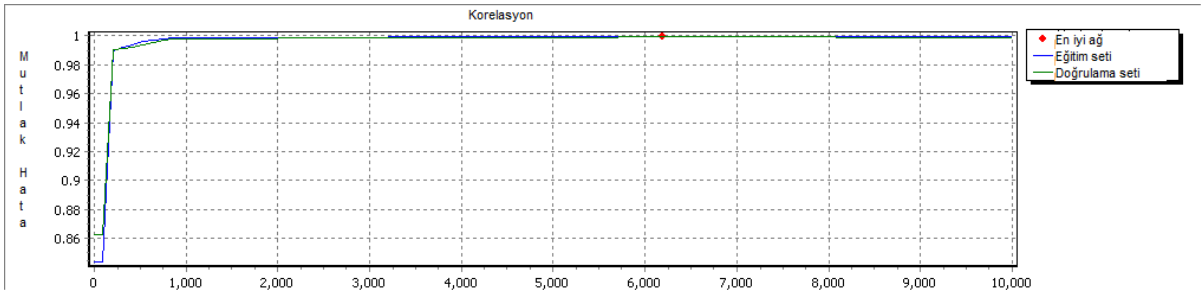
Tablo 5.17. CO_2 birinci eğitim seti kullanılarak yapılan eğitim sonucu eğitim, test, ve doğrulama için kullanılan tüm noktaların hata, doğruluk ve R-kare değerleri

CO_2 Set 1 eğitim, doğrulama ve testi içeren tüm noktalar	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	7,56019	7,56459	0,01913	0,00244
Standart sapma:	2,12053	2,12736	0,04056	0,00405
Minimum:	4,04	4,04141	7,8E-05	1,6E-05
Maksimum:	12,27	12,1125	0,24764	0,02368
Doğruluk oranı (Korelasyon):	0,999784			
R-kare:	0,999556			

Tablo 5.14 ve Tablo 5.17 arası dikkatlice incelenirse eğitim, test, doğrulama ve tüm noktalar için R-kare ve doğruluk oran değerlerinin yaklaşık %99,9 olduğu görülecektir. CO_2 için 5:12:1 mimarisinde gizli ve çıkış katmanında Hyperbolic tangent aktivasyon ve Online back propagation eğitim algoritması kullanılmak üzere bir numaralı eğitim seti ile gerçekleştirilen birinci eğitim sonucu elde edilen R-kare mutlak hatadaki ve doğruluk oranındaki (korelasyon) değişim grafiği Şekil 5.7 ve Şekil 5.8'deki gibidir. Şekil 5.7'de R-kare değerinin artışı ve eğitim kümesi ile test kümesi için 1'e yaklaşması görülmektedir. Ayrıca yine Şekil 5.8'den görüleceği üzere eğitim seti ve doğrulama seti için korelasyon (doğruluk) değeri 1'e yakındır. Buda eğitim seti ile doğrulama seti arasında 1'e yakın ilişki olduğu anlamındadır. Yani Tablo 5.14 ve Tablo 5.16'dan da anlaşılacağı üzere YSA tarafından belirlenen noktalar eğitim ve doğrulama setini sırasıyla % 99.99 ve % 99.98 oranında temsil edebilmektedir. 6000'inci iterasyondan sonra elde edilen ve her iki şekilde de kırmızı nokta ile gösterilen iterasyon değerindeki ağırlıklar sonraki test vb işlemler için kullanılmak üzere ağ ağırlıkları olarak belirlenmiştir.

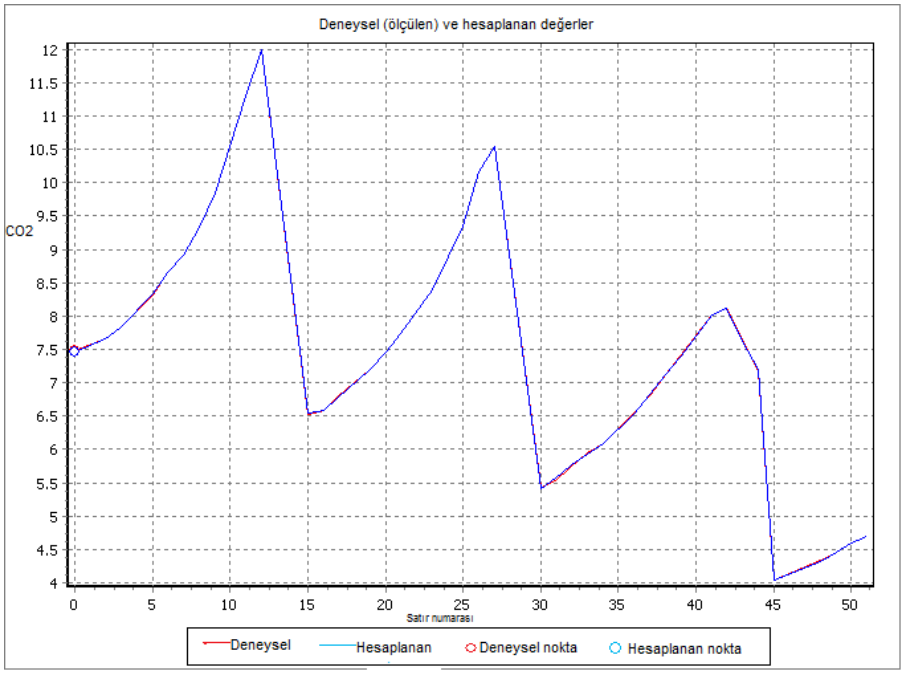


Şekil 5.7. 300PS E1 J1 CO_2 için eğitim seti ve doğrulama seti için R-kare mutlak hata değişimi



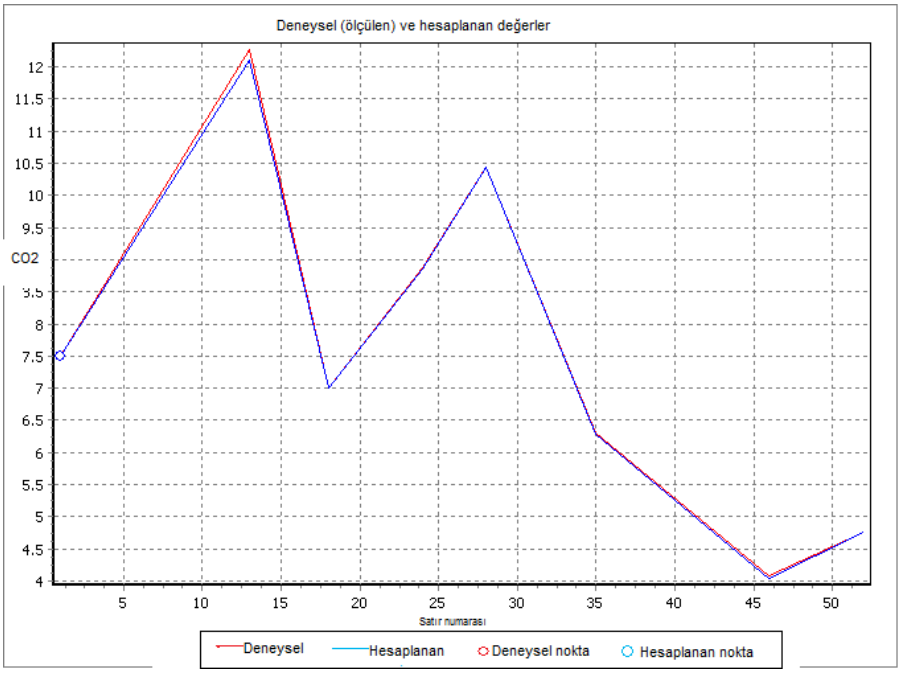
Şekil 5.8. 300PS E1 J1 CO_2 için eğitim seti ve doğrulama seti için doğruluk oranı değişimi

CO_2 için eğitim, test, validasyon, ve sonrasında eğitim ve test noktalarınında dahil edildiği tüm noktaların grafikleri sırasıyla Şekil 5.9.-Şekil 5.12'deki gibidir. Kırmızı çizgi ile motor deneyi sonuçları ve mavi çizgi ile YSA eğitim sonuçları gösterilmiştir. Ayrıca kırmızı daire motor deney noktasını gösterirken mavi daire hesaplanan noktayı göstermektedir. Yatay eksende ise 5 giriş için 54 adet farklı noktayı ifade etmektedir. Dikey eksende ise CO_2 parametresinin aldığı değerler yer almaktadır.

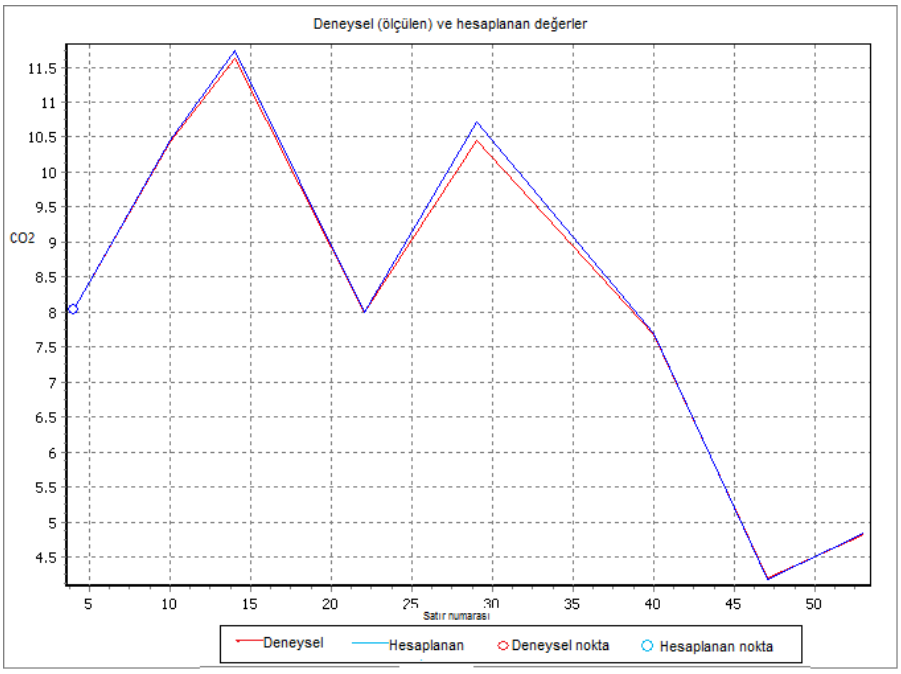


Şekil 5.9. 300PS E1 J1 CO_2 için eğitim grafiği

Şekil 5.9'da verilen eğitim grafiğindende anlaşılacağı üzere YSA ile hesaplanan 40 farklı CO_2 noktası ile deneysel olarak ölçülen 40 nokta tamamen örtüşmektedir. Buda Tablo 5.14'de sunulan CO_2 set 1 eğitim doğruluk oranının ve R-kare değerlerinin % 99,99 olmasından kaynaklanmaktadır. Şekil 5.10'da ise 7 noktadan oluşan CO_2 YSA test verisi ile CO_2 deneysel verisi bir arada sunulmuştur. Şekil 5.11'de 7 noktadan oluşan CO_2 YSA doğrulama verisi ile CO_2 deneysel verisi sunulmuştur. Her iki şekilden ve Tablo 5.15 ile Talo 5.16'dan görüleceği üzere test ve doğrulama noktaları deneysel verilerle sırasıyla % 99.96 ve % 99.98 oranında örtüşmektedir.

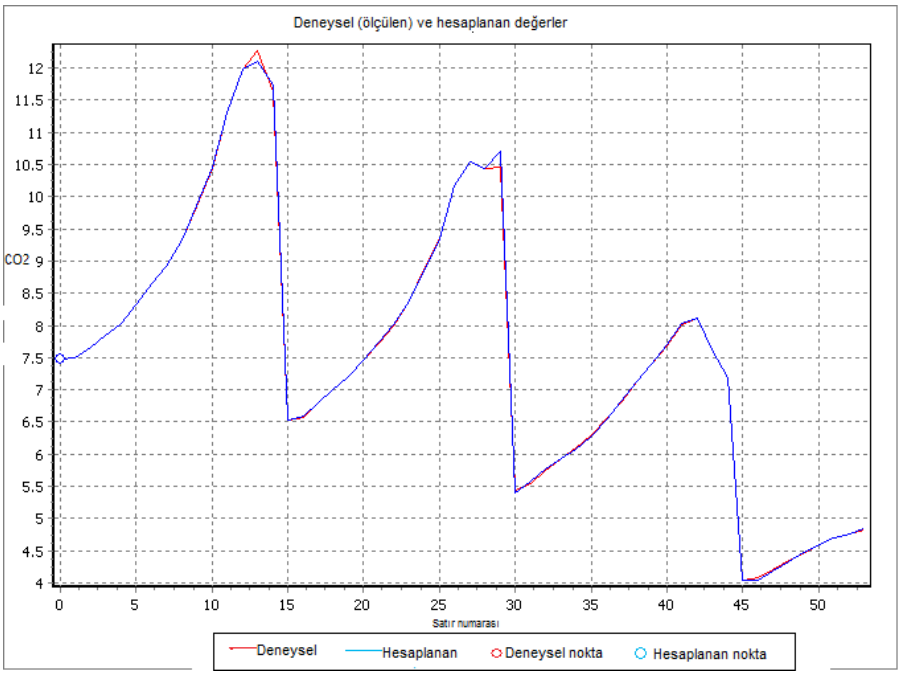


Şekil 5.10. 300PS E1 J1 CO_2 için test grafiği



Şekil 5.11. 300PS E1 J1 CO_2 için validasyon grafiği

Son olarak eğitim ve test noktalarının tümünün dahil edildiği 54 nokta için deneysel veriler ile YSA modellemesi sonucu elde edilen veriler Şekil 5.12'de birlikte sunulmuştur. Tablo 5.17'den görüleceği üzere % 99.97 doğrulukta deneysel veriler YSA'ca tahmin edilmiştir.



Şekil 5.12. 300PS E1 J1 CO_2 için tüm veriler grafiği

Benzer şekilde CO_2 için diğer 9 farklı eğitim, test ve doğrulama seti içinde eğitim yapılmış Tablo 5.18 ve Tablo 5.19'daki değerler elde edilmiştir. Tablo 5.18 ve Tablo 5.19'da yer alan eğitim, doğrulama, test ve tüm noktaların doğruluk değerlerinin ve R-kare değerlerinin ortalaması alınarak (toplam set sayısı 10'a bölünerek) Tablo 5.30 ve Tablo 5.31'de verilen CO_2 için ortalama eğitim, test, doğrulama ve tüm noktalar veri kümesi için doğruluk oranları ve R-kare değerleri elde edilmiştir.

Tablo 5.18. CO_2 için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	CO_2			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,99998	0,99969	0,999852	0,999784
Set 2	0,999471	0,998998	0,998484	0,998134
Set 3	0,999562	0,997708	0,997934	0,999416
Set 4	0,999843	0,999236	0,999692	0,999478
Set 5	0,999202	0,999231	0,999346	0,999034
Set 6	0,99971	0,999762	0,999524	0,99958
Set 7	0,998896	0,999752	0,998732	0,999026
Set 8	0,999609	0,998925	0,998003	0,999056
Set 9	0,999578	0,999707	0,998551	0,999327
Set 10	0,999766	0,998907	0,997952	0,999031
Ortalama	0,99956	0,99919	0,99881	0,99919

Tablo 5.19. CO_2 için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	CO_2			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,99996	0,998552	0,99947	0,99956
Set 2	0,99886	0,99707	0,99396	0,99782
Set 3	0,99707	0,99396	0,99782	0,99904
Set 4	0,99396	0,99782	0,99904	0,99516
Set 5	0,99782	0,99904	0,99516	0,99449
Set 6	0,99904	0,99516	0,99449	0,99788
Set 7	0,99516	0,99449	0,99788	0,99967
Set 8	0,99449	0,99788	0,99967	0,99685
Set 9	0,99788	0,99967	0,99685	0,99844
Set 10	0,99967	0,99685	0,99844	0,99897
Ortalama	0,99739	0,99705	0,99728	0,99779

Tüm çıkışlar için eğitim ve test işlemleri tamamlandıktan sonra elde edilen ortalama eğitim, test, doğrulama ve tüm veri seti R-kare ve doğruluk oran değerleri Tablo 5.20 ile Tablo 5.29 arasında sunulmuştur.

Tablo 5.20. HC için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	HC			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,999456	0,99916	0,9988	0,9991
Set 2	0,999492	0,99931	0,99846	0,99909
Set 3	0,998611	0,99711	0,99627	0,99782
Set 4	0,999501	0,99887	0,99918	0,99917
Set 5	0,999573	0,99728	0,99954	0,99906
Set 6	0,999187	0,99888	0,99905	0,99883
Set 7	0,999325	0,99913	0,99934	0,99928
Set 8	0,999289	0,99947	0,99635	0,99888
Set 9	0,999325	0,99823	0,99934	0,99884
Set 10	0,998389	0,99917	0,99876	0,9992
Ortalama	0,999215	0,99866	0,99851	0,99893

Tablo 5.21. HC için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	HC			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,9989	0,9972	0,99471	0,99801
Set 2	0,99897	0,99773	0,99356	0,99799
Set 3	0,99719	0,99394	0,99717	0,9953
Set 4	0,99899	0,99386	0,99799	0,9982
Set 5	0,99912	0,99149	0,99787	0,99789
Set 6	0,99832	0,99515	0,99756	0,99762
Set 7	0,99862	0,9981	0,99834	0,99853
Set 8	0,99849	0,99876	0,99114	0,99766
Set 9	0,99859	0,99217	0,99858	0,99741
Set 10	0,99875	0,99792	0,99721	0,99839
Ortalama	0,99859	0,99563	0,99641	0,9977

Tablo 5.22. NO_x için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	NO_x			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,999456	0,99916	0,9988	0,9991
Set 2	0,999492	0,99931	0,99846	0,99909
Set 3	0,998611	0,99711	0,99627	0,99782
Set 4	0,999501	0,99887	0,99918	0,99917
Set 5	0,999573	0,99728	0,99954	0,99906
Set 6	0,999187	0,99888	0,99905	0,99883
Set 7	0,999325	0,99913	0,99934	0,99928
Set 8	0,999289	0,99947	0,99635	0,99888
Set 9	0,999325	0,99823	0,99934	0,99884
Set 10	0,998389	0,99917	0,99876	0,9992
Ortalama	0,98952	0,98562	0,97749	0,98531

Tablo 5.23. NO_x için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	NO_x			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,9989	0,9972	0,99471	0,99801
Set 2	0,99897	0,99773	0,99356	0,99799
Set 3	0,99719	0,99394	0,99717	0,9953
Set 4	0,99899	0,99386	0,99799	0,9982
Set 5	0,99912	0,99149	0,99787	0,99789
Set 6	0,99832	0,99515	0,99756	0,99762
Set 7	0,99862	0,9981	0,99834	0,99853
Set 8	0,99849	0,99876	0,99114	0,99766
Set 9	0,99859	0,99217	0,99858	0,99741
Set 10	0,99875	0,99792	0,99721	0,99839
Ortalama	0,976	0,94945	0,93316	0,96547

Tablo 5.24. Güç (P) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Güç (P)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,999779	0,99949	0,99993	0,99747
Set 2	0,999726	0,99967	0,99992	0,99969
Set 3	0,999338	0,9988	0,99953	0,99922
Set 4	0,999667	0,99953	0,9996	0,9996
Set 5	0,999805	0,99905	0,99985	0,9996
Set 6	0,99985	0,99941	0,99977	0,99968
Set 7	0,999813	0,99954	0,99973	0,99974
Set 8	0,999805	0,99976	0,99926	0,99961
Set 9	0,999773	0,99939	0,99931	0,99963
Set 10	0,999708	0,99994	0,99995	0,99976
Ortalama	0,999726	0,99946	0,99968	0,9994

Tablo 5.25. Güç (P) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Güç (P)			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,99955	0,99897	0,99979	0,99369
Set 2	0,99942	0,99915	0,99941	0,99937
Set 3	0,99855	0,99729	0,99888	0,9984
Set 4	0,99928	0,99858	0,99887	0,99911
Set 5	0,99959	0,9969	0,99944	0,99915
Set 6	0,9997	0,99792	0,99903	0,9993
Set 7	0,99961	0,999	0,99919	0,99947
Set 8	0,9996	0,99865	0,99801	0,99922
Set 9	0,99952	0,99872	0,99856	0,99926
Set 10	0,99938	0,99981	0,99975	0,9995
Ortalama	0,99942	0,9985	0,99909	0,99865

Tablo 5.26. Özgül yakıt tüketimi (Sfc) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Özgül yakıt tüketimi (Sfc)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,99927	0,98426	0,99727	0,99134
Set 2	0,99847	0,99682	0,99822	0,99798
Set 3	0,99927	0,99167	0,99637	0,9937
Set 4	0,99733	0,99603	0,99689	0,99565
Set 5	0,99791	0,99413	0,99786	0,99736
Set 6	0,99834	0,99039	0,99484	0,99127
Set 7	0,99911	0,99548	0,99953	0,99482
Set 8	0,99893	0,99289	0,99693	0,99528
Set 9	0,99884	0,99675	0,99398	0,9963
Set 10	0,99911	0,99136	0,99689	0,99659
Ortalama	0,99866	0,99298	0,99688	0,99503

Tablo 5.27. Özgül yakıt tüketimi (Sfc) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Özgül yakıt tüketimi (Sfc)			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,99844	0,89735	0,9933	0,97539
Set 2	0,99653	0,99334	0,99606	0,99579
Set 3	0,99872	0,99722	0,9962	0,99581
Set 4	0,99427	0,9959	0,9931	0,99066
Set 5	0,9928	0,99306	0,99265	0,99485
Set 6	0,99645	0,99014	0,992	0,9901
Set 7	0,9981	0,99424	0,99932	0,99313
Set 8	0,99784	0,99123	0,99532	0,98996
Set 9	0,99674	0,99384	0,99113	0,99162
Set 10	0,99821	0,99024	0,99516	0,99453
Ortalama	0,99681	0,98366	0,99442	0,99118

Tablo 5.28. Tork (Tq) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Tork (Tq)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,999786	0,99969	0,99999	0,99976
Set 2	0,999745	0,99975	0,99992	0,99974
Set 3	0,999874	0,99981	0,99909	0,99814
Set 4	0,999811	0,99962	0,99988	0,99971
Set 5	0,999803	0,99971	0,99948	0,99985
Set 6	0,999895	0,99991	0,99992	0,99999
Set 7	0,999981	0,99993	0,99991	0,99997
Set 8	0,999972	0,99992	0,99976	0,99976
Set 9	0,999577	0,99963	0,99984	0,99961
Set 10	0,999756	0,9985	0,99942	0,99948
Ortalama	0,99982	0,99965	0,99972	0,9996

Tablo 5.29. Tork (Tq) için 10 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Tork (Tq)			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,99954	0,99905	0,99911	0,99938
Set 2	0,99946	0,99903	0,99921	0,99935
Set 3	0,9997	0,99931	0,99899	0,99614
Set 4	0,99959	0,99952	0,99887	0,99928
Set 5	0,99971	0,9996	0,99931	0,9997
Set 6	0,99977	0,99995	0,99991	0,99998
Set 7	0,99998	0,99992	0,99992	0,99992
Set 8	0,99992	0,99931	0,99905	0,99942
Set 9	0,99902	0,99859	0,99948	0,99902
Set 10	0,99946	0,99654	0,99847	0,99891
Ortalama	0,99961	0,99908	0,99923	0,99911

Tüm çıkışlar için eğitim ve test işlemleri tamamlandıktan sonra her bir çıkış için eğitim, doğrulama, test ve tüm noktaların doğruluk değerlerinin ve R-kare değerlerinin ortalaması alınarak (toplam set sayısı 10'a bölünerek) Tablo 5.30 ve Tablo 5.31'de verilençıkış parametreleri için ortalama eğitim, test, doğrulama ve tüm noktalar veri kümesi için doğruluk oranları ve R-kare değerleri elde edilmiştir.

Tablo 5.30. 300PS E1 J1 çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama R-kare değerleri

Değişken adı	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
CO_2	0,99739	0,99705	0,99728	0,99779
HC	0,99859	0,99563	0,99641	0,9977
NO_x	0,976	0,94945	0,93316	0,96547
P	0,99942	0,9985	0,99909	0,99865
Tq	0,99961	0,99908	0,99923	0,99911
Sfc	0,99681	0,98366	0,99442	0,99118
Ortalama	0,994637	0,987228	0,986598	0,99165

Tablo 5.31. 300PS E1 J1 çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama doğruluk oranları (%)

Değişken adı	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
CO_2	0,99956	0,99919	0,99881	0,99919
HC	0,999215	0,99866	0,99851	0,99893
NO_x	0,98952	0,98562	0,97749	0,98531
P	0,999726	0,99946	0,99968	0,9994
Tq	0,99982	0,99965	0,99972	0,9996
Sfc	0,99866	0,99298	0,99688	0,99503
Ortalama	0,99775	0,995927	0,995182	0,996243

Tablo 5.30 ve Tablo 5.31'den görüleceği üzere tüm çıkışlar için R-kare ve doğruluk oran (korelasyon) değerleri %100'e yakın değerler olarak çıkmıştır. Buda YSA ile gerçekleştirilen modellemenin yapılan motor deneyinde elde edilen sonuçlara göre eğitim setinde %99.77, doğrulam setinde %99.59, test setinde %99.51 ve tüm noktalarda %99.62 uyumlu sonuçlar ürettiğini göstermektedir. NO_x için elde edilen düşük doğrulama oranının yükseltilebilmesi amacıyla ilgili YSA eğitim algoritmasında öğrenme katsayısı ve momentumda değişikliğe gidilmiş olup yapılan denemeler sonucunda daha iyi sonuç elde edilememiştir.

SONUÇ:

Tablo 4.2, Tablo 5.2, Tablo 5.30 ve Tablo 5.31'den de görüleceği üzere, elde edilen performans ve emisyon parametre değerlerinini doğruluğunu gösteren R-kare ve doğruluk oran değerleri tüm çıkış parametreleri için YSA modellenmesinde en yüksek doğruluk değerine sahiptir. Dolayısıyla üzerinde çalışılan dizel motor verilerine dayalı olarak doğrusal olmayan yapıya sahip dizel motor performans ve emisyon karakteristiği modellenmesinde YSA'nın modelleme amaçlı olarak kullanılması diğer tekniklere göre daha başarılı sonuçlar verecektir.

Literatürde benzinli motorlar için yapılan bir çok modelleme mevcut iken, dizel motorlar için yapılan modelleme sayısı oldukça kısıtlıdır. Yapılan modelleme çalışmalarında da ağırlıklı olarak YSA kullanlmıştır. YSA topolojisi olarakda ÇKP yoğun olarak kullanılmıştır. Bunlardan Hafner ve ark. (2000) lokal lineer radyal tabanlı fonksiyon ağı (LOLIMOT) kullanarak yaptıkları modellemede çıkış değerlerini deneysel verilere % 97 yaklaşık sonuç ile elde etmişlerdir. Arcaklıoğlu ve Çelikten (2005) ÇKP kullanarak elde ettikleri modellemede deneysel verilere % 99 yaklaşık sonuç elde etmişlerdir. Bu çalışmada gerçekleştirilen ÇKP topolojisi için önceki çalışmalardan farklı sayıda gizli nöron ve eğitim algoritması kullanılmıştır. Modellemede YSA ile deneysel verilere göre eğitim setinde %99.77, doğrulama setinde %99.59, test setinde %99.51 ve tüm noktalarda %99.62 uyumlu sonuçlar üretilmiştir.

5.2.2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde YSA Uygulaması

Bir önceki alt bölümde (5.1.1) izlenilen uygulama adımları bu bölümde de izlenmiştir. Giriş verileri için uygun ağ mimarisinin bulunması için program (Alyuda Neuro Intelligence) 10 kez çalıştırılmış ve uygunluk değeri en yüksek olan ve 4 kez en uygun ağ tipi olarak seçilen 2:6:1 mimarisi çalışma için kullanılmıştır. Ağın en iyi öğrenme performansının öğrenme katsayısı 0,1 ve hızlı yayılım katsayısı 1,75 olduğunda gözlendiği için öğrenme katsayısı ve hızlı yayılım katsayısı sırasıyla 0,1 ve 1,75 olarak kullanılmıştır.

Gizli ve **çıkış katmanı** nöron aktivasyonları için **Logistic ve Hyperbolic-tangent** yapılan testler sonucu seçilmiştir. Eğitim algoritması için **Quick propagation** en uygun algoritma seçilmiştir. Gizli katman ve çıkış katmanı aktivasyon fonksiyonu ve eğitim algoritmasının belirlenmesi için güç (P) çıkış parametresi 7x9=63 kez eğitime tabi tutulmuştur. Epok sayısı olarak yine **10000 epok** belirlenmiştir. Çıkış verilerinini büyüklük ve değişim olarak birbirinden farklı olmasından ötürü hatadaki değişim ve hata oranının eğitim algoritmasını durdurma kriteri olarak kullanılması mümkün olmamıştır. Her biri 40 noktadan oluşan 2 giriş parametresi ve 4 çıkış parametresi 7 noktası test, 7 noktası doğrulama ve 26 noktası eğitim amaçlı olarak bölünmüştür. Her bir çıkış için tüm verilerin eğitim ve testte kullanılmış olması için 6 kez 2:6:1 mimarisinde gizli ve çıkış katmanı için sırasıyla Logistic ve Hyperbolic tanget aktivasyonu ve eğitim için de Quick propagation olmak üzere 8 farklı eğitim setiyle eğitim yapılmıştır. Güç için ilk eğitim seti ile yapılan eğitim sonucu elde edilen eğitim, doğrulama, test ve tüm noktalar için elde edilen değerler Tablo 5.32 ve Tablo 5.35'deki gibidir.

Tablo 5.32. Güç (P) birinci eğitim seti kullanılarak yapılan eğitim sonucu elde edilen eğitim hata, doğruluk ve R-kare değerleri

Güç (P) Set 1 Eğitim Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	2,43838	2,43855	0,00709	0,003
Standart sapma:	0,643	0,64264	0,01119	0,00432
Minimum:	1,14	1,13973	2,2E-05	9E-06
Maksimum:	3,46	3,45806	0,05178	0,01792
Doğruluk oranı:	0,99788			
R-kare:	0,999575			

Tablo 5.33. Güç (P) birinci test seti kullanılarak yapılan eğitim sonucu elde edilen test hata, doğruluk ve R-kare değerleri

Güç (P) Set 1 Doğrulama Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	2,00514	2,0016	0,04553	0,02455
Standart sapma:	0,86742	0,83382	0,04062	0,02642
Minimum:	0,968	1,04725	2,1E-05	1,7E-05
Maksimum:	2,999	3,03516	0,11947	0,08187
Doğruluk oranı:	0,998216			
R-kare:	0,994646			

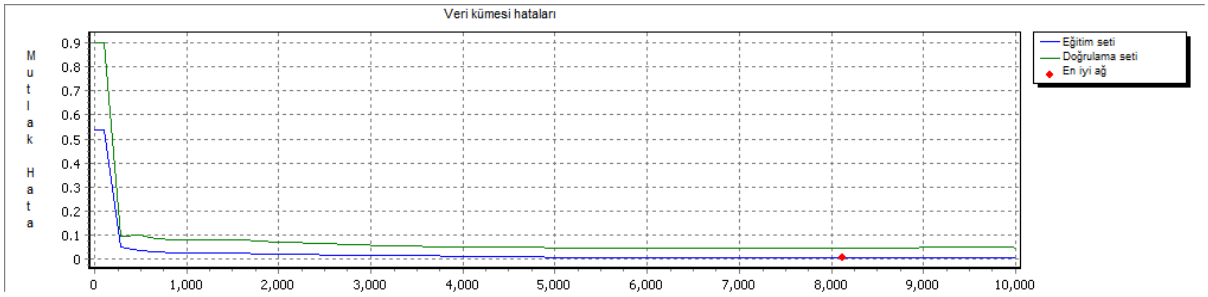
Tablo 5.34. Güç (P) birinci validasyon seti kullanılarak yapılan eğitim sonucu elde edilen doğrulama hata, doğruluk ve R-kare değerleri

Güç (P) Set 1 Test Değerleri	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	2,43714	2,41717	0,058	0,01907
Standart sapma:	0,76402	0,71932	0,08297	0,02202
Minimum:	1,487	1,50425	0,0017	0,00103
Maksimum:	3,632	3,37637	0,25563	0,07038
Doğruluk oranı:	0,992858			
R-kare:	0,980194			

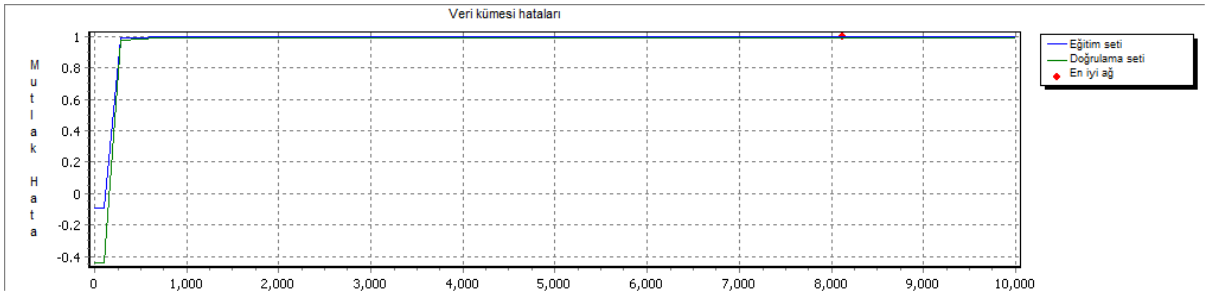
Tablo 5.35. Güç (P) birinci eğitim seti kullanılarak yapılan eğitim sonucu eğitim, test, ve doğrulama için kullanılan tüm noktaların hata, doğruluk ve R-kare değerleri

Güç (P) Set 1 eğitim, doğrulama ve testi içeren tüm noktalar	**Hedef**	**YSA çıkışı**	**Ortalama hata**	**Ortalama karesel hata**
Ortalama:	2,37502	2,371707	0,020117	0,008485
Standart sapma:	0,714896	0,702008	0,041916	0,016157
Minimum:	0,968	1,047251	0,000021	0,000009
Maksimum:	3,631999	3,458058	0,255628	0,081871
Doğruluk oranı:	0,998023			
R-kare:	0,995614			

Tablo 5.32 ve Tablo 5.35 arası dikkatlice incelenirse eğitim, test, doğrulama ve tüm noktalar için R-kare ve doğruluk oran değerlerinin %99'un üzerinde olduğu görülecektir. Güç için 2:6:1 mimarisinde gizli ve çıkış katmanında Logsigmoid ve Hyperbolic tangent aktivasyon ve Online back propagation eğitim algoritması kullanılmak üzere bir numaralı eğitim seti ile gerçekleştirilen birinci eğitim sonucu elde edilen R-kare mutlak hatadaki ve doğruluk oranındaki (korelasyon) değişim grafiği Şekil 5.13 ve Şekil 5.14'deki gibidir. Şekil 5.13'de R-kare değerinin artışı ve eğitim kümesi ile doğrulama kümesi için 1'e yaklaşması görülmektedir. Ayrıca yine Şekil 5.14'den görüleceği üzere eğitim seti ve doğrulama seti için korelasyon (doğruluk) değeri 1'e yakındır. Buda eğitim seti ile doğrulama seti arasında 1'e yakın ilişki olduğu anlamındadır. Yani Tablo 5.32 ve Tablo 5.34'den de anlaşılacağı üzere YSA tarafından belirlenen noktalar eğitim ve doğrulama setini sırasıyla % 99.78 ve % 99.28 oranında temsil edebilmektedir. 8000'inci iterasyondan sonra elde edilen ve her iki şekilde de kırmızı nokta ile gösterilen iterasyon değerindeki ağırlıklar sonraki test vb işlemler için kullanılmak üzere ağ ağırlıkları olarak belirlenmiştir.

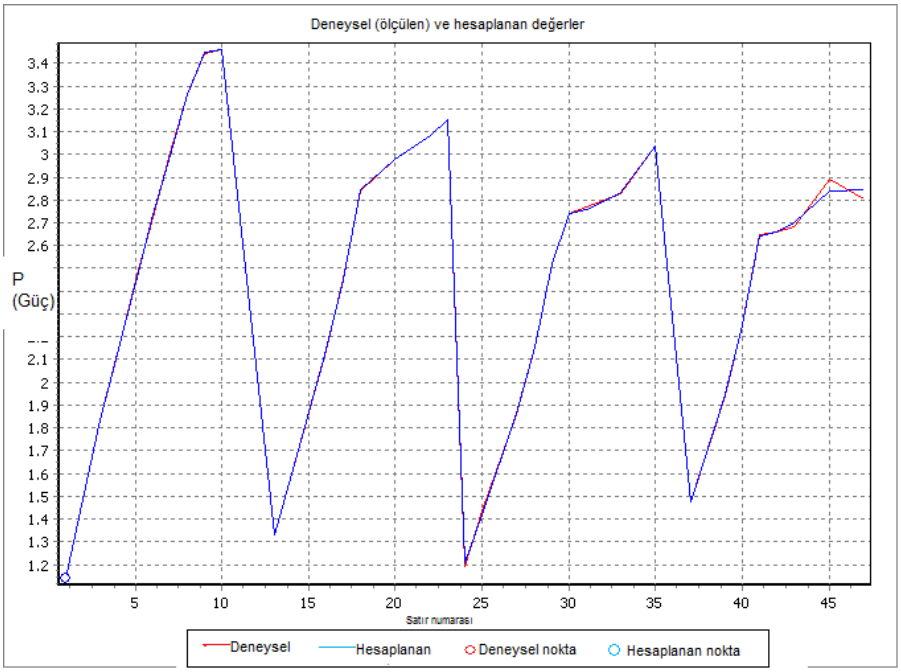


Şekil 5.13. Briggs ve Stratton Vanguard güç (P) için eğitim seti, doğrulama seti mutlak hata değişimi



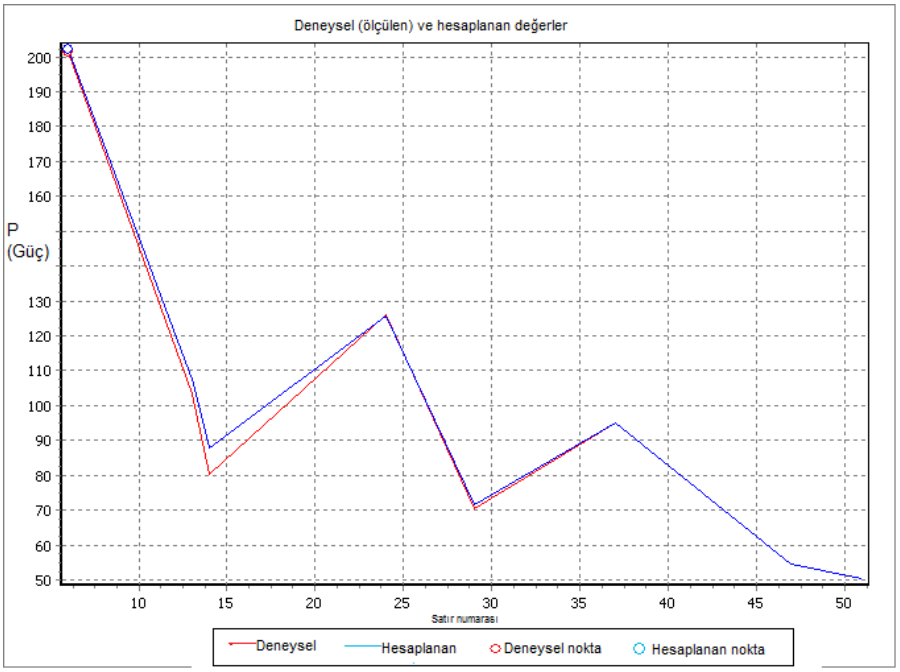
Şekil 5.14. Briggs ve Stratton Vanguard güç (P) için eğitim seti ve doğrulama seti için R-kare mutlak hata değişimi

P (güç) için eğitim, test, validasyon, ve sonrasında eğitim ve test noktalarınında dahil edildiği tüm noktaların grafikleri sırasıyla Şekil 5.15.- Şekil 5.18'deki gibidir. Kırmızı çizgi ile motor deneyi sonuçları ve mavi çizgi ile YSA eğitim sonuçları gösterilmiştir. Ayrıca kırmızı daire motor deney noktasını gösterirken mavi daire hesaplanan noktayı göstermektedir. Yatay eksende ise 2 giriş için 48 adet farklı noktayı ifade etmektedir. Dikey eksende ise güç (P) parametresinin aldığı değerler yer almaktadır.

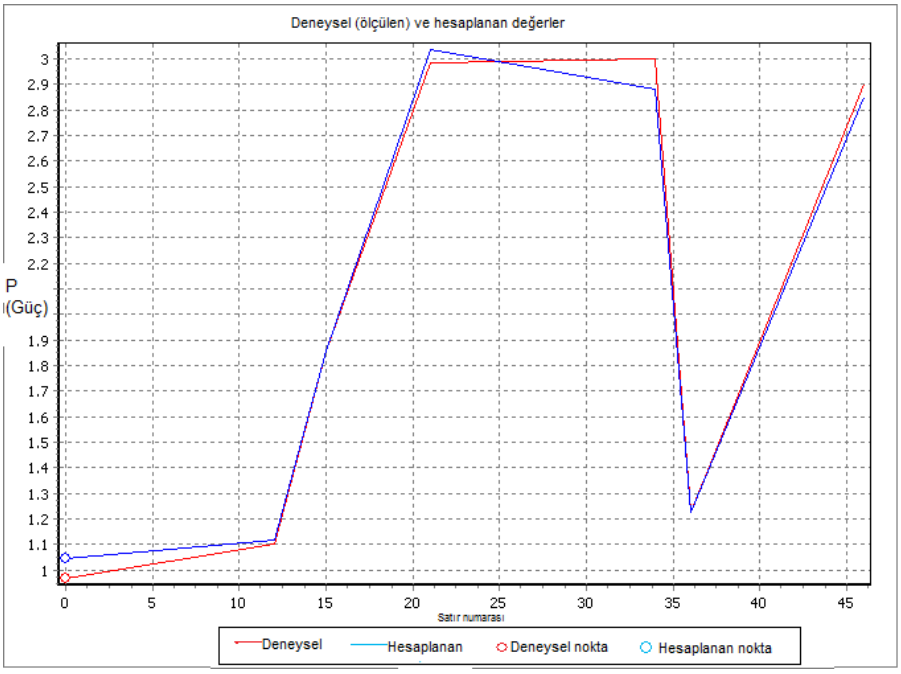


Şekil 5.15. Briggs ve Stratton Vanguard güç (P) için eğitim grafiği

Şekil 5.15'de verilen eğitim grafiğindende anlaşılacağız üzere YSA ile hesaplanan 40 farklı güç (P) noktası ile deneysel olarak ölçülen 40 nokta tamamen örtüşmektedir. Buda Tablo 5.32'de sunulan güç (P) set 1 eğitim doğruluk oranının ve R-kare değerlerinin sırasıyla % 99,78 ve % 99,95 olmasından kaynaklanmaktadır. Şekil 5.16'da ise 7 noktadan oluşan güç (P) YSA test verisi ile güç (P) deneysel verisi bir arada sunulmuştur. Şekil 5.17'de 7 noktadan oluşan güç (P) YSA doğrulama verisi ile güç (P) deneysel verisi sunulmuştur. Her iki şekilden ve Tablo 5.33 ile Tablo 5.34'den görüleceği üzere test ve doğrulama noktaları deneysel verilerle sırasıyla %99.82 ve %99.28 oranında örtüşmektedir.

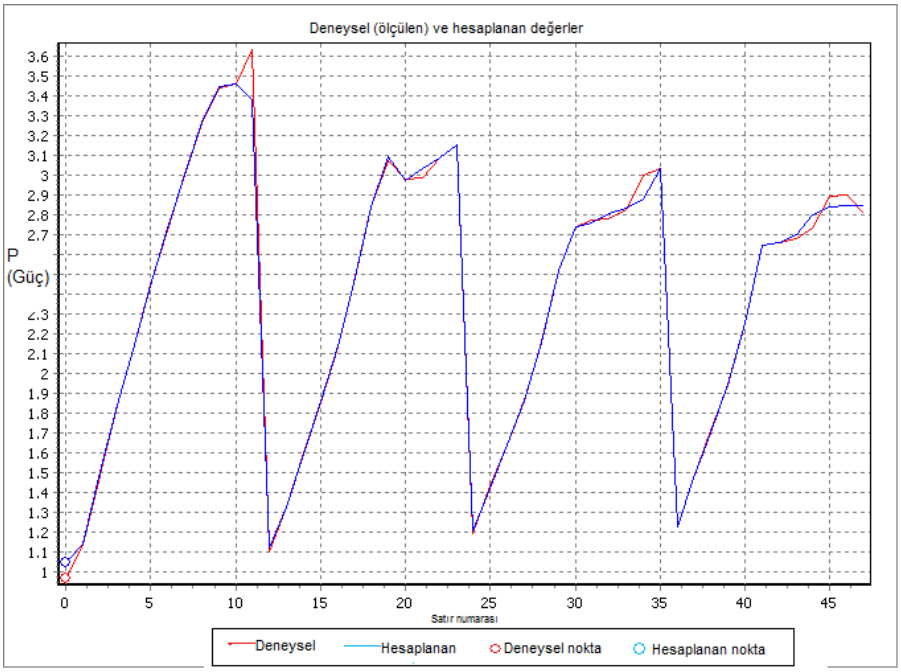


Şekil 5.16. Briggs ve Stratton Vanguard güç (P) için test grafiği



Şekil 5.17. Briggs ve Stratton Vanguard güç (P) için validasyon grafiği

Son olarak eğitim ve test noktalarının tümünün dahil edildiği 48 nokta için deneysel veriler ile YSA modellemesi sonucu elde edilen veriler Şekil 5.18'de birlikte sunulmuştur. Tablo 5.35'den görüleceği üzere % 99.80 doğrulukta deneysel veriler YSA'ca tahmin edilmiştir.



Şekil 5.18. Briggs ve Stratton Vanguard güç (P) için tüm veriler grafiği

Benzer şekilde güç (P) için diğer 7 farklı eğitim, test ve doğrulama seti içinde eğitim yapılmış Tablo 5.36 ve Tablo 5.37'deki değerler elde edilmiştir. Tablo 5.36 ve Tablo 5.37'de yer alan eğitim, doğrulama, test ve tüm noktaların doğruluk değerlerinin ve R-kare değerlerinin ortalaması alınarak (toplam set sayısı 8'e bölünerek) Tablo 5.43 ve Tablo 5.44'de verilen güç (P) için ortalama eğitim, test, doğrulama ve tüm noktalar veri kümesi için doğruluk oranları ve R-kare değerleri elde edilmiştir.

Tablo 5.36. Güç (P) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Güç (P)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,99788	0,99822	0,99286	0,99802
Set 2	0,99958	0,99465	0,98019	0,99561
Set 3	0,99822	0,99286	0,99802	0,99818
Set 4	0,99465	0,98019	0,99561	0,99625
Set 5	0,99286	0,99802	0,99818	0,99541
Set 6	0,98019	0,99561	0,99625	0,98199
Set 7	0,99802	0,99818	0,99541	0,99424
Set 8	0,99561	0,99625	0,98199	0,9801
Ortalama	0,994626	0,99425	0,99231	0,99248

Tablo 5.37. Güç (P) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Güç (P)			
Eğitim, test ve geçerlilik set numarası	**Eğitim Seti R-kare değeri**	**Validasyon Seti R-kare değeri**	**Test Seti R-kare değeri**	**Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri**
Set 1	0,999575	0,994646	0,980194	0,995614
Set 2	0,994646	0,980194	0,995614	0,998689
Set 3	0,980194	0,995614	0,998689	0,965593
Set 4	0,995614	0,998689	0,965593	0,987505
Set 5	0,998689	0,965593	0,987505	0,99317
Set 6	0,965593	0,987505	0,99317	0,999498
Set 7	0,987505	0,99317	0,999498	0,989263
Set 8	0,99317	0,999498	0,989263	0,991856
Ortalama	0,98937	0,98936	0,98869	0,99015

Tüm çıkışlar için eğitim ve test işlemleri tamamlandıktan sonra elde edilen ortalama eğitim, test, doğrulama ve tüm veri seti R-kare ve doğruluk oran değerleri Tablo 5.38 ile Tablo 5.43 arasında sunulmuştur.

Tablo 5.38. HC için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	HC			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,98429	0,87016	0,9789	0,97582
Set 2	0,9437	0,96443	0,76735	0,91473
Set 3	0,98969	0,93299	0,97069	0,97301
Set 4	0,97454	0,99399	0,93307	0,96777
Set 5	0,99666	0,94756	0,96986	0,97744
Set 6	0,93707	0,98686	0,92807	0,93895
Set 7	0,96502	0,99508	0,96874	0,96806
Set 8	0,8578	0,9635	0,99738	0,88949
Ortalama	0,9561	0,95682	0,93926	0,95066

Tablo 5.39. HC için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	HC			
Eğitim, test ve validasyon set numarası	Eğitim Seti R-kare değeri	Validasyon Seti R-kare değeri	Test Seti R-kare değeri	Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri
Set 1	0,96681	0,66641	0,95283	0,95002
Set 2	0,8659	0,91804	0,25609	0,79657
Set 3	0,97834	0,81731	0,85466	0,9405
Set 4	0,94309	0,96417	0,84953	0,93508
Set 5	0,99299	0,844	0,8838	0,95494
Set 6	0,8334	0,97063	0,79148	0,85196
Set 7	0,92478	0,98516	0,8876	0,93044
Set 8	0,48424	0,8896	0,88727	0,63059
Ortalama	0,87369	0,88191	0,79541	0,87376

Tablo 5.40. Özgül Yakıt Tüketimi (Sfc) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Özgül Yakıt Tüketimi (Sfc)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,96389	0,98774	0,9918	0,99427
Set 2	0,99941	0,99392	0,96843	0,99483
Set 3	0,999232	0,9892	0,99526	0,99016
Set 4	0,996767	0,98517	0,98137	0,9922
Set 5	0,996806	0,954	0,94803	0,98189
Set 6	0,986995	0,95305	0,91589	0,9761
Set 7	0,996437	0,97477	0,97582	0,98531
Set 8	0,997048	0,99103	0,96627	0,99377
Ortalama	0,992073	0,97861	0,96786	0,98857

Tablo 5.41. Özgül Yakıt Tüketimi (Sfc) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Özgül Yakıt Tüketimi (Sfc)			
Eğitim, test ve validasyon set numarası	Eğitim Seti R-kare değeri	Validasyon Seti R-kare değeri	Test Seti R-kare değeri	Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri
Set 1	0,99206	0,95937	0,97601	0,98835
Set 2	0,9987	0,98292	0,8934	0,98948
Set 3	0,99845	0,96767	0,91417	0,97905
Set 4	0,99291	0,96496	0,93056	0,98231
Set 5	0,99337	0,89694	0,76323	0,96031
Set 6	0,97182	0,88777	0,81705	0,94714
Set 7	0,99275	0,94242	0,94558	0,97067
Set 8	0,99318	0,98127	0,89847	0,98541
Ortalama	0,99165	0,94792	0,89231	0,97534

Tablo 5.42. Tork (Tq) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen doğruluk oran değerleri

Çıkış Parametresi	Tork (Tq)			
Eğitim, test ve doğrulama set numarası	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
Set 1	0,99999	0,99951	0,99987	0,99996
Set 2	0,99977	0,99153	0,99941	0,99898
Set 3	0,99999	0,99984	0,99856	0,99969
Set 4	0,99996	0,9999	0,99982	0,99991
Set 5	0,99998	0,99833	0,99967	0,99949
Set 6	0,99995	0,99987	0,9997	0,99988
Set 7	0,99999	0,99223	0,99976	0,99927
Set 8	0,99999	0,99992	0,98803	0,99871
Ortalama	0,99995	0,99764	0,9981	0,99949

Tablo 5.43. Tork (Tq) için 8 farklı eğitim, doğrulama ve test seti kullanılarak gerçekleştirilen eğitim, doğrulama, test ve tüm noktalar veri kümeleri için elde edilen R-kare değerleri

Çıkış Parametresi	Tork (Tq)			
Eğitim, test ve validasyon set numarası	Eğitim Seti R-kare değeri	Validasyon Seti R-kare değeri	Test Seti R-kare değeri	Tüm noktalar (eğitim, validasyon ve test seti) R-kare değeri
Set 1	0,99999	0,99978	0,99968	0,99991
Set 2	0,99953	0,98127	0,99879	0,99794
Set 3	0,99998	0,99964	0,99644	0,99935
Set 4	0,99992	0,99971	0,99956	0,99981
Set 5	0,99997	0,99627	0,99909	0,99896
Set 6	0,99999	0,99972	0,9988	0,99974
Set 7	0,99999	0,9821	0,99951	0,99852
Set 8	0,99998	0,99959	0,97116	0,99734
Ortalama	0,99992	0,99476	0,99538	0,99895

Tüm çıkışlar için eğitim ve test işlemleri tamamlandıktan sonra her bir çıkış için eğitim, doğrulama, test ve tüm noktaların doğruluk değerlerinin ve R-kare değerlerinin ortalaması alınarak (toplam set sayısı 8'e bölünerek) Tablo 5.44 ve

Tablo 5.45'de verilen çıkış parametreleri için ortalama eğitim, test, doğrulama ve tüm noktalar veri kümesi için doğruluk oranları ve R-kare değerleri elde edilmiştir.

Tablo 5.44. Briggs ve Stratton Vanguard çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama R-kare değerleri

Değişken adı	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
HC	0,87369	0,88191	0,79541	0,87376
P	0,98937	0,98936	0,98869	0,99015
Tq	0,99992	0,99476	0,99538	0,99895
Sfc	0,99165	0,94792	0,89231	0,97534
Ortalama	0,963658	0,953488	0,917948	0,95955

Tablo 5.45. Briggs ve Stratton Vanguard çıkış parametrelerinin YSA ile modellenmesi sonucu elde edilen ortalama doğruluk oranları (%)

Değişken adı	**Eğitim seti**	**Doğrulama seti**	**Test Seti**	**Tüm noktalar (eğitim, validasyon ve test seti)**
HC	0,9561	0,95682	0,93926	0,95066
P	0,994626	0,99425	0,99231	0,99248
Tq	0,99995	0,99764	0,9981	0,99949
Sfc	0,992073	0,97861	0,96786	0,98857
Ortalama	0,985687	0,98183	0,974383	0,9828

Tablo 5.44 ve Tablo 5.45'den görüleceği üzere tüm çıkışlar için R-kare ve doğruluk oran (korelasyon) değerleri %100'e yakın değerler olarak çıkmıştır. Buda YSA ile gerçekleştirilen modellemenin yapılan motor deneyinde elde edilen sonuçlara göre eğitim setinde %98,56 doğrulama setinde %98.18, test setinde %97.43 ve tüm noktalarda %98.28 uyumlu sonuçlar ürettiğini göstermektedir. HC için elde edilen düşük doğrulama oranının yükseltilebilmesi amacıyla ilgili YSA eğitim algoritmasında öğrenme ve hızlı yayılım katsayısında değişikliğe gidilmiş olup yapılan denemeler sonucunda daha iyi sonuç elde edilememiştir.

SONUÇ:

Tablo 4.4, Tablo 5.4, Tablo 5.44 ve Tablo 5.45'den de görüleceği üzere, elde edilen performans ve emisyon parametre değerlerinini doğruluğunu gösteren R-kare ve doğruluk oran değerleri tüm çıkış parametreleri için YSA modellenmesinde en yüksek doğruluk değerine sahiptir. Dolayısıyla üzerinde çalışılan benzinli motor verilerine dayalı olarak doğrusal olmayan yapıya sahip benzinli motor performans ve emisyon karakteristiği modellenmesinde YSA'nın modelleme amaçlı olarak kullanılması diğer tekniklere göre daha başarılı sonuçlar verecektir.

Literatürde benzinli motorlar için yapılan bir çok modelleme mevcuttur. Bu çalışmada elde edilen eğitim setinde %98,56 doğrulama setinde %98.18, test setinde %97.43 ve tüm noktalarda %98.28 uyumlu sonuçlar bu verileri kullanarak yapılan ve Bulanık Uzman Sistem kullanılan çalışmada elde edilen (Taşdemir 2004) değer olan % 97.24' den daha yüksektir. Bundan ötürü YSA'nın benzinli motorların emisyon ve performans karakteristiğinin modellenmesinde kullanılabilecek tekniklerin başında geldiği savunulmaktadır.

6. MOTORUN PERFORMANS VE EMİSYONUNUN NOKTASAL DEĞERLER YERİNE ARALIKSAL OLARAK İLERİ VE TERS YÖNLÜ MODELLEMESİ

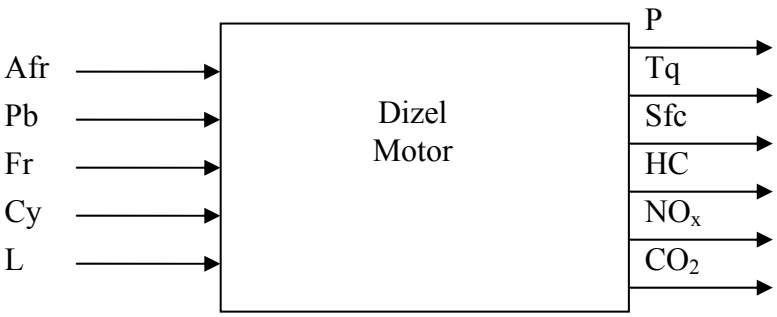
6.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde İleri ve Ters Yönlü Aralıksal Modelleme

Bölüm 4 ve bölüm 5'te sayısal analiz ve YZ teknikleri ile dizel motor performans ve emisyon karakteristiğinin noktasal modellemesi üzerinde durulmuştur. Bu bölümde dizel motor deneyinden elde edilen verilere dayalı olarak gerçekleştirilen aralıksal modelleme sunulacaktır. Aralıksal modellemede amaç verilen noktasal girişlere göre ya da verilen noktasal çıkışlara göre aralıksal olarak çıkış ve veya giriş değerlerinin bulunmasıdır. Özellikle eğitim amaçlı olarak kullanılabilecek sistemle örneğin;

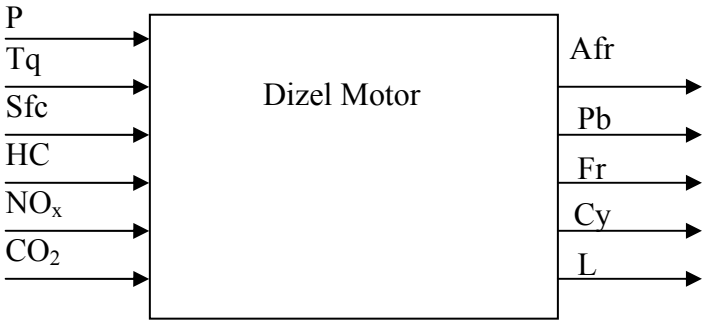
Hava akışı, Boost basıncı, benzin oranı, devir ve yük verildiğinde dizel motorun güç, tork, özgül yakıt tüketimi ve emisyon paramterleri hangi aralık değerlerinde olması gerektiğinin cevabı aranmıştır. Ya da çıkış paramterleri giriş olarak verildiğinde ve giriş parametreleri çıkış olarak kabul edilip tersten modelleme yapıldığında istenilen tork, güç, özgül yakıt tüketimi ve emisyon paramterleri için giriş paramterleri hangi aralıkta olmalıdır sorusunun cevaplanmasıda yine bu sistemle gerçekleştirilmiştir. Böylelikle okullarda eğitim amaçlı olarak ve ya araba üretim firmalarında tasarım amaçlı olarak kullanılabilecek bir sistem oluşturulmuştur.

6.1.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Tersten Aralıksal Modelleme

Bu çalışmada dizel motor için gerçekleştirilen modelleme giriş ve çıkış parametreleri Şekil 6.1'deki gibidir. Motorun verilen çıkış parametre değerlerine göre hangi optimum aralıkta giriş parametresi üretmesi gereklidir sorusuna cevap olarak hazırlanan sistem için Şekil 6.2'deki yapı kullanılmıştır. Yani girişler çıkış ve çıkışlarda sistemin girişleri olmuştur.



Şekil 6.1. 300PS E1 J1 dizel motor giriş ve çıkış parametreleri



Şekil 6.2. 300PS E1 J1 dizel motor parametrelerin terslenmesi

- Öncelikli olarak hem giriş hem de çıkış verileri kümelenmiştir (Aralıksal değerler bulmak için).
- Kümelenmiş veriler küme merkezleri baz alınarak ANFIS'te modellenmiştir.
- Modelleme sonucunda %100 doğrulukta girilen çıkış parametrelerine göre optimum aralık değerleri bulunmuştur.

- Bulanık *c*-ortalamalar ve *k*-ortalamalar kümeleme için kullanılmıştır.
- Giriş ve çıkış parametrelerinin her birisi için 13 kez bulanık *c*-ortalamalar ve *k*-ortalamalar uygulanmıştır. Bulanık *c*-ortalamalar ve *k*-ortalamaların bulunması için Matlab'da kod yazılmıştır. Her bir giriş ve çıkış parametresi için (toplam 11 parametre) 2'den 26 küme merkezine kadar kümeleme yapan *c*-ortalamalar ve *k*-ortalamalar programı 13 kez çalıştıtılmıştır.
- Bulanık *c*-ortalamalar ve *k*-ortalamalar algoritmaları başlangıçta farklı küme merkezlerinden yola çıktığı için farklı sonuçlar üretmektedir.
- En yüksek değere sahip ya da optimal kümelemenin belirlenmesi için;
- Bulanık *c*-ortalamalar için *PBM* ve *k*-ortalamalar için de siluet yöntemleri kullanılmıştır. Bunun için yine matlabda kod yazılmıştır. Her bir parametre için (*c*-ortalamalar) PBM indis değer çiftini hesaplayan kod 13 kez çalıştırılmıştır. Benzer şekilde her bir parametre için (*k*-ortalamalar) silüet indis değer çiftini hesaplayan kod 13 kez çalıştırılmıştır. Tablo 6.1 ve Tablo 6.2'de sırasıyla bulanık *c*-ortalamalar ve *k*-ortalamalar kullanılarak giriş ve çıkış parametreleri için bulunan optimum küme sayısı gösterilmektedir.

Tablo 6.1. Bulanık *c*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin optimal küme sayısının *PBM* ile belirlenmesi

Giriş	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer
P	17	10	22	12	17	9,6	22	11	**26**	**19**	16	9,9	17	9,2	21	10
Tq	23	17	26	18	**25**	**26**	26	23	20	15	26	23	25	17	20	19
Sfc	25	10	**26**	**20**	25	10	26	7,1	21	7,5	26	8,4	23	6,5	20	6,5
NO_x	14	4,9	15	4,7	10	4,5	13	4,8	**14**	**4,9**	19	4,7	10	4,5	14	5
HC	26	1,5	25	1,7	14	1,3	26	1,7	25	1,5	**24**	**1,9**	24	1,2	23	1,6
CO_2	23	9,2	9	7,2	25	9,7	8	7,1	**26**	**10**	8	7,1	26	7,4	8	7,1
Çıkış																
Fr	11	6	11	6,5	10	6,4	**24**	**7,4**	19	6,5	18	6,7	14	7,4	18	6,7
Afr	**25**	**4,9**	15	4,1	14	4,4	22	4,2	14	4,4	22	4,1	13	4,5	26	4
L	18	19	16	26	**19**	**39**	19	21	18	36	17	20	14	20	18	36
Cy	7	5,8	7	5,8	6	5,7	6	5,7	6	5,6	7	5,8	7	5,8	**7**	**5,9**
Pb	23	2,6	14	2,5	13	2,6	**26**	**2,9**	13	2,6	11	2,6	16	2,6	17	2,5

Tablo 6.2. *K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin optimal küme sayısının siluette ile belirlenmesi

Giriş	indis	değer	indis	değer	indis	Değer	indis	değer	indis	değer	indis	değer
P	4	0,80	21	0,82	4	0,80	4	0,80	22	0,81	**24**	**0,84**
Tq	20	0,89	22	0,87	4	0,86	4	0,86	**18**	**0,90**	15	0,87
Sfc	21	0,81	3	0,81	23	0,81	3	0,81	25	0,83	**26**	**0,87**
NO_x	26	0,78	2	0,77	26	0,77	2	0,77	**24**	**0,79**	2	0,77
HC	3	0,87	**4**	**0,88**	3	0,87	17	0,85	3	0,87	3	0,87
CO_2	23	0,82	24	0,84	25	0,82	22	0,81	23	0,84	**25**	**0,84**
Çıkış												
Fr	4	0,79	4	0,79	4	0,79	4	0,79	**4**	**0,79**	4	0,79
Afr	25	0,80	24	0,83	**25**	**0,86**	26	0,83	26	0,81	24	0,85
L	4	0,87	4	0,87	4	0,87	2	0,86	**4**	**0,87**	4	0,87
Cy	2	0,76	2	0,76	2	0,76	**2**	**0,76**	2	0,76	2	0,76
Pb	**4**	**0,80**	2	0,79	4	0,80	4	0,80	4	0,80	4	0,80

Tablo 6.1 kullanılarak giriş ve çıkış parametreleri bulanık *c*-ortalamalar yöntemi ile Tablo 6.3'deki gibi küme merkezlerine ayrılmıştır. Tablo 6.2 kullanılarak giriş ve çıkış parametreleri *k*-ortalamalar yöntemi ile Tablo 6.4'deki gibi küme merkezlerine ayrılmıştır.

Tablo 6.3. Bulanık *c*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme merkez sayıları ve merkezleri

Parametr	CO_2(26)	Afr(25)	Cy (7)	Fr(24)	HC (24)	Yük (19)	NO_X(14)	Pb(26)	P(26)	Sfc(26)	Tq(25)
1	4,169	321,743	1057,01	10,62	30,37	29,378	213,36	157,54	42,56	200	231,23
2	4,702	379,357	1296,87	13,03	42,69	31,853	302,97	296,441	51,13	202,5	262,99
3	5,504	442,604	1547,84	14,93	48,04	36,534	365,22	382,952	54,79	206,3	383,29
4	5,931	502,943	1747,51	16,65	50,82	38,298	411,24	500,688	62,88	208,44	447,16
5	6,288	533,544	1949,96	18,7	54,42	46,094	460,1	585,188	71,57	209,71	452,75
6	6,549	579,082	2152,46	19,94	56,67	47,915	489,18	645,615	79,42	211,26	473,9
7	6,8	624,376	2354,69	20,79	61,67	51,066	521,04	667,033	89,44	212,75	490,8
8	7,015	665,523		21,41	65	55,488	563,66	715,498	95,11	213,8	498,5
9	7,181	688,021		22,67	79,63	62,901	611,55	762,707	101,3	214,21	504,2
10	7,39	721,681		23,59	80,5	68,846	674,45	807,35	104,4	215,1	520
11	7,459	762,487		24,13	82,89	72,157	719,63	827,116	109,4	216,1	526,8
12	7,5	806,135		24,7	83,26	73,624	783,65	862,515	110,9	216,7	534
13	7,668	818,232		25,59	85,25	74,058	857,04	950,471	113,9	220,6	671,39
14	7,835	862,327		26,38	86,64	74,941	944,69	966,849	118,6	222,3	680,01
15	7,993	872,978		27,15	87,45	78,397		1056,41	126	223,9	710,92
16	8,025	920,892		29,13	90,01	79,698		1110,21	127,2	229,8	736,47
17	8,12	948,926		29,99	92,31	84,699		1139,22	135,8	231,84	752,41
18	8,356	976,007		32,01	98,54	88,8		1197,37	144,4	233,1	766,6
19	8,65	1024,01		33,05	104,3	100		1242,27	152,7	235	780,09
20	8,895	1075,01		34,15	109			1286,63	158,2	237,1	801,7
21	9,335	1129,31		35,82	111,1			1342,47	165	240,9	898,34
22	9,85	1203,76		38,17	122,6			1439,18	169,3	244,4	948,91
23	10,17	1276,07		43,04	125			1572,41	180,7	247,6	995,18
24	10,47	1366,1		47,2	132			1662,19	191,9	251,62	1043,6
25	11,46	1515,11						1710,22	208,2	258,93	1068,4
26	12,13							1319,3	219,7	271,4	

Tablo 6.4. *K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme sayısı ve merkezleri

Parametr	CO_2(25)	Afr(25)	Cy (2)	Fr(4)	HC (4)	Yük (4)	NO_X(24)	Pb(4)	P(24)	Sfc(21)	Tq(20)
1	4,065	283,9	1373,08	13,58	43,6	41,017	186,28	374,651	40,2	199,2	229
2	4,21	322,9	2100	23,3	55,87	71,625	248,12	800,713	46	200,6	248,4
3	4,395	341,6		33,7	88,18	82,9	291,64	1212,27	50,3	201,9	265,25
4	4,723	382,65		45,03	121,8	100	316,07	1613,41	52,13	202,25	383,3
5	5,44	442,333					341,41		54,53	203,3	449,27
6	5,54	502,9					370,96		56,2	203,7	491,85
7	5,74	532,233					416,71		62,9	205,1	530,97
8	6,015	570,9					461,62		71,55	205,5	673,5
9	6,31	620,6					484,84		79,2	206,53	710,9
10	6,55	625,1					502,41		87,25	206,9	745,6
11	6,8	625,9					518,71		95,15	208,55	773,4
12	7,13	679,967					538,13		104	209,7	801,17
13	7,39	718					561,83		111,1	211,26	802,23
14	7,473	762,433					596,61		123,9	212,75	894,45
15	7,675	805,8					628,97		141,5	214,07	906,6
16	7,84	817,4					636,55		152,6	215,1	948,3
17	8,038	869,4					670,44		158,3	216,5	981,4
18	8,32	941,675					687,12		164,9	222,27	1001,1
19	8,39	1039,45					711,38		169,3	233,12	1047,2
20	8,65	1129,97					753,51		180,7	246,13	1068,8
21	8,895	1203,6					797,92		191,6	263,03	
22	9,507	1275,35					849,53		207,9		
23	10,41	1355,5					916,33		218,5		
24	11,47	1447,9					965,11		224,3		
25	12,13	1549,6									

Her biri 54 noktadan oluşan giriş ve çıkış parametreleri için noktaların ait oldukları küme merkezlerleri belirlenmiştir. Bulanık c-ortalamalar yöntemi için Tablo 6.3'deki *k*-ortalamalar içinde Tablo 6.4'deki değerler kullanılmıştır. CO_2 için bulanık *c*-ortalamalar yöntemi ile oluşturulan yeni noktalar Tablo 6.5'deki gibidir. Talo 6.6'da ise *k*-ortalamalar yöntemi ile oluşturulan CO_2 veri kümesi görülmektedir.

Tablo 6.5. CO_2 için 26 küme merkezinden oluşan yeni set (bulanık *c*-ortalamalar) ve orijinal set

CO_2 (bulanık c-ortalamalar) veri kümesi	CO_2 orijinal veri kümesi
7,459384	11,63
7,500404	12,27
7,66848	11,99
7,835341	11,3
8,02512	10,43
8,355751	9,85
8,649956	9,32
8,895134	8,92
9,335061	8,65
9,850384	8,32
10,46595	8,03
11,4585	7,84
12,13387	7,66
12,13387	7,5
11,4585	7,47
6,549004	6,52
6,549004	6,58
6,79962	10,46
7,014636	6,8
7,181358	10,17
7,459384	7,01
7,66848	9,35
7,992993	7,2
8,355751	8,87
8,895134	7,73
9,335061	7,99
10,17122	8,39
10,46595	10,54
10,46595	7,45
10,46595	10,44
5,503503	5,44
5,503503	5,54
5,9313	5,74
5,9313	5,94
5,9313	6,09
6,287515	6,55
6,549004	7,68
6,79962	6,8
7,181358	7,39
7,389764	7,12
7,66848	8,01
8,02512	6,31

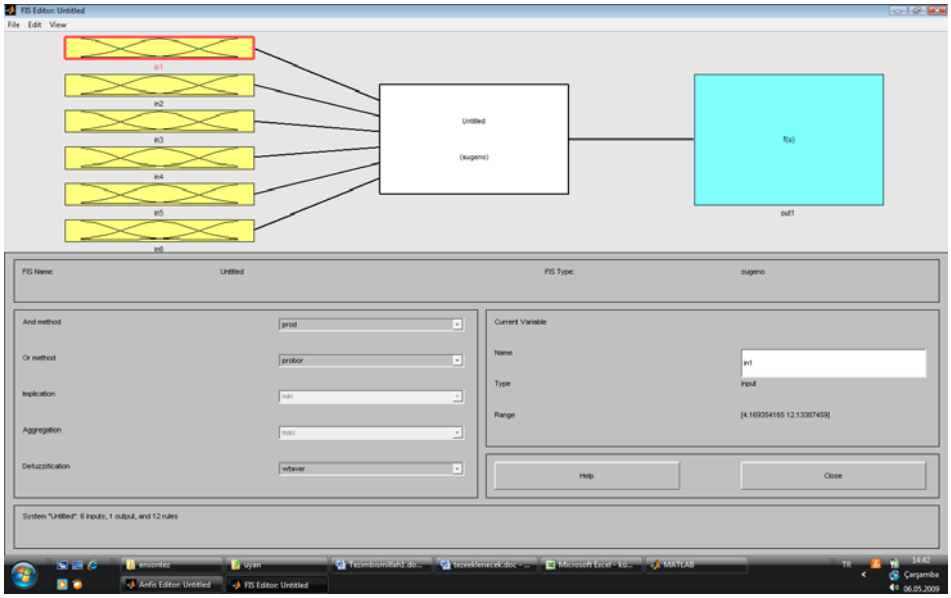
8,120072	8,12
7,66848	7,63
7,181358	7,19
4,169354	4,04
4,169354	4,09
4,169354	4,21
4,169354	4,34
4,701738	4,45
4,701738	4,7
4,701738	4,59
4,701738	4,83
4,701738	4,77

Tablo 6.6. CO_2 için 25 küme merkezinden oluşan yeni set (*k*-ortalamalar) ve orijinal set

CO_2 (k-ortalamalar) veri kümesi	CO_2 orijinal veri kümesi
7,473333	11,63
7,473333	12,27
7,675	11,99
7,84	11,3
8,0375	10,43
8,32	9,85
8,65	9,32
8,895	8,92
9,506667	8,65
9,506667	8,32
10,408	8,03
11,465	7,84
12,13	7,66
12,13	7,5
11,465	7,47
6,55	6,52
6,55	6,58
6,8	10,46
7,13	6,8
7,13	10,17
7,473333	7,01
7,675	9,35
8,0375	7,2
8,39	8,87
8,895	7,73
9,506667	7,99

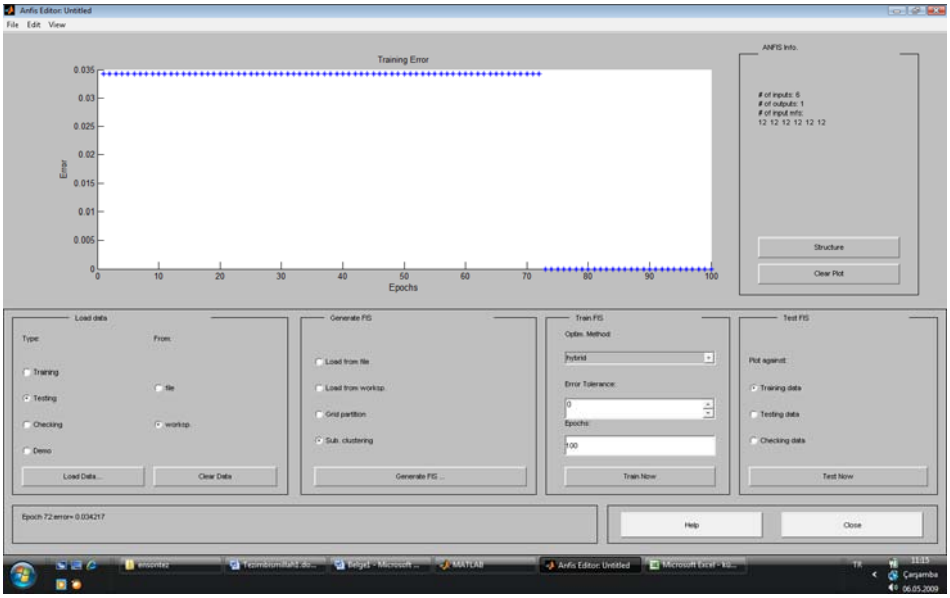
10,408	8,39
10,408	10,54
10,408	7,45
10,408	10,44
5,44	5,44
5,54	5,54
5,74	5,74
6,015	5,94
6,015	6,09
6,31	6,55
6,55	7,68
6,8	6,8
7,13	7,39
7,39	7,12
7,675	8,01
8,0375	6,31
8,0375	8,12
7,675	7,63
7,13	7,19
4,065	4,04
4,065	4,09
4,21	4,21
4,395	4,34
4,395	4,45
4,7225	4,7
4,7225	4,59
4,7225	4,83
4,7225	4,77

Tüm giriş ve çıkış parametreleri için bulanık *c*-ortalamalara ve *k*-ortalamalara göre yeni veri setleri oluşturulduktan sonra her bir çıkış parametresi için bulanık c-ortalamalar ve k-ortalamalar için 2 adet olmak üzere toplam 10 adet ANFIS topolojisi hazırlanmıştır. Her bir çıkış parametresi için 41 adet küme merkezinden oluşan eğitim seti 13 küme merkezinden oluşan test seti ilgili ANFIS'leri eğitmek ve test etmek için hazırlanmıştır. Eğitimde çaprazlama prensibini sağlama amaçlı olarak 3 adet eğitim ve test seti hazırlanmıştır. Şekil 6.3'de hava akış oranı (Afr) çıkışı için bulanık *c*-ortalamalar yönteminden elde edilen ve 25 küme merkezini kullanarak oluşturulan yeni veri setinde sınıflandırma yapmak üzere yaratılan ANFIS gösterilmektedir.

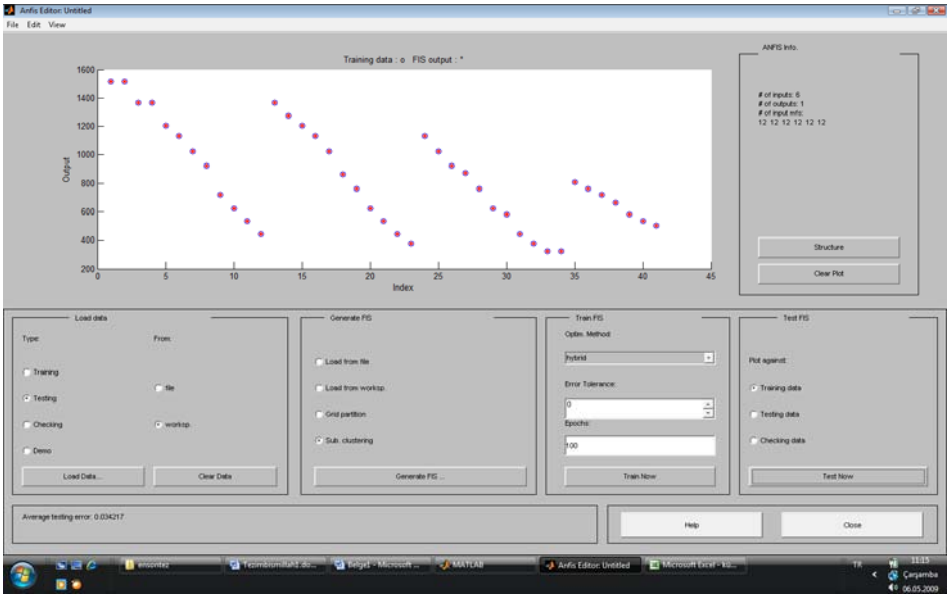


Şekil 6.3. Afr bulanık *c*-ortalamaları kullanarak oluşturulan ANFIS

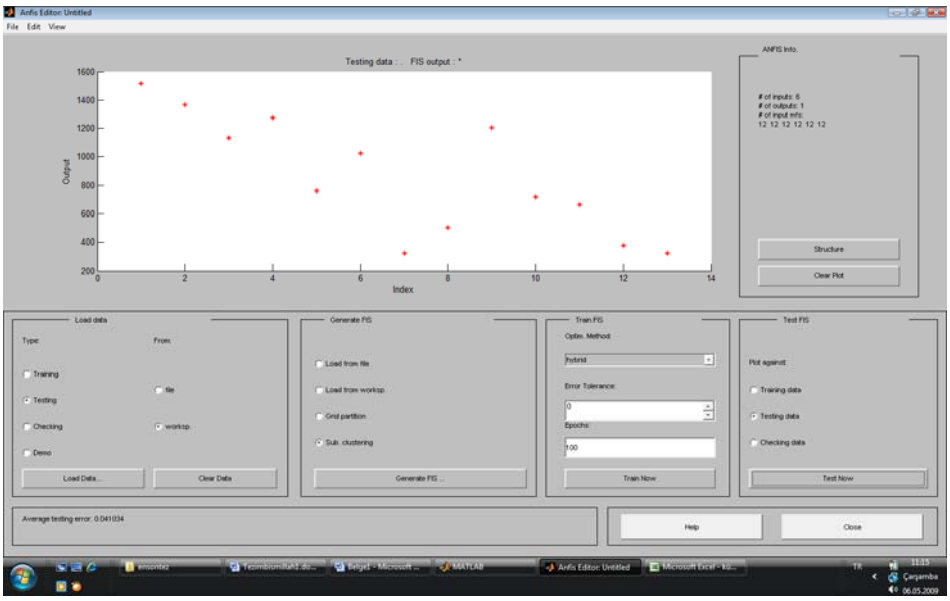
Şekil 6.3'den görüleceği üzere 6 giriş ve tek çıkışlı Sugeno çıkarım mekanizmasını kullanan ANFIS topolojisi hava akış oranı (afr) için yaratılmıştır. 3 ayrı eğitim ve test kümesi sırasıyla bu topoloji üzerinde eğitim ve test amaçlı olarak kullanılmıştır. Şekil 6.4 eğitim esnasından, Şekil 6.5 eğitim sonucu eğitim seti ile ANFIS çıkış setinin karşılaştırılmasından ve Şekil 6.6 ise test amaçlı kullanılan veriler ve ANFIS'ın ürettiği çıkış verilerinin karşılaştırılmasından oluşmaktadır. Bu set için ortalama eğitim ve test hatası sırasıyla 0,034217 ve 0,041034 olduğundan Şekil 6.5 ve Şekil 6.6'de hem eğitim hem de test seti kümelerinin ANFIS çıkış kümeleriyle örtüştüğü gözlenmektedir.



Şekil 6.4. Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS eğitiminden bir görüntü



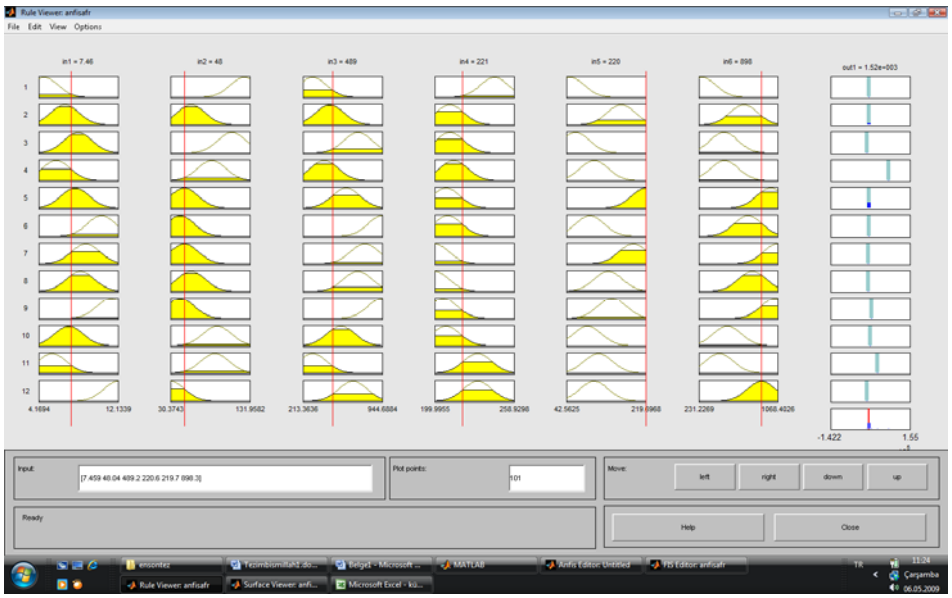
Şekil 6.5. Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS eğitimi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması



Şekil 6.6. Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS testi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması

Hava akış oranı (afr) için yaratılan bu topoloji için oluşturulan kurallar ve bu kuralları kullanarak çıkış elde edilecek ara yüz ise Şekil 6.7'deki gibidir. Bu set için 12 adet üyelik fonksiyonu ve kural oluşturulmuştur. Altı giriş için sırasıyla 7,459384314 48,03906668 489,1802692 220,5992585 219,6967565 898,339177 değerleri girildiğinde ANFIS tarafından hesaplanan hava akış oranı (afr) değeri 1520 olarak hesaplanmıştır. Bu değer orijinal veri kümesinde aynı girişler için 1515.1'dir. Afr için 25 küme merkezinden birisi olan ve Tablo 3'den de görüleceği üzere kendisine en yakın küme merkezi olarak 1366.1' e sahip olan 1515.1 küme merkezi 1520 olarak ANFIS tarafından $3x10^{-3}$ hatayla bulunmuştur. Dolayısıyla 6 adet giriş küme merkezine dahil olan noktalar için (aralıksal modelleme) 1515.1 küme merkezine dahil olan noktalar doğru olarak kestirilmiştir. Burada her bir küme merkezinin bulanık c-ortalamalar yöntemiyle elde edildiğini hatırlatmakta yarar vardır. Motor deneylerinden elde edilen veriler bu yöntem ile eğitim ve test setinde ait oldukları küme merkezi tarafından temsil edilmektedir. Normalde 54 farklı noktadan oluşan hava akış oranı eğitim seti ve test setinde yine 54 noktadan oluşmakta olup bu noktaların alabileceği değerler ise sadece 25 adettir. Çünkü

bulanık c-ortalamalar yöntemi ile 25 adet farklı kümeleme merkezi bulunmuştur. Dolayısıyla küme merkezlerinden oluşan girişlere göre ANFIS tarafından doğru çıkış küme merkezinin bulunması o kümelere ait noktasal değer aralıklarının doğru bulunması anlamındadır. Farklı girişler içinde denemeler yapılmış ve tümünde 10^{-3} katlarında hata payıyla doğru çıkış küme merkezleri elde edilmiştir. Zaten ortalama test hatasının Tablo 6.7'den de görüleceği üzere düşük değer de olması tüm giriş test küme merkezlerine karşılık doğru çıkış küme merkezinin bulunması anlamındadır.



Şekil 6.7. Bulanık c-ortalamalar ile elde edilen afr çıkış parametresinin ANFIS kural ve sonuç ara yüz ekranı

Benzer şekilde diğer 4 çıkış içinde bulanık c-ortalamalar yöntemi ile elde edilen küme merkezlerini kullanarak oluşturulan eğitim ve test setleri her bir çıkış parametresi için oluşturulan ANFIS eğitim ve testinde kullanılmış ve sonuçlar Tablo 6.7'de sunulmuştur. Bulanık *c*-ortalamalar sonucu elde edilen küme merkezleri kullanılarak eğitilen her bir çıkış parametresi ANFIS topolojisinde 3 ayrı test seti için ortalama doğru aralık değerleri, eğitim hatası, test hatası ve epok sayısı Tablo 6.7'de sunulmuştur.

Tablo 6.7 300PS E1 J1 dizel motorun Bulanık *c*-ortalamalar ve ANFIS ile tersten modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Ortalama Eğitim Hatası (41 nokta)	Ortalama Test Hatası (13 nokta)	Doğru aralık tahmin sayısı
Afr (25)	300	14	0,076	0,9	13
Fr (24)	300	14	0, 0029	0,60	13
Cy (7)	300	15	0,1309	1	13
L (19)	300	15	0,0066	0,104	13
Pb (26)	300	16	0,0356	1	13

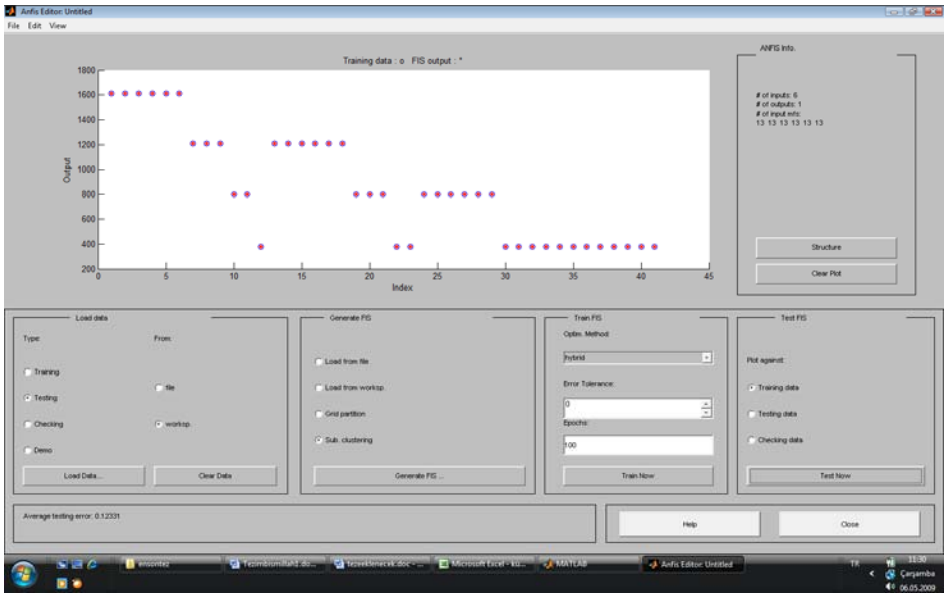
K-ortalamalar kullanılarak elde edilen küme merkezleri kullanılarak bulanık c-ortalamalar ve ANFIS için yapılan çalışmaların aynısı gerçekleştirilmiştir. 5 adet çıkış için ANFIS'deki epok sayısı, üyelik sayısı, ortalama eğitim ve test hatası (3 ayrı eğitim ve test seti için) ve doğru aralık tahmin sayısı Tablo 6.8'de sunulmuştur.

Tablo 6.7. ve Tablo 6.8'den görüldüğü üzere Bulanık *c*-ortalamalar ve ANFIS'in birlikte kullanıldığı metot 3 ayrı test verisinin hepsi için 13 test verisinin hepsini doğru kümelemiştir. Buda verilen motor performans ve emisyon çıkış değerlerine karşılık girişlerin hangi optimum aralıkta olması gerektiğinin %100 başarı ile bulunması demektir. Tablo 6.8'den de görüleceği üzere *k*-ortalamalar ve ANFIS kombinasyonu sonucu sadece hava akış oranı (afr) değişkeni için 13 doğru aralık tahmini gerçekleşmiş, diğer çıkış parametreleri için bu değer 13'ün altında kalmıştır.

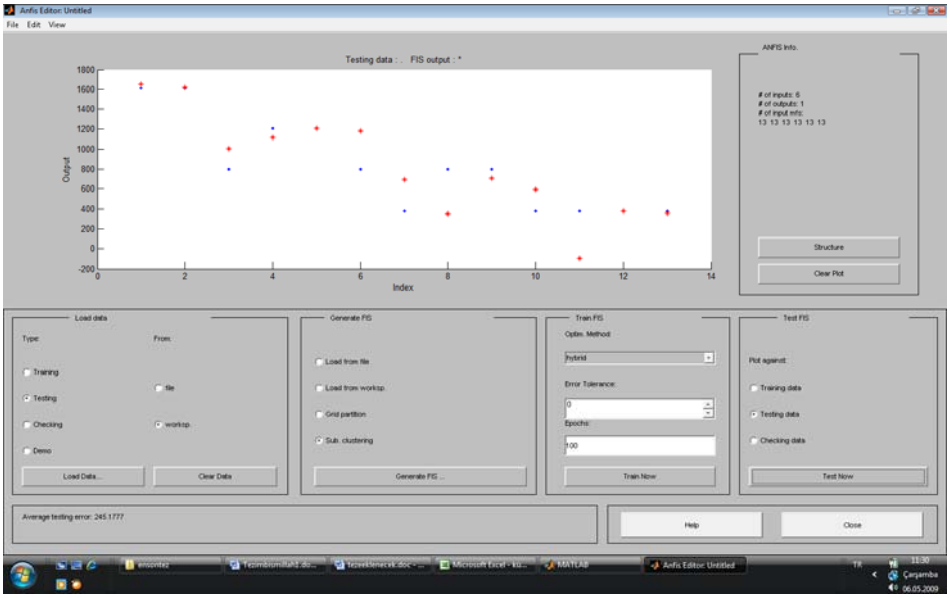
Tablo 6.8. 300PS E1 J1 dizel motorun *K*-ortalamalar ve ANFIS ile tersten modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Ortalama Eğitim Hatası (41 nokta)	Ortalama Test Hatası (13 nokta)	Doğru aralık tahmin sayısı
Afr (25)	300	16	0,0351	4,7	13
Fr (4)	300	13	0,001	4,15	11
Cy (2)	300	13	1,09	1549	6
L (4)	300	13	0,006	13,21	12
Pb (4)	300	13	0,146	452,338	7

Tablo 6.8'de sunulan boost basıncı (Pb) için eğitim seti 1 için eğitim ve test sonucu Şekil 6.8 ve Şekil 6.9'da sunulmuştur. Şekil 6.8'den görüleceği üzere eğitim verileri ortalama hata 0.12331 olup ANFIS sonuçları eğitim verileri ile örtüşmektedir. Fakat Şekil 6.9'dan görüleceği üzere test hatası ortalama test hatası 245.177 olup ANFIS çıktıları test verilerinden önemli oranda sapmaktadır.



Şekil 6.8. K-ortalamalar ve ANFIS ile Pb parametresi için eğitim seti 1 eğitim sonuçları



Şekil 6.9. K-ortalamalar ve ANFIS ile Pb parametresi için test seti 1 test sonuçları

6.1.2. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde İleri Yönlü Aralıksal Modelleme

Sistemin ileri yönlü aralıksal modellemesinde Tablo 6.3 ve Tablo 6.4'de verilen bulanık *c*-ortalamalar ve *K*-ortalamalar yöntemi ile elde edilen gruplandırma değerleri kullanılmıştır. Şekil 6.1'de sunulan sistem kullanılmıştır. Tersten modelleme için gerçekleştirilen işlemlerin aynısı yapılmıştır. Tek fark ise girşilerle çıkışların yer değiştirmesidir. Bulanık *c*-ortalamalar sonucu elde edilen küme merkezleri kullanılarak eğitilen (3 ayrı eğitim ve test seti) ANFIS'de 13 test noktası için elde edilen ortalama doğru aralık değerleri, eğitim hatası, ortalama test hatası ve epok sayısı Tablo 6.9'da *K*-ortalamalar kullanılarak elde edilen değerlerde Tablo 6.10'da sunulmuştur. Tablo 6.9 ve Tablo 10'dan görüleceği üzere bulanık c-ortalamalar ve ANFIS yöntemi ile gerçekleştirilen modellemede 13 aralık %100 doğrulukla tahmin edilirken bu oran k-ortalamalar ve ANFIS yöntemi ile sadece CO_2 çıkış parametresinde gerçekleştirilmiş olup diğerlerinde doğru aralık değerlerinde başarısızlığa uğrama söz konusu olmuştur.

Tablo 6.9. 300PS E1 J1 dizel motorun Bulanık *c*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Ortalama Eğitim Hatası (41 nokta)	Ortalama Test Hatası (13 nokta)	Doğru aralık tahmin sayısı
Tq (25)	300	15	0,066	0,9	13
P (26)	300	15	0, 0049	0,60	13
Sfc (26)	300	16	0,1208	1	13
NO_x(14)	300	15	0,0077	0,104	13
CO_2 (26)	300	16	0,036	1	13
HC(24)	300	15	0,04	0,2	13

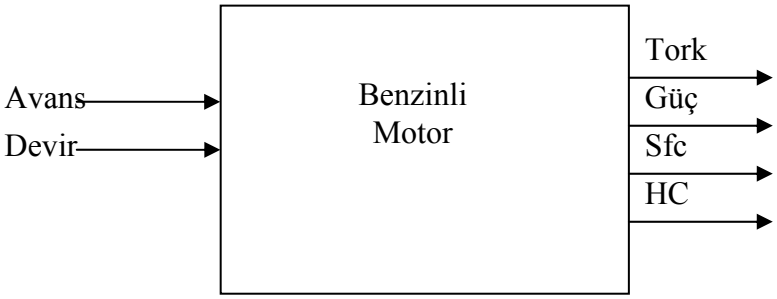
Tablo 6.10. 300PS E1 J1 dizel motorun *K*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Ortalama Eğitim Hatası (41 nokta)	Ortalama Test Hatası (13 nokta)	Doğru aralık tahmin sayısı
Tq (18)	300	12	0,085	4,7	11
P (24)	300	13	0,035	4,15	10
Sfc (26)	300	14	1,19	13	4
NOx(24)	300	13	0,059	13,21	11
CO_2 (25)	300	13	0,0023	1,2	13
HC(4)	300	12	0,146	4,5	7

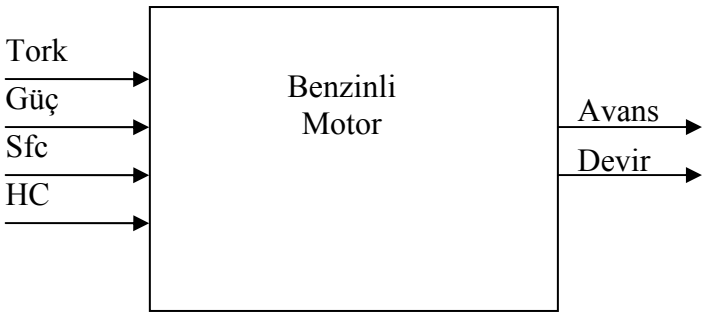
6.2. Briggs ve Stratton Vanguard Benzinli Motor Motor Veri Kümesinde İleri ve Ters Yönlü Aralıksal Modelleme

6.2.1. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Tersten Aralıksal Modelleme

Bu çalışmada benzinli motor için gerçekleştirilen modelleme giriş ve çıkış parametreleri Şekil 6.10'daki gibidir. Motorun verilen çıkış parametre değerlerine göre hangi optimum aralıkta giriş parametresi üretmesi gereklidir sorusuna cevap olarak hazırlanan sistem için Şekil 6.11'deki yapı kullanılmıştır. Yani girişler çıkış ve çıkışlarda sistemin girişleri olmuştur.



Şekil 6.10. Briggs ve Stratton Vanguard benzinli motor giriş ve çıkış parametreleri



Şekil 6.11. Briggs ve Stratton Vanguard benzinli motor parametrelerin terslenmesi

- Alt bölüm 6.1'de uygulanan yöntemler benzinli motor veri kümesi üstünde de denenmiştir. Öncelikli olarak hem giriş hem de çıkış verileri kümelenmiştir (Aralıksal değerler bulmak için). Kümelenmiş veriler küme merkezleri baz alınarak ANFIS'te modellenmiştir. En yüksek değere sahip ya da optimal kümelemenin belirlenmesi için;
- Bulanık *c*-ortalamalar için *PBM* ve *k*-ortalamalar için de siluet yöntemleri kullanılmıştır. Tablo 6.11 ve Tablo 6.12'de sırasıyla bulanık *c*-ortalamalar ve *k*-ortalamalar kullanılarak giriş ve çıkış parametreleri için bulunan optimum küme sayısı gösterilmektedir. Tablolarda indis küme sayısını değer ise küme sayısının verilere göre uygunluğunu göstermektedir. Bulanık *c*- ortalamalar metodu her bir küme sayısı için uygunluk değerini PBM yöntemi ile bulmakta ve en yüksek PBM değerine sahip kümeleme en uygun kümeleme olarak kabul edilmektedir. *K*-ortalamalar metodu ise silüet yöntemi ile en yüksek uygunluk değerine sahip kümeleme sayısını belirlemektedir. Dolayısıyla her bir parametre için Tablo 6.11 ve Tablo 6.12'de en yüksek değere sahip indis küme sayısı olarak seçilmiştir.

Tablo 6.11. Bulanık *c*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin optimal küme sayısının *PBM* ile belirlenmesi

Giriş	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	Değer
Avans	2	5,05	2	5,06	2	5,6	2	4,96	2	5,76	2	5,3	2	4,8	2	4,6
Devir	5	5,87	5	7,14	5	8,25	10	17,17	10	15,14	10	14,05	10	18,13	10	16,30
Çıkış																
HC	14	0,25	16	0,27	12	0,26	20	0,30	12	0,26	15	0,27	19	0,25	18	0,26
P	17	4,3	8	4,07	19	4,47	21	5,7	14	4,42	10	4,52	12	4,71	7	4,23
Tq	19	5,7	10	5,9	11	5,6	18	5,7	13	5,3	21	6,5	14	5,7	11	5,2
Sfc	15	9,6	21	11,48	12	9,4	11	9,96	10	9,7	13	9,7	8	9,5	14	10,6

Tablo 6.12. *K*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin optimal küme sayısının siluette ile belirlenmesi

Giriş	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	değer	indis	Değer
Avans	2	10	2	12	2	9,6	2	11	2	19	2	9,9	2	9,2	2	10
Devir	2	0,79	2	0,8	2	0,6	2	0,7	2	0,8	2	0,8	2	0,7	2	0,9
Çıkış																
HC	2	0,86	2	0,7	2	0,64	2	0,94	2	0,65	2	0,67	2	0,74	2	0,67
P	22	0,9	23	0,8	20	0,8	22	0,7	22	0,8	14	0,67	20	0,85	20	0,84
Tq	23	0,83	17	0,80	10	0,82	22	0,84	22	0,82	20	0,85	22	0,91	19	0,83
Sfc	23	0,83	23	0,85	23	0,82	23	0,84	23	0,81	23	0,86	20	0,8	23	0,85

Tablo 6.11 kullanılarak giriş ve çıkış parametreleri bulanık *c*-ortalamalar yöntemi ile Tablo 6.13'deki gibi küme merkezlerine ayrılmıştır.

Tablo 6.13. *K*-ortalamalar kullanılarak Briggs ve Stratton Vanguard Benzinli motorun giriş ve çıkış parametrelerinin küme merkez sayıları ve merkezleri

Parametr	avans(2)	Devir(10)	HC (20)	Güç-P-(21)	T(21)	Sfc (21)
1	4,726249	1228,902	49,62169	0,9769	7,78141	355,92265
2	25,27375	1565,195	64,80347	1,1778	8,57456	370,07573
3		1797,66	74,02184	1,4563	8,83341	386,76204
4		1999,457	81,11805	1,5971	8,968	396,38918
5		2199,98	91,06151	1,6403	9,07476	412,98478
6		2400,482	103,6899	1,7162	9,21248	425,12843
7		2602,099	107,3538	1,8522	9,49772	440,24038
8		2828,043	112,9542	1,9408	9,74845	446,358
9		3172,621	116,9877	2,1376	9,77289	452,96114
10		3397,805	124,9898	2,2508	9,7987	458,93438
11			129,9934	2,4535	9,85708	461,92435
12			143,9985	2,5232	10,0753	471,9057
13			150,005	2,6604	10,1392	483,64764
14			156,9916	2,7314	10,1953	488,08455
15			162,6986	2,7769	10,25	495,08206
16			169,9956	2,8307	10,3002	506,22925
17			173,0246	2,8952	10,3254	525,23199
18			175,5561	2,9974	10,6022	548,40248
19			180,8477	3,086	10,7646	574,15296
20			205,9992	3,2623	10,9742	605,35825
21				3,4885	11,314	649,95071

Tablo 6.12 kullanılarak giriş ve çıkış parametreleri *k*-ortalamalar yöntemi ile Tablo 6.14'deki gibi küme merkezlerine ayrılmıştır.

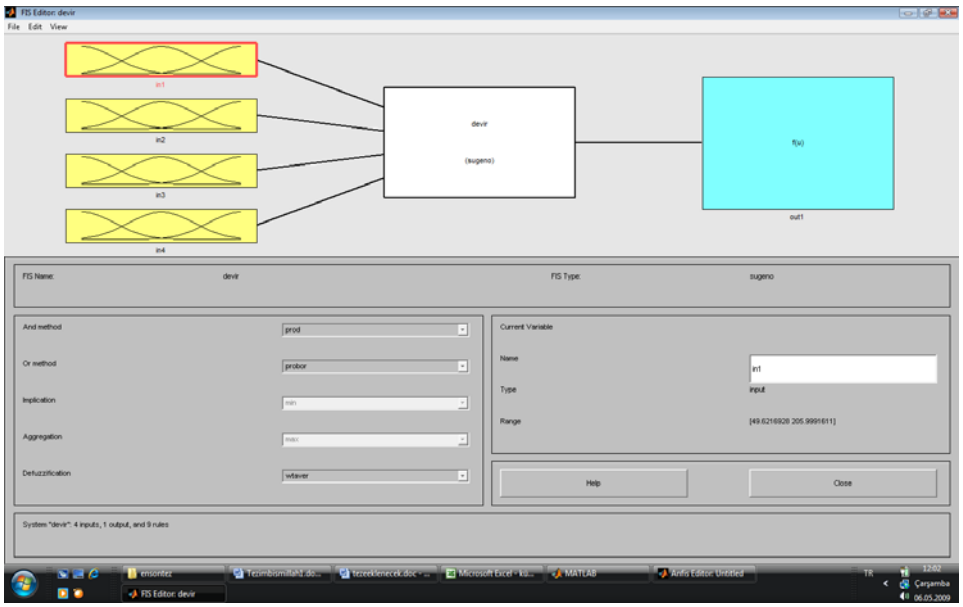
Tablo 6.14. *K*-ortalamalar kullanılarak 300PS E1 J1 dizel motorun giriş ve çıkış parametrelerinin küme sayısı ve merkezleri

Parametr	avans(2)	Devir(2)	HC (2)	Güç-P-(21)	T(21)	Sfc (21)
1	1700	5	87,86667	22	22	23
2	2900	25	168,7778	1,1215	7,78333	526,195
3				3,101333333	9,85	369,42
4				2,476666667	9,875	599,945
5				2,8335	10,995	572,25
6				3,022	10,7667	544,915
7				1,33	9,49167	488,624
8				1,717	10,25	355,3
9				1,87425	10,1375	471,9
10				1,621	8,83333	412,655
11				2,778	10,6	395,8925
12				3,262	10,075	388,1
13				2,8945	9,58	460,455
14				1,2095	10,325	506,09
15				2,986666667	9,24167	453,95
16				2,77	9,00833	387,62
17				2,804	8,5875	383,17
18				3,510666667	11,325	451,36
19				2,731333333	9,75	435,84
20				1,465666667	10,1917	521,18
21				2,16625	9,775	650

Her biri 48 noktadan oluşan giriş ve çıkış parametreleri için noktaların ait oldukları küme merkezlerleri belirlenmiştir. Bulanık c-ortalamalar yöntemi için Tablo 6.13'deki *k*-ortalamalar içinde Tablo 6.14'deki değerler kullanılmıştır.

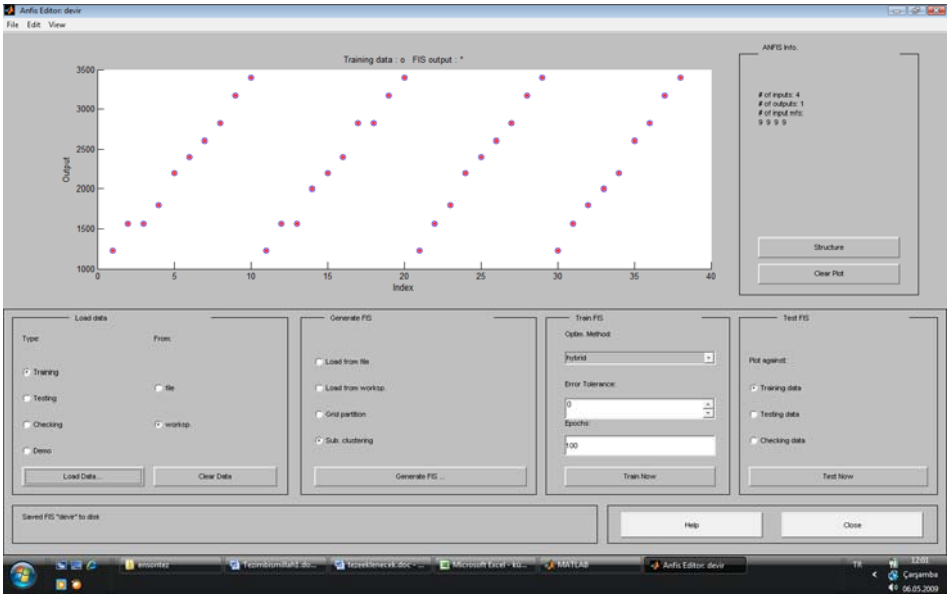
Tüm giriş ve çıkış parametreleri için bulanık *c*-ortalamalara ve *k*-ortalamalara göre yeni veri setleri oluşturulduktan sonra her bir çıkış parametresi için bulanık c-ortalamalar ve k-ortalamalar için 2 adet olmak üzere toplam 4 adet ANFIS topolojisi hazırlanmıştır. Her bir çıkış parametresi için 38 adet küme merkezinden oluşan eğitim seti 10 küme merkezinden oluşan test seti ilgili ANFIS'leri eğitmek ve test etmek için hazırlanmıştır. Eğitimde çaprazlama prensibini sağlama amaçlı olarak 3

adet eğitim ve test seti hazırlanmıştır. Şekil 6.12'de devir çıkışı için bulanık *c*-ortalamalar yönteminden elde edilen ve 10 küme merkezini kullanarak oluşturulan yeni veri setinde sınıflandırma yapmak üzere yaratılan ANFIS gösterilmektedir.

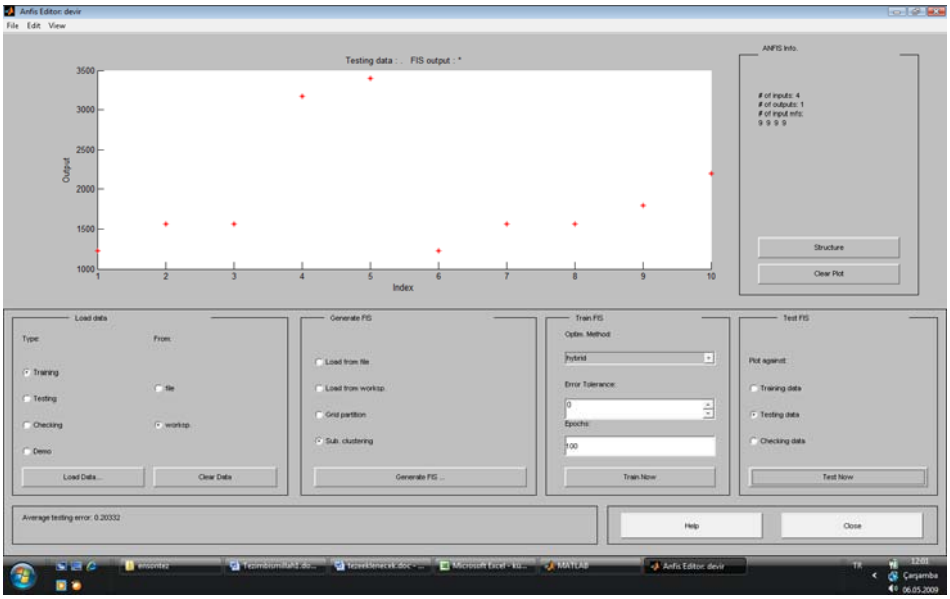


Şekil 6.12. Devir bulanık *c*-ortalamaları kullanarak oluşturulan ANFIS

Şekil 6.12'den görüleceği üzere 4 giriş ve tek çıkışlı Sugeno çıkarım mekanizmasını kullanan ANFIS topolojisi deir için yaratılmıştır. 3 ayrı eğitim ve test kümesi sırasıyla bu topoloji üzerinde eğitim ve test amaçlı olarak kullanılmıştır. Şekil 6.13 eğitim sonucu eğitim seti ile ANFIS çıkış setinin karşılaştırılmasından ve Şekil 6.14 ise test amaçlı kullanılan veriler ve ANFIS'ın ürettiği çıkış verilerinin karşılaştırılmasından oluşmaktadır. Bu set için ortalama eğitim ve test hatası sırasıyla 0,026711 ve 0,20302 olduğundan Şekil 6.14 ve Şekil 6.15'de hem eğitim hem de test seti kümelerinin ANFIS çıkış kümeleriyle örtüştüğü gözlenmektedir.



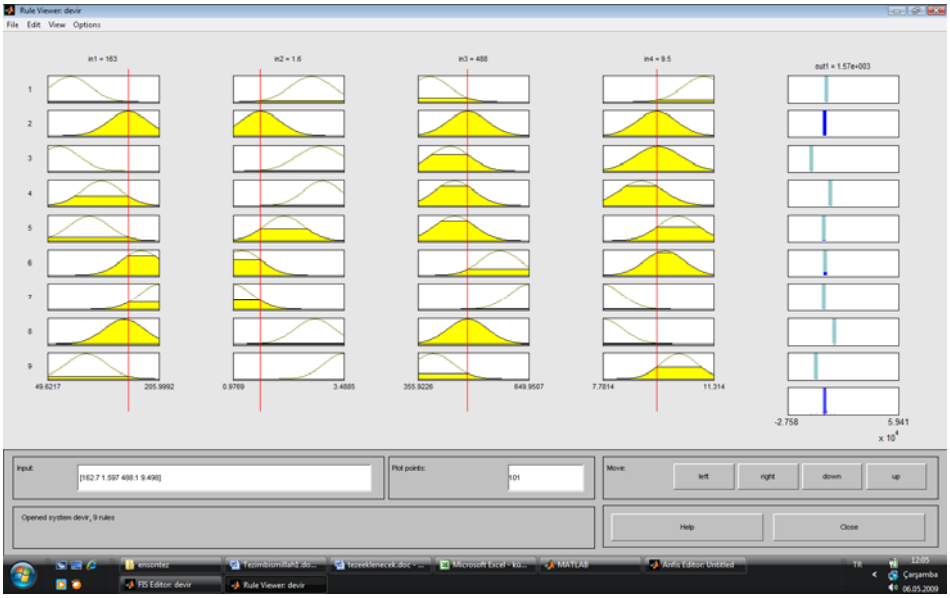
Şekil 6.13. Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS eğitimi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması



Şekil 6.14. Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS testi sonucu deneysel verilerle ANFIS çıktısının karşılaştırılması

Devir için yaratılan bu topoloji için oluşturulan kurallar ve bu kuralları kullanarak çıkış elde edilecek ara yüz ise Şekil 6.16'daki gibidir. Bu set için 9 adet üyelik fonksiyonu ve kural oluşturulmuştur. Dört giriş için sırasıyla 162,6985924

1,59709436 488,0845481 9,49771637 değerleri girildiğinde ANFIS tarafından hesaplanan devir değeri 1570 olarak hesaplanmıştır. Bu değer orijinal veri kümesinde aynı girişler için 1565,19'dir. Devir için 10 küme merkezinden birisi olan ve Tablo 13'den de görüleceği üzere kendisine en yakın küme merkezi olarak 1797.66'ya sahip olan 1565,19 küme merkezi 1570 olarak ANFIS tarafından $4x10^{-3}$ hatayla bulunmuştur. Dolayısıyla dört adet giriş küme merkezine dahil olan noktalar için (aralıksal modelleme) 1565.19 küme merkezine dahil olan noktalar doğru olarak kestirilmiştir. Burada her bir küme merkezinin bulanık c-ortalamalar yöntemiyle elde edildiğini hatırlatmakta yarar vardır. Motor deneylerinden elde edilen veriler bu yöntem ile eğitim ve test setinde ait oldukları küme merkezi tarafından temsil edilmektedir. Normalde 48 farklı noktadan oluşan hava akış oranı eğitim seti ve test setinde yine 48 noktadan oluşmakta olup bu noktaların alabileceği değerler ise sadece 10 adettir. Çünkü bulanık c-ortalamalar yöntemi ile 10 adet farklı kümeleme merkezi bulunmuştur. Dolayısıyla küme merkezlerinden oluşan girişlere göre ANFIS tarafından doğru çıkış küme merkezinin bulunması o kümelere ait noktasal değer aralıklarının doğru bulunması anlamındadır. Farklı girişler içinde denemeler yapılmış ve tümünde 10^{-3} katlarında hata payıyla doğru çıkış küme merkezleri elde edilmiştir. Zaten ortalama test hatasının Tablo 6.15'den de görüleceği üzere düşük değer de olması tüm giriş test küme merkezlerine karşılık doğru çıkış küme merkezinin bulunması anlamındadır.



Şekil 6.15. Bulanık c-ortalamalar ile elde edilen devir çıkış parametresinin ANFIS kural ve sonuç ara yüz ekranı

Benzer şekilde diğer çıkış (avans) içinde bulanık c-ortalamalar yöntemi ile elde edilen küme merkezlerini kullanarak oluşturulan eğitim ve test setleri her bir çıkış parametresi için oluşturulan ANFIS eğitim ve testinde kullanılmış ve sonuçlar Tablo 6.15'de sunulmuştur. Bulanık *c*-ortalamalar sonucu elde edilen küme merkezleri kullanılarak eğitilen her bir çıkış parametresi ANFIS topolojisinde 3 ayrı test seti için ortalama doğru aralık değerleri, eğitim hatası, test hatası ve epok sayısı Tablo 6.15'de sunulmuştur.

K-ortalamalar kullanılarak elde edilen küme merkezleri kullanılarak bulanık c-ortalamalar ve ANFIS için yapılan çalışmaların aynısı gerçekleştirilmiştir. 2 adet çıkış için ANFIS'deki epok sayısı, üyelik sayısı, ortalama eğitim ve test hatası (3 ayrı eğitim ve test seti için) ve doğru aralık tahmin sayısı Tablo 6.16'da sunulmuştur.

Tablo 6.15. ve Tablo 6.16'den görüldüğü üzere Bulanık *c*-ortalamalar ve ANFIS'in birlikte kullanıldığı metot 3 ayrı test verisinin hepsi için 10 test verisinin hepsini doğru kümelemiştir. Buda verilen motor performans ve emisyon çıkış değerlerine karşılık girişlerin hangi optimum aralıkta olması gerektiğinin %100 başarı ile bulunması demektir. Tablo 6.16'dan da görüleceği üzere *k*-ortalamalar ve

ANFIS kombinasyonu sonucu her iki çıkış parametresi için 10 doğru aralık tahminini gerçekleştirmemiştir.

Tablo 6.15 Briggs ve Stratton Vanguard benzinli motorun bulanık *c*-ortalamalar ve ANFIS ile geri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Eğitim Hatası (38 nokta)	Ortalama Test Hatası (10 nokta)	Doğru aralık tahmin sayısı
Avans (2)	300	11	0,026711	0,05	10
Devir (10)	300	8	0,35657	0,2032	10

Tablo 6.16. Briggs ve Stratton Vanguard benzinli motorun *k*-ortalamalar ve ANFIS ile geri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Eğitim Hatası (38 nokta)	Ortalama Test Hatası (10 nokta)	Doğru aralık tahmin sayısı
Avans (2)	300	10	0,076	0,9	7
Devir (2)	300	10	111	120	5

6.2.2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde İleri Yönlü Aralıksal Modelleme

Sistemin ileri yönlü aralıksal modellemesinde Tablo 6.13 ve Tablo 6.14'de verilen bulanık *c*-ortalamalar ve *K*-ortalamalar yöntemi ile elde edilen gruplandırma değerleri kullanılmıştır. Şekil 6.10'da sunulan sistem kullanılmıştır. Tersten modelleme için gerçekleştirilen işlemlerin aynısı yapılmıştır. Tek fark ise girşilerle

çıkışların yer değiştirmesidir. Bulanık *c*-ortalamalar sonucu elde edilen küme merkezleri kullanılarak eğitilen (3 ayrı eğitim ve test seti) ANFIS'de 10 test noktası için elde edilen ortalama doğru aralık değerleri, eğitim hatası, ortalama test hatası ve epok sayısı Tablo 6.17'de *K*-ortalamalar kullanılarak elde edilen değerlerde Tablo 6.18'de sunulmuştur. Tablo 6.17 ve Tablo 18'den görüleceği üzere bulanık c-ortalamalar ve ANFIS yöntemi ile gerçekleştirilen modellemede 10 aralık %100 doğrulukla tahmin edilirken bu oran k-ortalamalar ve ANFIS yöntemi ile hiçbir çıkış parametresinde gerçekleştirilememiştir.

Tablo 6.17. Briggs ve Stratton Vanguard benzinli motorun bulanık *c*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Eğitim Hatası (38 nokta)	Ortalama Test Hatası (10 nokta)	Doğru aralık tahmin sayısı
HC (20)	300	6	0,002	0,01	10
P (21)	300	8	0,012	0,2	10
T (21)	300	8	0,023	0,27	10
Sfc(21)	300	7	0,04	0,2	10

Tablo 6.18. Briggs ve Stratton Vanguard benzinli motorun *k*-ortalamalar ve ANFIS ile ileri yönlü aralıksal modelleme sonuçları

Çıkış Değişkeni	Epok sayısı	Üyelik sayısı	Eğitim Hatası (38 nokta)	Ortalama Test Hatası (10 nokta)	Doğru aralık tahmin sayısı
HC (2)	300	7	32,6	36	1
P (22)	300	7	0,3667	25	1
T (22)	300	7	0, 80368	4,8	2
Sfc (23)	300	7	52,02	56	5

SONUÇ: Dizel ve benzinli motorun ileri ve ters yönlü optimum aralıksal olarak modellenmesi daha önce hiç yapılmamıştır. Bulanık *c*-ortalamalar ve ANFIS yöntemi ile gerçekleştirilen aralıksal modelleme ile dizel motor ve benzinli motor için çıkışların %100 doğrulukta hangi aralığa ait olması gerektiği hesaplanılmıştır. Öncelikle sistemin giriş parametreleri için verilen noktasal değerler bulanık *c*-ortalamalardan elde edilmiş gruplardan tabi olduğu aralığa dahil edilirler. Sonrasında ANFIS kullanılarak oluşturulan modelleme mekanizmasınca bu aralıklar kullanılarak giriş değerlerine karşılık gelen çıkış değerlerinin hangi optimum aralıkta olması gerektiği hesaplanır. Bu sayede modelleme amaçlı olarak kullanılan bu sistem içten yanmalı motorlar üzerinde çalışan araştırmacılar, öğrenciler ve diğer ilgili alan insanları için verilen çıkış motor parametre değerlerine karşılık girişlerin hangi optimum aralıkta olması yada verilen motor giriş parametrelerine göre çıkışların hangi optimum aralıkta olması gerektiği konusunda üzerinde çalışılan dizel motor ve benzinli motor deney verisi için %100 doğrulukta bilgi verecektir. Literatürde aralıksal optimum modelleme daha önce hiç çalışılmamıştır.

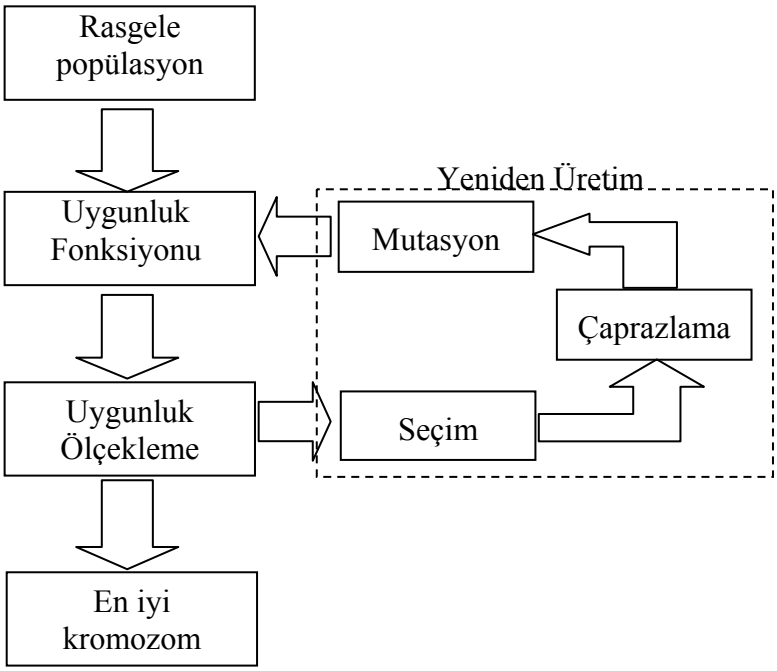
7. GENETİK ALGORİTMA İLE YAKIT OPTİMİZASYONU

7.1. Genetik Algoritmalar

Bu çalışmada geleneksel tek amaçlı GA ve çok amaçlı GA yakıt, emisyon ve güç parametreleri arasında optimizasyon sağlama amaçlı olarak kullanılmıştır. Öncelikle GA'lar hakkında teorik bilgi sunulup sonrasında tek amaçlı GA için yazılan program ve bu program üzerinde elde edilen sonuçlar her iki motor verisi için sunulacaktır. Takip eden bölümde yine her iki motor verisi üzerinde gerçekleştirilen çok amaçlı GA sonuçları sunulacaktır.

7.1.1. Tek Amaçlı Genetik Algoritmalar

Genetik algoritmalar (GA), yönlendirilmiş rasgele araştırma algoritmalarının bir türü olup, canlılardaki doğal gelişim prensibine dayanmaktadır. Daha çok karmaşık optimizasyon problemlerinin çözümünde kullanılmaktadır. Bir problemi çözebilmek için öncelikle rasgele başlangıç çözümleri belirlenir. Daha sonra bu çözümler birbiri ile eşleştirilerek performansı daha iyi çözümler üretilmeye çalışılmaktadır. Olaslıksal karakterleri ve çoklu mümkün çözümleri araştırma gibi özelliklere sahip olmaları en önemli üstünlüklerindendir. Bir GA'nın temel birimleri Şekil 7.1'de gösterilmiştir.



Şekil 7.1 Genetik algoritmanın temel birimleri

GA'da araştırma uzayında bulunan bazı çözümlerin oluşturduğu bir başlangıç yoğunluğu kullanılır. Bu başlangıç yoğunluğu her kuşakta, doğal seleksiyon ve tekrar üreme işlemleri yoluyla geliştirilir. Son kuşağın en uygun bireyi, problem için en iyi çözüm olmaktadır.

Başlangıç yoğunluğunun üretilmesini takiben, her çözümün uygunluğu veya iyiliği, seçilen uygunluk fonksiyonuna göre değerlendirilir. Uygunluk fonksiyonu, eldeki verileri dikkate alarak sonuçları değerlendirir. Seçme, çaprazlama ve mutasyon gibi genetik operatörler, elde edilen iyi çözümlerden denenmiş yeni çözümler üretmek için kullanılırlar.

Birçok seçme operatörü vardır. Bu operatörlerden ekilmiş (seeded) seçme, daha iyi çözümlere, daha fazla yaşama şansı veren yeni bir yoğunluk için çözüm anındaki yoğunluktan seçme işlemini gerçekleştirir (MMO 2007). Rasgele (random) seçme, o andaki elde edilen çözümlerden tamamen rasgele olarak yeni bir yoğunluk oluşturur. Seçkin (elite) seçme operatörü ise, her zaman en iyi çözümü bir kuşaktan diğerine kopyalar.

GA'da bir problem için birçok çözüm olabilir. GA bunlar içerisinden en iyisini bulmaya çalışır. Kromozomlar bu çözümleri gösterirler. Bir kromozomun elemanlarından her birisi çözümün bir özelliğini göstermektedir. Bunlara da gen denilir. Bir kromozomun ikili sayılarla temsil edilmesi şu şekildedir:

Kromozom 1 1101100100110110
Kromozom2 1101111000011110

Kromozom, temsil ettiği çözümle ilgili bilgi içermelidir. Her kromozom ikili (binary) bir diziden oluşur. Bu dizi içindeki bit adı verilen her bir sayı çözümün bir karakteristiğini temsil edebilir veya bir dizi bütünüyle bir sayıya işaret edebilir. Kromozomu ikili düzendeki sayılar dizisiyle ifade etmek çok tercih edilen bir temsil şeklidir, ancak bunun yerine tamsayı veya reel sayılar da kullanılabilir. İkili düzenin tercih edilmesinin sebebi basit olması ve bilgisayar tarafından daha kolay ve hızlı bir biçimde işlenebilmesidir.

Bir problemin en iyi çözümünü aramak için kullanılan ve rasgele belirlenmiş başlangıç çözüm setine çözüm havuzu denilmektedir. Problem çözüm havuzunda bulunan çözümleri (kromozomları) ikişer ikişer birleştirerek yeni çözümler üretmektir. İki kromozomdan iki adet yeni kromozom üretilir. Bir problem çözüm uzayından kaç adet kromozomun çaprazlanacağı çaprazlama oranına göre belirlenir. Kromozomların nasıl temsil edileceğine karar verildikten sonra çaprazlama yapılabilir. Çaprazlama ebeveynlerden bazı genleri alarak yeni bireyler oluşturma işlemidir.

Kromozom 1 11011 | 00100110110
Kromozom 2 11011 | 11000011110
Birey 1 11011 | 11000011110
Birey 2 11011 | 00100110110



Çaprazlama yapılacak konum rasgele seçilir (|). Oluşan yeni birey ebeveynlerin bazı özelliklerini almış ve bir bakıma ikisinin kopyası olmuştur.

Çaprazlama işlemi başka şekillerde de yapılabilir. Mesela birden fazla çaprazlama noktası seçilebilir. Daha iyi performans almak amacıyla değişik çaprazlamalar kullanılabilir. Çaprazlama neticesinde farklı çözümlere ulaşmak bazen zor olmaktadır. Yeni çözüm aramanın kolaylaştırılması ve aramanın yönünü değiştirmek amacı ile bir kromozomun bir elemanının (bir geninin) değiştirilmesi işlemidir. Bir problem havuzu içinden kaç kromozomun mutasyona uğratılacağı mutasyon oranına göre belirlenir. Mutasyon oluşan yeni bireyin bir bitini (eğer ikili düzende ifade edilmiş ise) rasgele değiştirir.

Orijinal Birey 1	*1101111000011110*
Orijinal Birey 2	*1101100100110110*
Değişmiş Birey 1	*1100111000011110*
Değişmiş Birey 2	*1101101100110110*

Belirlenen çözümlerin uygunluk derecelerinin ölçülmesini sağlayan fonksiyondur. Her problem için bir uygunluk fonksiyonunun belirlenmesi gerekir. Bu fonksiyon probleme göre değişmektedir. Birçok problemde uygunluk fonksiyonu elde edilen sonuç ile tahmin edilen sonuç arasındaki hatadan bulunmaktadır. Örneğin, bir iş sıralanması probleminde belirlenen sıraya göre işlerin tamamının bitirilmesi zamanı uygunluk fonksiyonu ölçütü olarak belirlenebilir. En kısa zamanda işi bitiren iş sırasının belirlenmesi istenir. İşlerin toplam bitirilme zamanı azaltıldığı sürece daha farklı iş sıralarının aranmasına devam eder. Sürenin en aza indirildiği noktada en iyi çözüm bulunmuş olacaktır. Sınıflandırma problemlerinde ise uyguluk fonksiyonu, sisteme verilen giriş değerlerinden elde edilen çıkış değerinin istenen çıkış değerine ne kadar yakınsadığına bakılarak belirlenebilir. İstenen değerlere en yakın değerler üreten genetik parametreler uygunluk fonksiyonunu oluşturmaktadır.

Çözüm havuzundaki kromozomlar çaprazlama ve mutasyon neticesinde üretilen yeni kromozomlar nedeni ile çoğalacaktır. Bunların arasından problem havuz büyüklüğüne göre kromozomlar seçilerek diğerleri atılır. Seçilenler ise bir sonraki nesil için yeniden çaprazlanarak gelecek çözümleri üretirler. Seçim işleminde bireylerin uygunluklarına bakılarak en iyi bireyler bir sonraki üretime dahil edilirler.

En kötü bireyler ise atılırlar. Yeniden üretim için kullanılan en yaygın yöntem Rus Ruleti yöntemidir. Bu yöntemde yeni havuz üyeleri rulet mantığı ile seçilirler. Rulet tekerleğinin rasgele döndürülmesinden sonra, bireyin bir sonraki nesil için seçilmesi, tekerlek üzerinde kapladığı alana bağlı olarak değişir. Bu yöntemde düşük uygunluğa sahip bireylere de seçilme hakkı verilir. Bir diğer seçim yöntemi olan sıralama (rank) yönteminde ise populasyonun sıralanmasının ardından kromozomların uygunluğuna bakılır. Bu yöntemde en uygun kromozomlarda değişiklik yapılmadığından seçme işlemi daha yavaş olmaktadır.

Populasyon büyüklüğünün seçimi, GA'nın performansını etkileyen en önemli rollerden birisidir. Populasyon büyüklüğünün çok küçük seçilmesi algoritmanın bir eşikte takılıp kalmasına yol açabilmektedir. Bunun tersine populasyon büyüklüğü çok büyük değerde seçilirse en iyi çözüme ulaşmak çok fazla süre alacaktır. Bu konuda yalnızca kromozom uzunluğuna bağlı bir populasyon büyüklüğü hesaplama yönteminin daha uygun olduğu önerilmektedir. Bunun yanı sıra test fonksiyonları üzerine yapılan araştırmalar sonucunda, 10-30 arası bir populasyon büyüklüğünün iyi sonuçlar verdiği belirtilmiştir .

GA içerisinde kromozomlar birbirine benzemeye başlıyorsa ve çözüm noktalarına hala ulaşılamıyorsa o halde mutasyon işlemi uygulanır. Böylece hesaplama süreci takıldığı yerden kurtulabilir. Ancak, yüksek değerde bir mutasyon olasılığı algoritmanın daha az kararlı olmasına sebep olabilir. Bir diğer deyişle mutasyon olasılığı artarsa, genetik arama rastsal bir aramaya dönüşür. Mutasyon olasılığı genellikle 0 ile 1 arasında bir değerde seçilir. Mutasyon işlemi populasyondaki genetik çeşitliliğin korunmasına yardımcı olmaktadır. Mevcut kromozomların özelliklerini birleştirerek daha uygun kromozomların elde edilmesi işlemine çaprazlama denmektedir. Kromozom çiftleri, belirli bir olasılık değeriyle çaprazlamaya uğramak üzere seçilirler. Ancak çok fazla çaprazlamanın yapılması bazı iyi kromozomların bozulma olasılığını arttırmaktadır. Çaprazlama olasılığı genellikle 0 ile 1 arasında seçilmektedir (Emel ve Taşkın 2002).

7.1.2. Çok Amaçlı Genetik Algoritmalar

Gerçek dünya problemleri genellikle birbiriyle çelişen birden fazla amacın eş zamanlı optimizasyonundan oluşur. Amaçların her birini sağlayan tek bir çözümün bulunması her zaman mümkün olmayabilir. Bu durumda problem bilgisine sahip olan karar vericiden, amaçların her biri için kabul edilebilir düzeyde olan alternatif çözümlerden seçim yapması istenir. Bu çözümlerin her birine *Pareto-Optimal Çözüm*, bu çözümlerin kümesine de *Pareto-Optimal Çözümler Kümesi* denir. Pareto-Optimal çözüm; amaçların herhangi biri için en kötü olmayan ve en azından bir amaç için diğerlerinden daha iyi olan çözümdür. Diğer bir ifadeyle çözüm kümesindeki diğer herhangi bir çözüm tarafından bastırılmamış olan çözümdür.

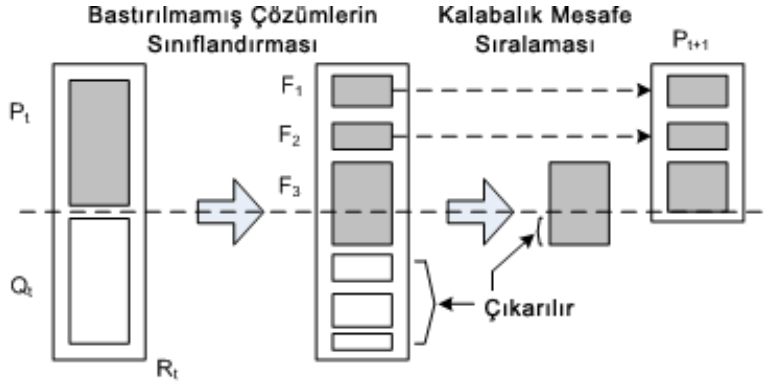
Optimizasyon problemlerinin çözümünde öncelikle doğrusal modellemeler kullanılmış, ancak bu yöntemler, her problemin çözümü için yeterli olmadığı görülmüştür. Son zamanlarda, çok amaçlı optimizasyon problemlerinin çözümünde genetik ve evrimsel algoritmalar yaygın olarak kullanılmaya başlanmıştır (Osyczka 2002, Fonseca ve arkç 1995). Çok amaçlı genetik algoritmaların performanslarını değerlendirmede Pareto yüzeyin bulunması önemli bir göstergedir.

Vektör Değerlendirmeli Genetik Algoritma (VEGA), Çok Amaçlı Genetik Algoritma (MOGA), Hücrelendirilmiş Pareto Genetik Algoritması (NPGA), Bastırılmamış Sınıflandırmalı Genetik Algoritma (NSGA), Bastırılmamış Sınıflandırmalı Genetik Algoritma II (NSGAII), Kuvvet Pareto Evrimsel Algoritma (SPEA), Kuvvet Pareto Evrimsel Algoritma 2 (SPEA2) ve Pareto Zarflama-Temelli Seçim Algoritması (PESA), çok amaçlı optimizasyon problemlerinin çözümünde kullanılan teknikler arasında yer almaktadır. Bu algoritmaların bir kısmı Zitzler ve ark. (2003) tarafından yapılan bir çalışmada birbiriyle karşılaştırılarak performansları değerlendirilmiştir. Değerlendirme sonucunda NSGA II algoritmasının en iyi sonucu verdiğini gözlemişlerdir.

Srinivas ve Deb (1994) tarafından önerilen NSGA'da popülâsyon bastırılmamışlık ilkesiyle derecelendirilir. Tüm bastırılmamış bireyler sahte uygunluk değeri ile bir kategori içinde sınıflandırılır. Kategori sayısı popülasyon

boyutuyla orantılıdır. Aynı kategorideki bireylerin hepsine aynı uygunluk değeri atanarak eşit seviyede yeniden üretilme potansiyeli sağlanır. Daha sonra popülasyonda çeşitliliği sağlamak için paylaşım metodu uygulanır. İlk yüzeydeki bireyler geçici olarak ihmal edilir ve kalan popülasyon aynı süreçten geçirilerek ikinci bastırılmamış yüzey tanımlanır. Önceki yüzeyin minimum paylaşılan sahte uygunluk değerinden daha küçük tutulan yeni bir sahte uygunluk değeri yeni yüzeydeki tüm bireylere atanır. Bu işlem popülasyondaki tüm bireyler sınıflandırılıncaya kadar devam eder.

Daha sonra Deb ve ark. (2002) Pareto-Optimal yüzeyde daha geniş bir dağılım bulabilen ve daha az bir hesaplama karmaşıklığına sahip olan, hızlı ve seçkinlikli çok amaçlı NSGA'yı (NSGA-II) geliştirdiler. Bu yaklaşımda ilk olarak rasgele P_0 ebeveyn popülâsyonu oluşturulur. Popülasyon, Pareto üstünlüklerine dayalı olarak sıralanır. Her çözümün uygunluğu, kendi bastırılmamışlık seviyesine eşit olarak atanır. Sonra, bilinen ikili turnuva seçimi, çaprazlama ve mutasyon işlemcileri, N boyutlu Q_0 popülâsyonunun bireylerini oluşturmak için ebeveyn popülâsyona uygulanır. Seçkinlik işlemi ise, önceki en iyi bastırılmamış çözümlerle mevcut popülâsyon karşılaştırılarak gerçekleştirilecektir. Bu yüzden, başlangıç jenerasyonundan sonra prosedür farklı bir şekilde işler. NSGA-II'nin çalışma prosedürü Şekil 7.2'de görülmektedir. Öncelikle, birleşik popülâsyon $R_t = P_t \cup Q_t$ oluşturulur. Bu popülâsyon 2N boyutundadır ve bastırılmamışlığa göre sıralanmalıdır. Önceki popülâsyonun tümü ve mevcut popülâsyonun bireyleri R_t ye eklendiği için, seçkinlik garantilenmiş olur. En iyi bastırılmamış küme olan F_1'e ait olan çözümler, birleşik popülâsyondaki en iyi çözümlerdir ve birleşik popülâsyondaki diğer çözümlerden daha fazla vurgulanmalıdırlar. Eğer F_1'in boyutu N'den küçükse, yeni popülâsyon P_{t+1} için F_1 kümesinin tüm üyeleri kesin olarak seçilir. P_{t+1} popülâsyonunun kalan üyeleri, oranları sırasında sonradan gelen bastırılmamış yüzeylerden seçilir. Diğer bir ifadeyle, sırasıyla önce F_2 kümesinden, sonra F_3 kümesinden çözümler alınır ve bu şekilde devam edilir. Bu işlem P_{t+1} popülâsyonu doluncaya kadar devam eder.



Şekil 7.2. NSGA II prosedürü

7.2. Yakıt Optimizasyonu

Yakıt optimizasyonu tork ve güç gibi motor verimini etki eden faktörlerde yüksek değer elde ederken emisyon değerlerinde düşük değerlere sahip olmak anlamına gelmektedir. Tüm bunları gerçekleştirirken minimal ya da optimum yakıt tüketiminin sağlanması gerekmektedir. Bu yüzden yanma odası içinde kimyasal ve ısı tepkimeleri üzerinde yapılan optimizasyon çalışmalarında elde edilen yüksek emisyon değerleri kabul edilebilir sınırlar ötesindedir.

Literatürde yakıt optimizasyon çalışmaları genellikle yanma odasında gerçekleşen ısınma ve yanmalara bağlı olarak elde edilen kısmi kimyasal ve ısıl denklemlerin matematiksel olarak optimizasyonuna dayalıdır (Hamosfakidis ve ark. 2003, Morita 1993, Nakakita ve ark. 1994, Polifke ve ark. 1998). Bu çalışmalara ek olarak Saerens ve ark (2009) dizel bir motorun dinamik olarak optimizasyonunu sağlamışlardır. Modelin iki durum değişkeni mevcuttur; motor manifoldundaki basınç ve motor devri. Kontrol girişi ise kısma vana açısıdır. Bock doğrudan çoklu vuruş metodu kullanılarak optimizasyon gerçekleştirmişlerdir. Aracın 1100 rpm den 3700 rpm'ye 30 s içinde çıkması sağlanmış ve bahsedilen metot uygulanarak

simülasyon ve ayrıca deney düzeneğinde metodun sonuçları karşılaştırılmıştır. Her iki sonuçta geleneksel EMS sistemine göre 12%'lik yakıt tasarrufu sağlanmıştır.

YZ teknikleri kullanılarak geliştirilen yakıt optimizasyonu çalışmaları literatürde oldukça az sayıdadır. (Hafner ve ark. 2000, Rajagopalan ve ark 2003). Hafner ve ark. (2000) YZ tekniklerinden BK kullanarak optimizasyon çalışması gerçekleştirmiştir. Lee ve ark (2003) bulanık kontrol sistemi ile güç ve tork değerinde %12 artış sağlamışlardır. Hiroyaşu ve arkd (2005) HIDECS olarak isimlendirilen ve dizel motor performansını modellemek için kullanılan sprey (püskürtme) analiz metodu ve çok amaçlı GA kullanarak NO_x için %60 ve yakıt tüketimi için %3'lük düşüş sağlamışlardır. Kesgin (2004) YSA ve GA kullanarak yaktı tüketiminin %3 artmasına karşın NO_x değerini uluslar arası standart değer oran 250mg/Nm3 altına indirmiştir. Alonso ve ark (2007) YSA ve GA kullanarak NO_x için %4,4 ve yakıt tüketimi için %2.9'luk azalma sağlanmıştır. Vossogi ve ark (2005) Lagrange ve NSGA kullanarak NO_x ve HC için toplamda %20'lik bir iyileştirme sağlarken yakıt tüketiminde %0.5'lik iyileştirme sağlamışlardır. Obodeh ve ark (2008) YSA ve GA kullanarak NOx, PM, CO ve özgül yakıt tüketimi için sırasıyla 39.3%, 69.2%, 39.3% ve 2.5% iyileştirme elde etmişlerdir. Kaji ve ark (2008) geliştirdikleri motor simülasyon programı ve GA kullanarak yakıtın torka göre optimizasyonunu gerçekleştirmişlerdir.

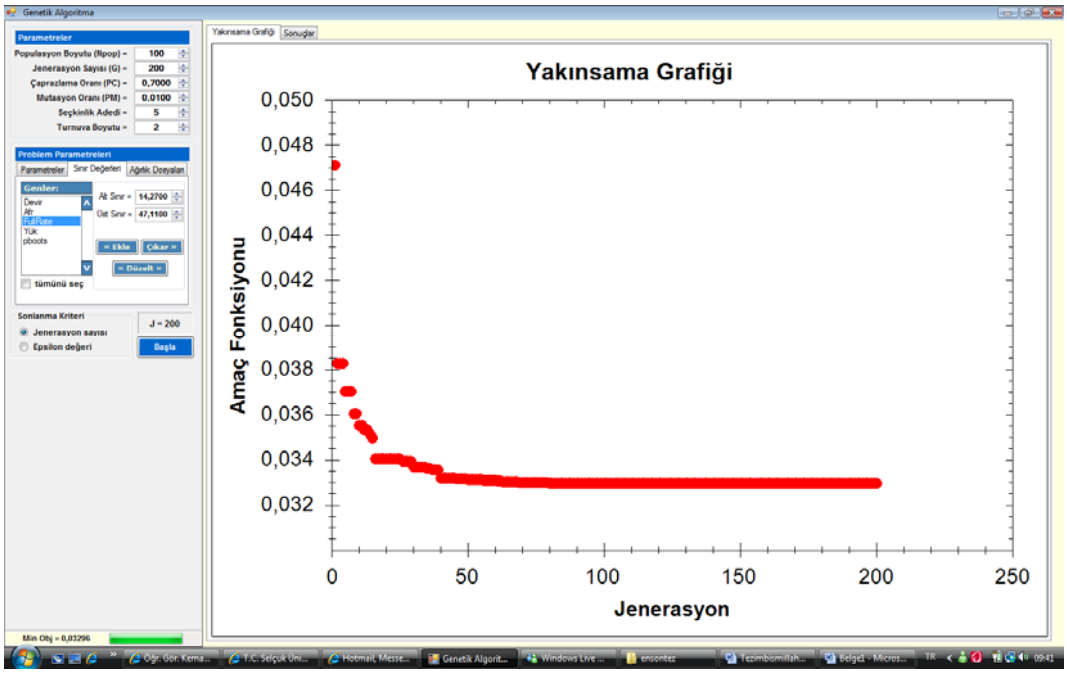
Bu çalışmada ise yakıt, tork, güç ve emisyon arasında optimizasyon tek amaçlı ve çok amaçlı GA'ların her ikiside kullanılarak gerçekleştirilmiştir. Bölüm 5.2'de sunulan YSA modellemesi her iki motor türü içinde simülasyon aracı olarak kullanılmıştır. Tek amaçlı ya da çok amaçlı GA'lar optmizasyonu gerçekleştirmek için başlangıç popülasyonuna ve sonrasında yeni nesilleri oluşturacak diğer popülasyonlara ihtiyaç duyacaktır. Bu popülasyonların üretilmesi için ya dinamik motor ölçüm ve deneyleri yapılmalı ya da motoru simüle eden yazılımlar (modelleme yazılımları) kullanılmalıdır. Motor deneylerinin her bir jenerasyon üretimi için yapılması uzun süre alacağından elde edilecek optimizasyon çalışması çok uzun sürecek ve sağlıklı sonuç alınmayacaktır. Bu yüzden Bölüm 5.2'de her iki motor verisinin modellenmesi için oluşturulan YSA'ların ağırlık değerleri ve ileri yönlü çıkış hesaplama denklemleri optimizasyon çalışmalarında simülasyon amaçlı olarak

kullanılmıştır. Böyle başlangıç popülasyonu ve diğer popülasyonların oluşturulması her iki tür GA için sağlanmıştır.

7.2.1. Tek Amaçlı GA Kullanılarak Gerçekleştirilen Yakıt Optimizasyonu

7.2.1.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Tek Amaçlı GA Uygulaması

Tek amaçlı GA kullanılarak yakıt optimizasyonunun gerçekleştirilebilmesi için Visual Studio programı ve C# programlama dili kullanılarak bir GA programı yazılmıştır. Programın ara yüzü Şekil 7.3'deki gibidir.



Şekil 7.3. Yakıt optimizasyonu için tasarlanan GA programı

Şekil 7.3'den de görüleceği üzere programda uygulanacak olan genetik algoritmanın popülasyon boyutu, jenerasyon sayısı, çaprazlama oranı, mutasyon oranı, seçkinlik adedi ve turnova boyutu parametreleri değiştirilebilmektedir.

İterasyon sonlandırması için jenerasyon sayısı ve epsilon değerinden birini seçmeye imkan kılmaktadır.

Çözülecek olan problemin parametreleri, bu parametreler için (7.1)'de kullanılan ağırlık değerleri, parametrelerin değerlerinin belirlenmesi için gerekli YSA ağırlık değerleri ve varsa problem ile ilgili sınır değerlerin girildiği ikinci bir alt menüye sahiptir.

$$J= \quad \sum_{i=1}^{n} w_i \left(\frac{\varphi_i(x)}{norm(\varphi_i(x))} \right)^2 \qquad (7.1)$$

optimizasyon için kullanılan GA uygunluk fonksiyonunu denklem (7.1)'deki gibidir. Burada;

- J uygunluk fonksiyonu,
- w_i ağırlık değerlerini,
- $\varphi_i(x)$ motor performans ve emisyon parametrelerini,
- norm($\varphi_i(x)$) normalize edilmiş performans ve emisyon parametrelerini

ifade etmektedir. Normalize değerler hesaplanırken verilen hızdaki maksimum değer kullanılmaktadır.

Denklem (7.1)'den görüleceği üzere performans ve emisyon parametrelerinin her birisi verilen hızdaki maksimum değere göre normalize edildikten sonra ağırlık ile çarpılmakta ve uygunluk fonksiyonuna dahil edilmektedir.

Program çalıştırıldığında yakınsama grafiği ve sonuçların sayısal değerlerinin bulunduğu iki ayrı pencereden seçim yapılarak sonuçların doğruluğu gözlenebilmektedir.

Çalışmada tüm çıkış parametreleri için ağırlık değerleri manuel olarak girilmektedir. Dinamik optimizasyon gerçekleştirilmesi durumunda bu ağırlık değerleri;

Navigasyon yada GPS cihazından gelen yol durumu, şehir içi yada şehirler arası araç kullanımı, hava durumu, aracın boşta veya yürüyor olması, şöfor istekleri, aracın çalışır durumda veya ilk çalışma durumunda olması gibi parametrelere bağlı

olarak hazırlanacak olan BUS ile belirlenecektir. BUS çıktısı ise sırasıyla tork ve emisyon parametrelerinin ağırlık değerleridir. Ağırlık değerlerinin belirlenmesinden sonra uygunluk fonksiyonunun minimum olduğu noktalarda bu çalışmanın giriş parametresi olan yakıt oranı (fr) değeri belirlenmiş olacaktır. Elde edilen değere göre pistona püskürtülen yakıt miktarı arttırılıp ya da azaltılacak olup yeni ölçüm değerleri hesaplanan değerler ile karşılaştırılacaktır. Örneğin şehir dışında sürüm için emisyon değerlerinin ağırlık katsayıları BUS tarafından 0.5 ve üzeri olarak bulunabilirken bu değer şehir içi kullanımda 0.5'in altında hesaplanabilinmektedir. Bir başka örnek olarak yüksek eğime sahip bir arazide istenilen tork değerinin yüksek olmasından ötürü navigasyondan gelen bilgiler ve diğer BUS giriş parametrelerine göre tork parametresinin ağırlığı yüksek olup emisyon parametrelerinin ağırlık değerleri yakıt tüketiminin artması nedeniyle düşük olacaktır. Böylelikle dinamik olarak elde edilen verilere göre istenilen tork ve emisyon parametrelerini sağlamak için gerekli optimum yakıt tüketimini BUS ve GA ile tasarlanmış olacaktır. Bu şekilde gerçekleştirilen optimizasyon çalışması dinamik olup kapalı kontrol geri besleme döngüsü ile desteklenmektedir.

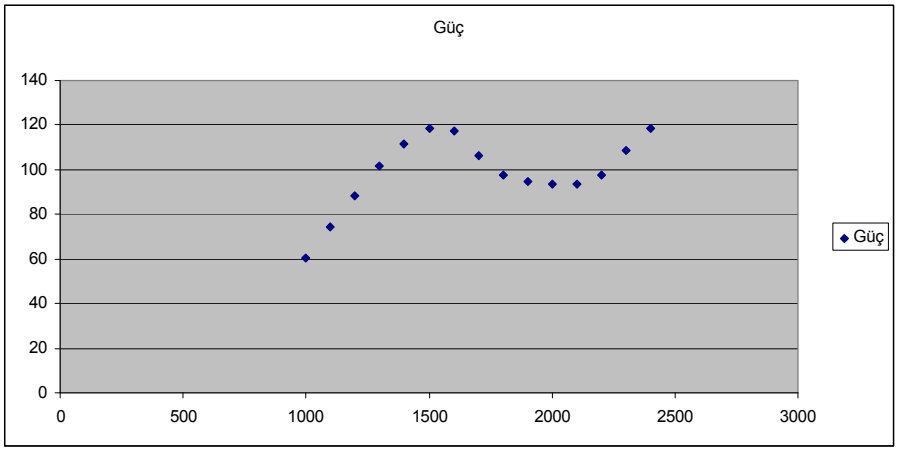
Program çalıştırılıp ağırlık dosyaları bu dizel motor için oluşturulan 5:12:1 topolojisindeki ÇKP ağırlıkları yüklendikten sonra gücün maksimum yakıt tüketiminin minimum olduğu noktaları belirlemek için sırasıyla 0,1 ve 1 katsayıları (ağırlıkları) ana pencereden güç ve sfc parametreleri için girilmiştir. Diğer tüm çıkış parametreleri için bu değer sıfır olarak alınmıştır. Yük parametresi 100 olarak seçilmiştir. Tam yük için Tablo 7.1'de özgül yakıt tüketimi ve güç için tüm devirlerde elde edilen optimum noktalar sunulmuştur. Tablo 7.2'de ise tüm devirlerde tam yük için deneysel olarak ölçülen motor verileri yer almaktadır. Özgül yakıt tüketimi (sfc) ve güç için karşılaştırma yapıldığında maksimum güç ve minimum yakıt tüketiminin elde edildiği noktalarda deneysel verilere göre özgül yakıt tüketimi %14.2 azalırken güçte %43.9 azalmaktadır. Ayrıca giriş parametrelerinden yakıt oranı (Fr) %26.4 azalmıştır. Şekil 7.4 ve Şekil 7.5'de devre göre tam yükte hesaplanan maksimum güç ve minimum yakıt tüketim grafikleri sunulurken Şekil 7.6 ve Şekil 7.7'da ilgili parametreler için deneysel motor veri grafikleri sunulmuştur..

Tablo 7.1. Tüm devirlerde tam yük için maksimum güç ve minimum yakıt tüketim noktaları

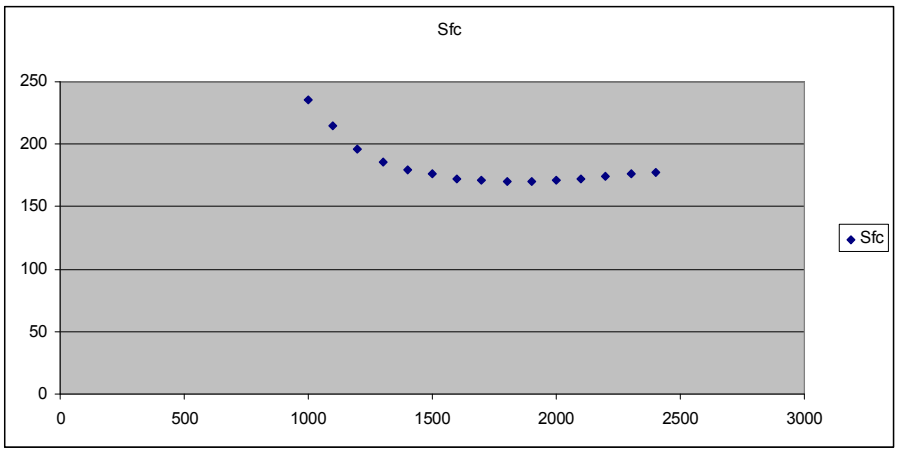
Devir	Sfc	Güç	Afr	Fr	Pboost
1000	235,5613	60,30183	283,9	20,79	421,29
1100	214,3107	74,37903	336,7	24,17	603,2
1200	196,186	88,39891	389,5	27	801,39
1300	185,3493	101,4109	445,2	29,88	966,91
1400	179,4199	111,3987	508	31,97	1110,15
1500	176,8623	118,3243	557,9	33,75	1208,59
1600	172,4501	117,1949	497,8	33,48349	1319,34
1700	170,7804	106,3428	538,6	28,0373	1438,64
1800	169,7283	97,46449	583,9	24,0243	1542,63
1900	170,2528	94,68196	625,8	22,9706	1590,04
2000	171,1469	93,54167	665,4	22,46422	1624,39
2100	172,1849	93,53859	708,9	22,72267	1658,68
2200	173,844	97,82972	754	24,92986	1672,78
2300	176,2052	108,7452	805,8	29,66649	1668,58
2400	177,8695	118,2827	874,2	33,83308	1711,52
Toplam	2742,151	1481,836	8575,6	409,692	19338,13

Tablo 7.2. Tüm devirlerde motor deneyinden elde edilen tam yük için güç, yakıt tüketimi ve diğer değerler

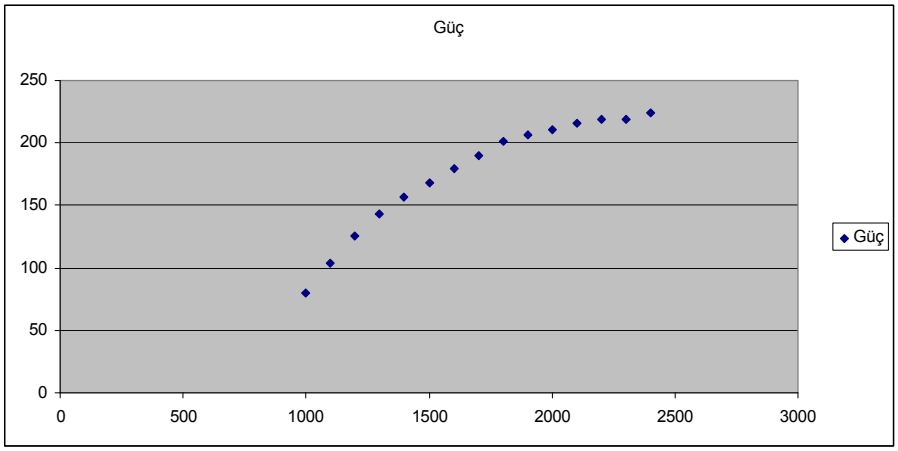
Devir	Sfc	Güç	Afr	Fr	pboost
1000	259,1	80,26	346,5	20,79	421,29
1100	233,5	103,44	431,6	24,17	603,2
1200	215,7	125,05	526,4	27	801,39
1300	208,2	143,5	626	29,88	966,91
1400	203,9	156,87	727,1	31,97	1110,15
1500	201,2	167,74	813,9	33,75	1208,59
1600	200,4	179,21	915,8	35,91	1319,34
1700	201,8	190,08	1021,3	38,37	1438,64
1800	203,5	201,47	1122,3	41	1542,63
1900	205,2	206,93	1204,1	42,46	1590,04
2000	206,9	210,92	1280,3	43,65	1624,39
2100	209,5	215,79	1359,2	45,19	1658,68
2200	212,1	218,44	1421,8	46,33	1672,78
2300	215,7	218,4	1474	47,11	1668,58
2400	220,9	224,05	1549,6	49,48	1711,52
Toplam	3197,6	2642,15	14819,9	557,06	19338,13



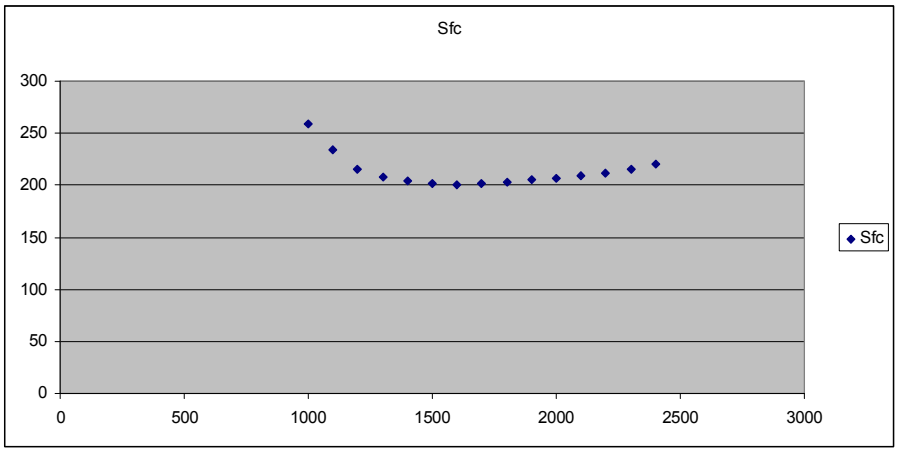
Şekil 7.4. Tam yükte tüm devirlerde minimum yakıt tüketimi için maksimum güç noktalar



Şekil 7.5. Tam yükte tüm devirlerde maksimum güç için minimum özgül yakıt yakıt tüketim noktaları



Şekil 7.6 Tam yükte tüm devirlerde güç için deneysel motor verileri



Şekil 7.7 Tam yükte tüm devirlerde özgül yakıt tüketimi için deneysel motor verileri

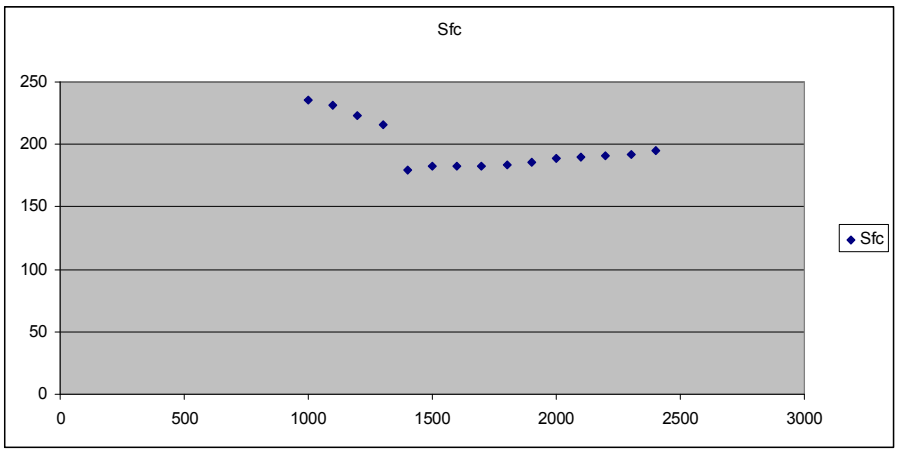
Program tekrar çalıştırılıp tam yükte yakıt tüketimi ve emisyonun minimum olduğu noktaları bulmak için sfc ve NO_x ağırlık değerleri 1 olarak girilmiştir. Optimizasyon sonucu Tablo 7.3'deki gibi değerler elde edilmiştir. Tablo 7.4'de ise deneysel motor verileri sunulmuştur. Özgül yakıt tüketimi %7.7, NO_x %8.51, güç %30, tork %4 ve afr %7.4 azalırken HC %10.5 artmıştır. Özgül yakıt tüketimindeki azalma beraberinde HC artışını getirmiştir. Tam yükte tüm devirlerde elde edilen optimum yakıt tüketimi ve NO_x grafikleri ile bu optimum değerlerde elde edilen güç, tork ve HC grafikleri Şekil 7.8 ile Şekil 7.12 arasında sunulmuştur. Görsel karşılaştırma yapılabilmesi amacıylada Şekil 7.13 ile Şekil 7.15 arasında tam yük ve tüm devirlerde deneysel olarak ölçülen NO_x , tork ve HC grafikleri sunulmuştur.

Tablo 7.3. Tüm devirlerde tam yük için minimum NO_x ve minimum yakıt tüketim noktaları

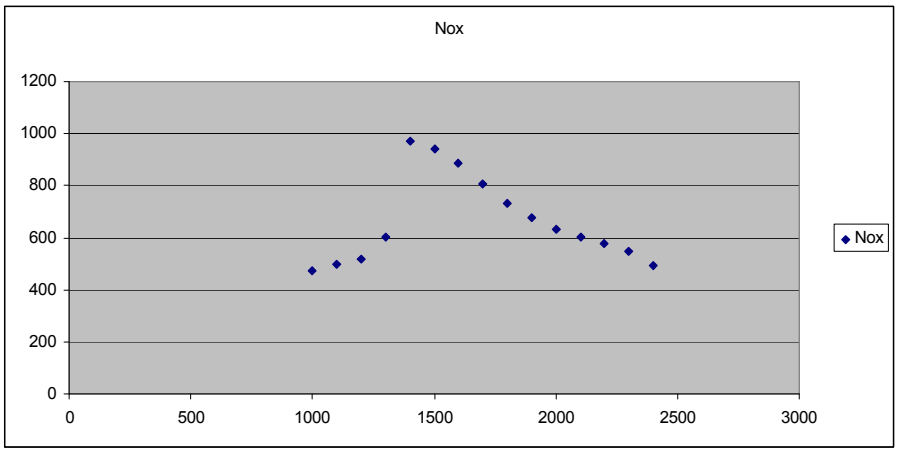
Devir	Afr	Fr	Pboost	Sfc	Nox	Tork	HC	Güç
1000	283,9	20,79	421,29	235,56	471,58	835,07	27,08	60,3
1100	336,7	11,22	603,2	231,15	495,44	845,12	88,24	47,41
1200	389,5	13,32	646,43	223,53	517,33	800,4	84,55	52,27
1300	445,2	15,08	703,2	215,79	601,18	769,38	84,95	57,19
1400	508	31,97	1110,1	179,42	972,56	1062	38,59	111,4
1500	813,9	33,75	1208,6	182,85	939,54	1041,3	44,73	124,9
1600	915,8	35,91	1319,3	182,63	887,73	1040,7	44,29	133,8
1700	1021,3	38,37	1438,6	182,87	807,06	1038,1	43,32	143,1
1800	1122,3	41	1542,6	183,85	731,16	1030,7	42,47	151,6
1900	1204,1	42,46	1590	186,01	678,42	1011,5	42,61	155,2
2000	1280,3	43,65	1624,4	188,41	633,53	985,46	42,86	157,7
2100	1325,3	45,19	1658,7	189,85	600,01	967,45	42,65	160,2
2200	1322,1	46,33	1672,8	190,36	576,43	958,74	42,22	160,6
2300	1323,3	47,11	1668,6	191,45	547,84	941,77	41,85	159,9
2400	1367	49,48	1615,1	194,98	494,23	895,43	40,5	162,2
Toplam	13659	515,6	18823	2958,7	9954,1	14223	750,9	1838

Tablo 7.4. Tüm devirlerde tam yük için ölçülen deneysel NO_x , özgül yakıt tüketimi ve diğer değerler

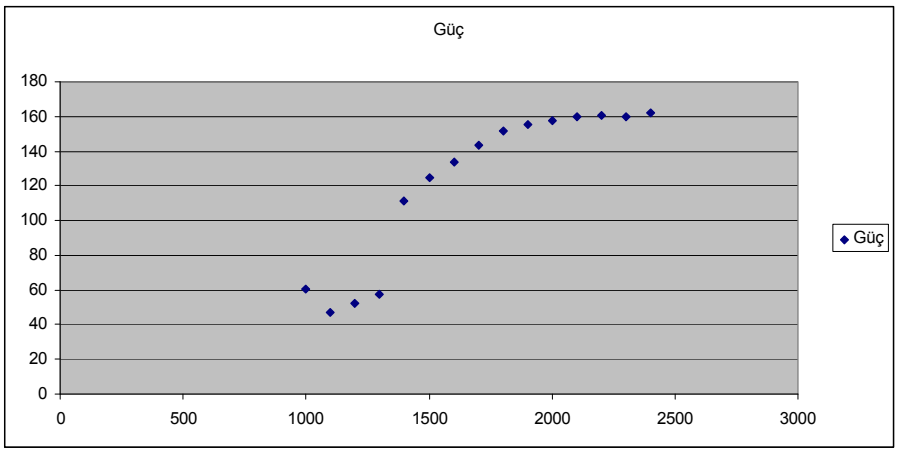
Devir	Sfc	Güç	Afr	Fr	pboost	nox	hc	Tork
1000	259,1	80,26	346,5	20,79	421,29	453,95	31,16	766,7
1100	233,5	103,44	431,6	24,17	603,2	671,43	27,03	897,7
1200	215,7	125,05	526,4	27	801,39	925,82	35,39	995,1
1300	208,2	143,5	626	29,88	966,91	989,57	42,91	1054,5
1400	203,9	156,87	727,1	31,97	1110,15	955,04	48,62	1070
1500	201,2	167,74	813,9	33,75	1208,59	950,73	51,36	1068
1600	200,4	179,21	915,8	35,91	1319,34	903,62	49,99	1069,8
1700	201,8	190,08	1021,3	38,37	1438,64	808,84	48,03	1067,8
1800	203,5	201,47	1122,3	41	1542,63	742,59	47,31	1068,4
1900	205,2	206,93	1204,1	42,46	1590,04	687,12	48,57	1039,9
2000	206,9	210,92	1280,3	43,65	1624,39	636,55	48,38	1007,1
2100	209,5	215,79	1359,2	45,19	1658,68	597,65	49	981,4
2200	212,1	218,44	1421,8	46,33	1672,78	560,24	47,84	948,3
2300	215,7	218,4	1474	47,11	1668,58	516,91	47,49	906,6
2400	220,9	224,05	1549,6	49,48	1711,52	479,41	48,71	891,2
Toplam	3197,6	2642,15	14820	557,06	19338,13	10879,5	671,79	14833



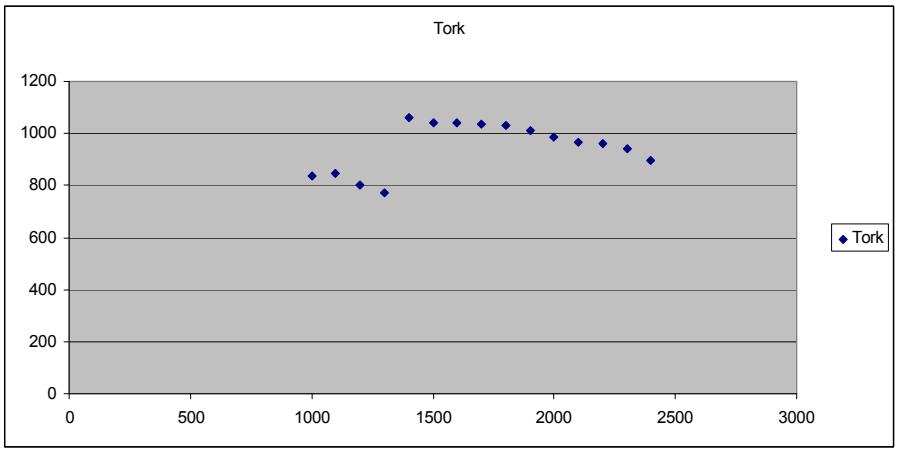
Şekil 7.8. Minimum NO_x ve özgül yakıt tüketimi için optimum sfc değerleri



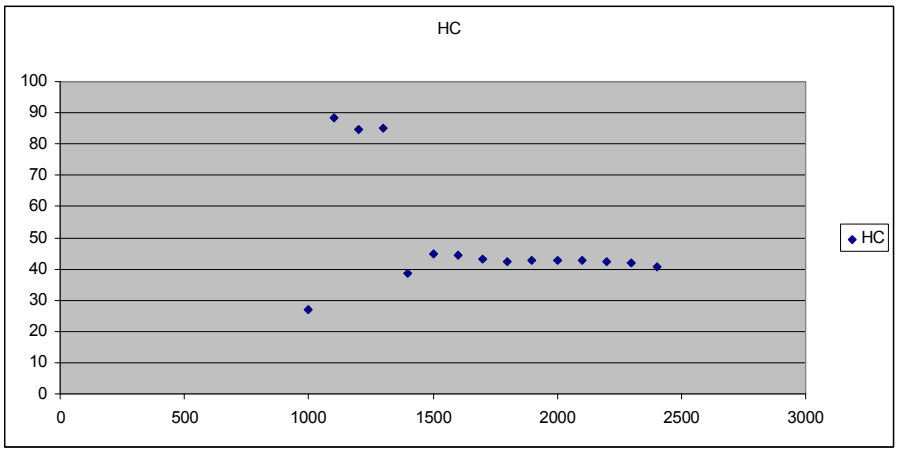
Şekil 7.9. Minimum NO_x ve özgül yakıt tüketimi için optimum NO_x değerleri



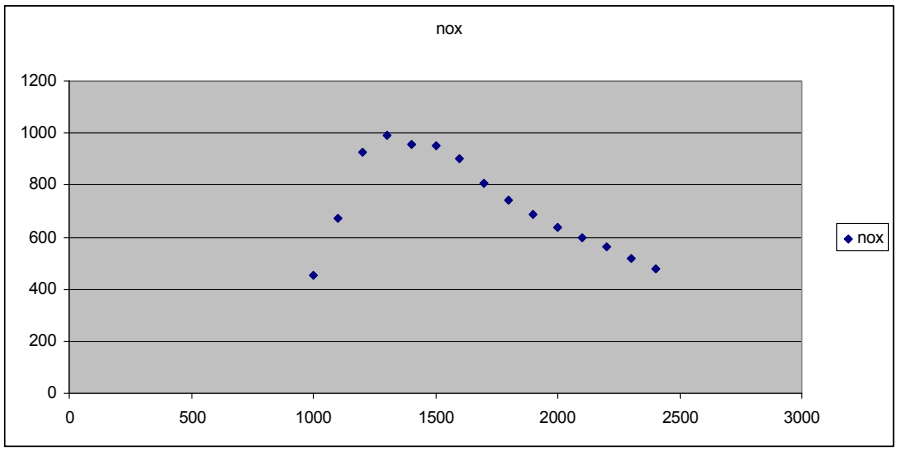
Şekil 7.10. Minimum NO_x ve özgül yakıt tüketimi için optimum güç değerleri



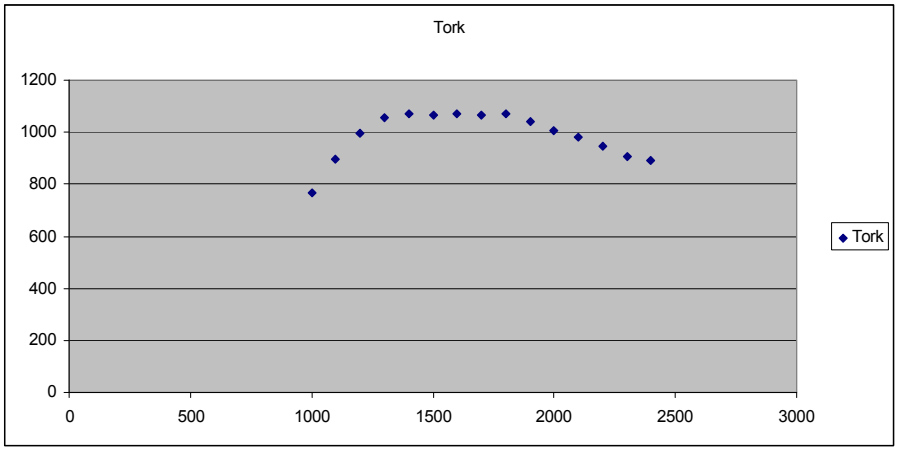
Şekil 7.11. Minimum NO_x ve özgül yakıt tüketimi için optimum tork değerleri



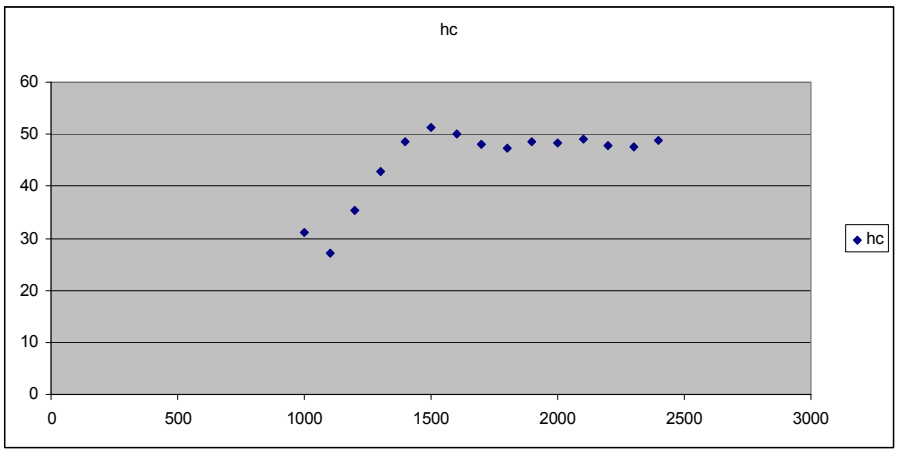
Şekil 7.12. Minimum NO_x ve özgül yakıt tüketimi için optimum HC değerleri



Şekil 7.13. Tam yükte tüm devirlerde NO_x için deneysel motor verileri



Şekil 7.14. Tam yükte tüm devirlerde tork için deneysel motor verileri



Şekil 7.15. Tam yükte tüm devirlerde HC için deneysel motor verileri

Ayrıca NO_x, HC ve Sfc (Specific yakıt tüketimi) için ağırlık değerleri Tablo 7.5'deki gibi verilmiş ve yine aynı tabloda yer alan optimum çıkış değerleri elde edilmiştir. Çıkışlar ile ilgili yorumlar tablonun yorum kısmında yer almaktadır.

Tablo 7.5'den görüleceği üzere emisyon ağırlıkları arttırıldığı zaman yani emisyon değerlerinin düşük olması talep edildiği zaman yakıt tüketimi artmaktadır. Buna mukabil yüksek emisyon değeri için düşük emisyon katsayısı belirlendiğinde yakıt tüketimi düşmektedir.

Tablo 7.5 Hazırlanan optimizasyon aracının farklı ağırlık değerleri için performansı

Ağırlıklar						
NO_x	**HC**	**Sfc**	**NO_x**	**HC**	**Sfc**	**Yorum**
			100	100	100	Varsayılan başlangıç değerleri
0.7	0	0.3	68	87	102	NO_x düşüyor ama yakıt tüketimi aynı
0.3	0	0.7	104	188	92	Düşük yakıt kazancı ama yüksek HC değeri
0.3	0.3	0.3	68	55	98	Tüm parametrelerde iyileşme
0.25	0.25	0.5	88	68	95	Düşük yakıt tüketimi ve kabul edilebilir emisyon değeri

7.2.1.2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesinde Tek amaçlı GA Uygulaması

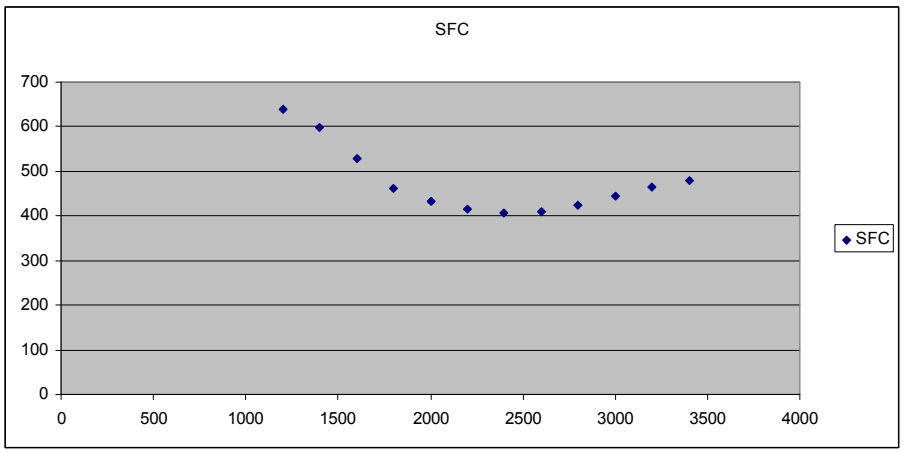
Benzinli motorlarda optimizasyon çalışmalarında HC emisyon parametresi olarak ele alınır. Bu yüzden bu bölümde güç, yakıt tüketimi ve HC arasında optimizasyon yapılmaya çalışılmıştır. Yine program çalıştırılıp 5:6:1 mimarisie sahip ÇKP ağırlıkları dosyadan okutulmuştur. Sonrasında gücün maksimum ve yakıt tüketiminin minimum olduğu noktaları bulmak için sırasıyla 0,1 ve 1 ağırlık katsayı değerleri güç ve sfc parametreleri için seçilmiştir. Sıfır avans için Tablo 7.6'de özgül yakıt tüketimi ve güç için tüm devirlerde elde edilen optimum noktalar sunulmuştur. Tablo 7.7'de ise sıfır avans ve tüm devirlerde elde edilen deneysel motor verileri sunulmuştur. Tablo 7.6 ve Tablo 7.7'den de görüleceği üzere yakıt tüketiminde %7.4 artış ve güçte %8.5 azalma vardır. Şekil 7.16 ve Şekil 7.17'de ise sıfır avans ve tüm devirlerde elde edilen optimum güç ve yakıt tüketimi grafikleri verilmiştir. Görsel karşılaştırma yapılabilmesi amacıyla Şekil 7.18 ve Şekil 19'da sırasıyla motor deneyinden elde edilen özgül yakıt tüketimi ve güç grafikleri sunulmuştur.

Tablo 7.6. Tüm devirlerde sıfır avans için maksimum güç ve minimum yakıt tüketim noktaları

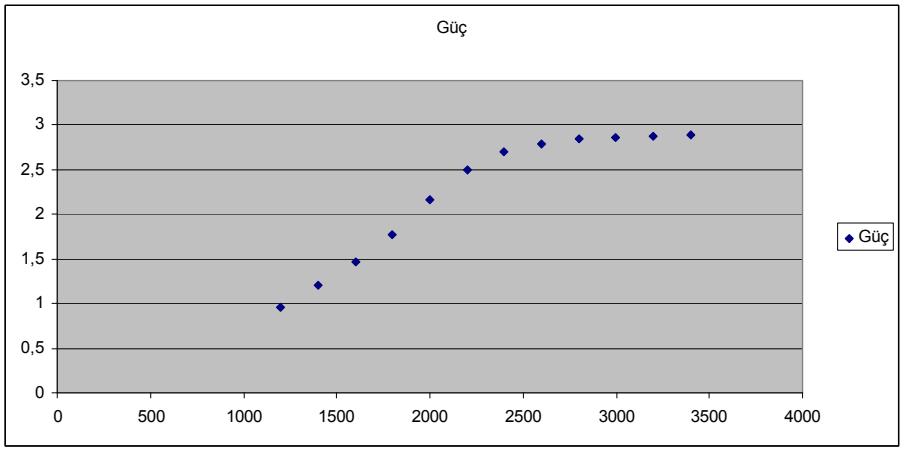
Devir	SFC (1)	Güç (0,1)
1200	638,2929	0,954166
1400	599,0386	1,199518
1600	529,831	1,46661
1800	461,5091	1,768751
2000	432,7722	2,168849
2200	416,1276	2,494543
2400	407,7929	2,696339
2600	409,7929	2,794026
2800	423,1452	2,840116
3000	443,9688	2,859815
3200	465,4649	2,872478
3400	479,0937	2,883777
Toplam	5706,83	26,99899

Tablo 7.7. Tüm devirlerde sıfır avans için elde edilen deneysel motor verileri

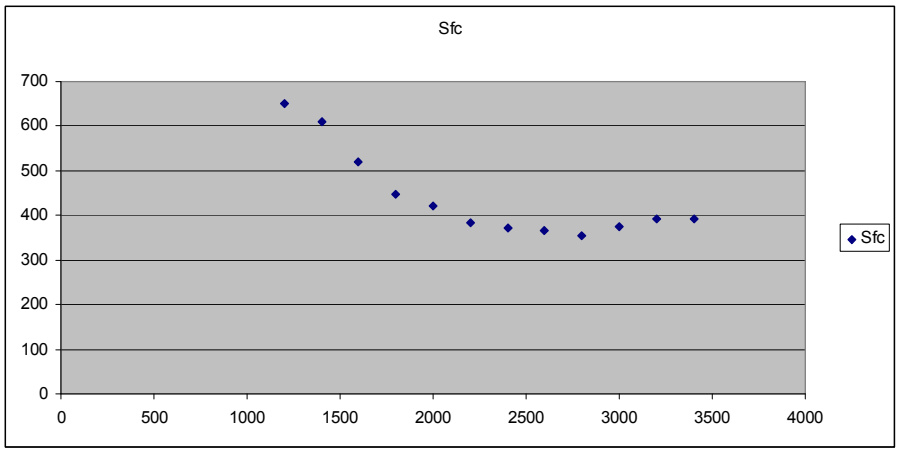
Devir	Güç	Sfc	Hc
1200	0,968	650	206
1400	1,14	608,77	180
1600	1,487	521,18	176
1800	1,838	446,14	173
2000	2,121	422,44	162
2200	2,448	383,17	104
2400	2,721	371,19	80
2600	3,009	364,57	83
2800	3,262	355,3	71
3000	3,44	373,26	55
3200	3,46	393,06	76
3400	3,632	393,45	105
Toplam	29,526	5282,53	1471



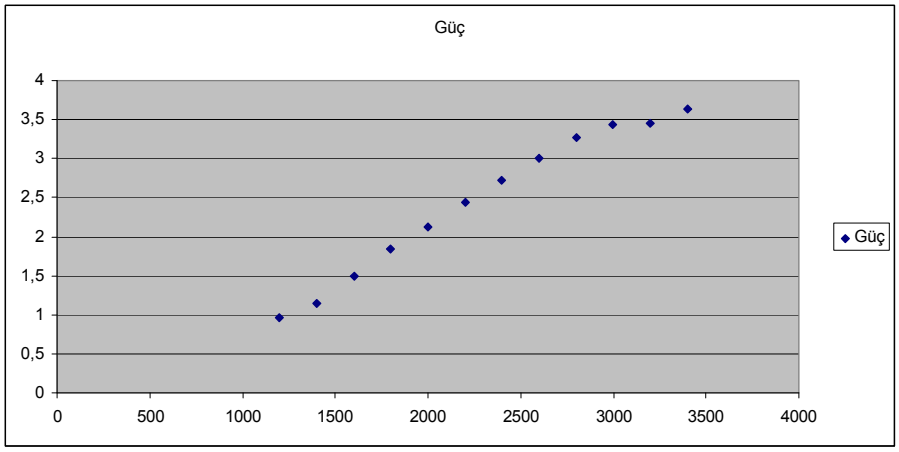
Şekil 7.16. Maksimum güç için tüm devirlerdeki minimum yakıt noktaları



Şekil 7.17. Sıfır avans ve tüm devirlerde minimum yakıtta elde edilen maksimum güç noktaları



Şekil 7.18. Sıfır avans ve tüm devirlerde deneysel olarak elde edilen özgül yakıt tüketim değerleri

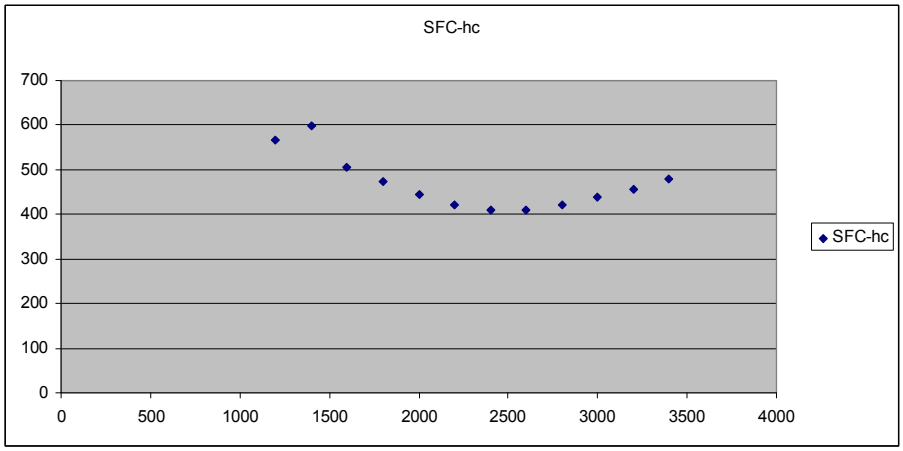


Şekil 7.19. Sıfır avans ve tüm devirlerde deneysel olarak elde edilen güç değerleri

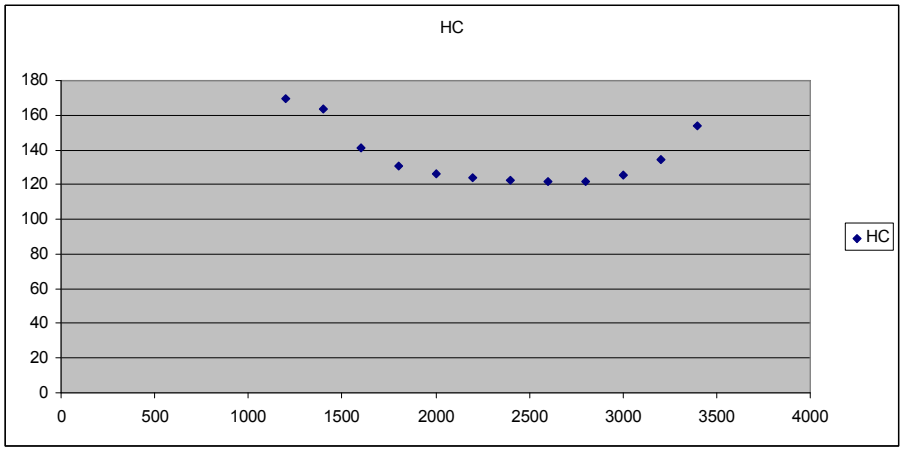
Program çalıştırılıp sıfır avansta yakıt tüketimi ve emisyonun minimum olduğu noktaları bulmak için sfc ve HC ağırlık değerleri 1 olarak girilmiştir. Optimizasyon sonucu Tablo 7.8'deki gibi değerler elde edilmiş ve tüm devirlerde yakıt tüketimi ve NO_x grafikleri ise Şekil 7.20 ve Şekil 7.21'de sunulmuştur. Tablo 7.7 ve Tablo 7.8'den görüleceği üzere (deneysel verilerle karşılaştırıldığında) özgül yakıt tüketimi (sfc) %3 artarken ve HC'da ortalama olarak %12 artmaktadır. Gerek güç optimizasyonunda gerekse de emisyon optimizasyonunda başarısız olunmasının sebebi devir ve avansın sabit tutulması sonucunda çıkışların sadece birbirine göre optimizasyon fonksiyonunu minimize etmesi için değiştirilmesinden kaynaklanmaktadır. Bu durumda da özgül yakıt tüketimi değeri Tablo 7.7'den görüleceği üzere HC ve güçe göre büyüktür. Ve buda uygunluk fonksiyonunun minimum edilmesi için verilen ağırlık değerleri ne olursa olsun özgül yakıt tüketiminin değerini azaltma yoluna gitmeyi gerektirmektedir. Bundan ötürüde hem özgül yakıt tüketimi hemde bu parametre ile optimize edinilmeye çalışılan diğer parametre artmaktadır.

Tablo 7.8. Tüm devirlerde sıfır avans için minimum HC ve minimum yakıt tüketim noktaları

Devir	SFC (1)	HC (1)
1200	567,0474	169,6339
1400	598,3665	163,3576
1600	506,3779	140,882
1800	472,8501	130,7962
2000	444,1117	126,4098
2200	421,3108	123,8526
2400	408,3504	122,2786
2600	409,4165	121,4507
2800	421,9423	121,9087
3000	439,3512	125,31
3200	454,8589	134,2545
3400	479,0937	153,5458



Şekil 7.20 Minimum HC için tüm devirlerdeki minimum yakıt noktaları



Şekil 7.21. Minimum yakıtta tüm devirlerdeki minimum HC noktaları

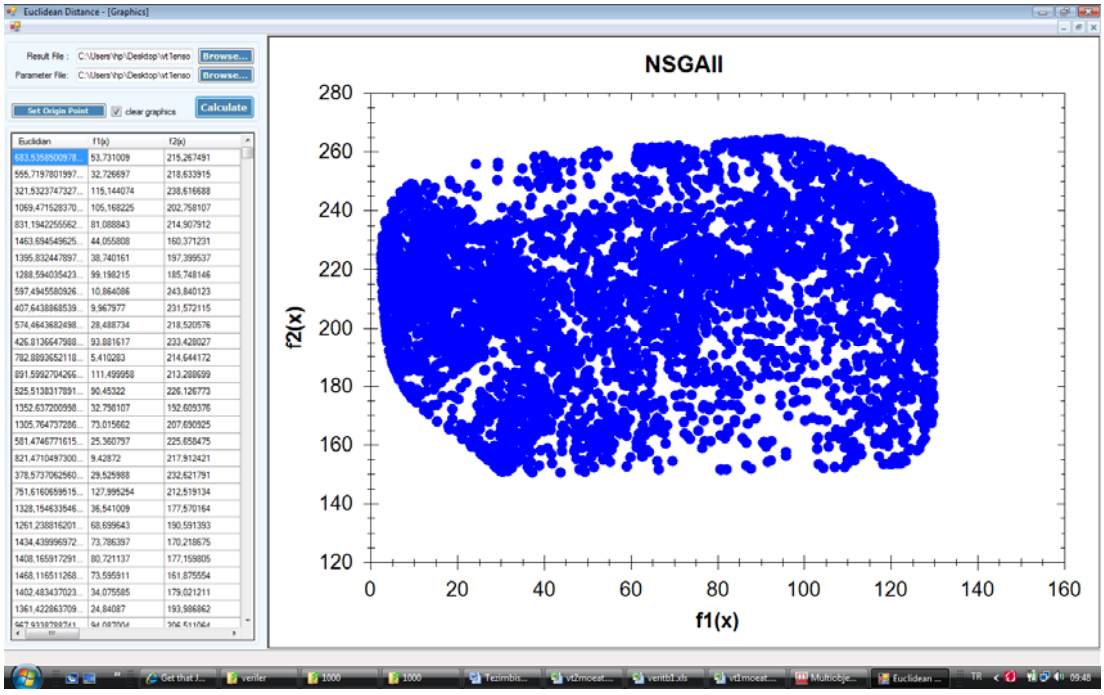
7.2.2. Çok Amaçlı GA Kullanılarak Gerçekleştirilen Yakıt Optimizasyonu

7.2.2.1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesinde Çok Amaçlı GA Uygulaması

Tüm çıkışlar için (güç, tork, özgül yakıt tüketimi, HC, CO_2 ve NO_x) çok amaçlı GA uygulaması gerçekleştirilmiştir. Elde edilen çözüm kümesinde uygunluk

fonksiyonunu minimum yapan çözüm popülasyonun da tüm çıkışlardan her birinin minimum olduğu noktalar bulunmaktadır. Eğer özgül yakıt tüketiminin minimum olmasını istersek çözüm popülasyonunda özgül yakıt tüketimini küçükten büyüğe doğru sıralatabiliriz. Böylelikle bu sıralamaya göre değişen ve fakat minimum olmayan diğer noktalarla birlikte tüm devirlerde özgül yakıt tüketiminin ve uygunluk fonksiyonunun minimum olduğu noktalara göre optimizasyon performansını değerlendirebiliriz. Eğer emisyon parametrelerinden herhangi birinin minimum olduğu noktaları bulmak istersek yine ilgili emisyon parametresini küçükten büyüğe doğru sıralatıp ilgili devirdeki en düşük değerini ve bu değere karşılık gelen diğer çıkış parametre değerlerini ekranda sunabiliriz.

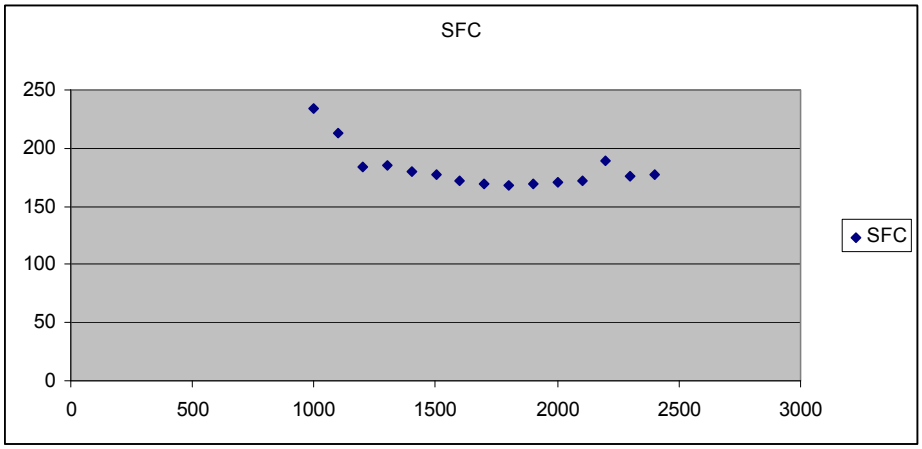
Sağ ve ark (2009) tarafından hazırlanan çok amaçlı genetik algoritma programı kullanılarak tüm çıkışlar için bölüm 5.2'de oluşturulan ilgili YSA ağırlık değerleri programa yüklenmiştir. Tüm çıkışların aynı anda optimizie edilmesi istendiğinden amaç fonksiyonu 6 adet seçilmiştir. NSGA II kullanılarak tüm devirler için (1000-2400 arası) program çalıştırılmıştır. Tüm devirler için dört çekirdekli mikroişlemciye sahip bir bilgisayarda sonuç kümesi yaklaşık 3 saatte elde edilmiştir. 1000 devir için 6 çıkış parametresinin optimizasyonu sonucunda programdan elde edilen çözüm kümesi ve ilgili pareto grafiği Şekil 7.22'deki gibidir.



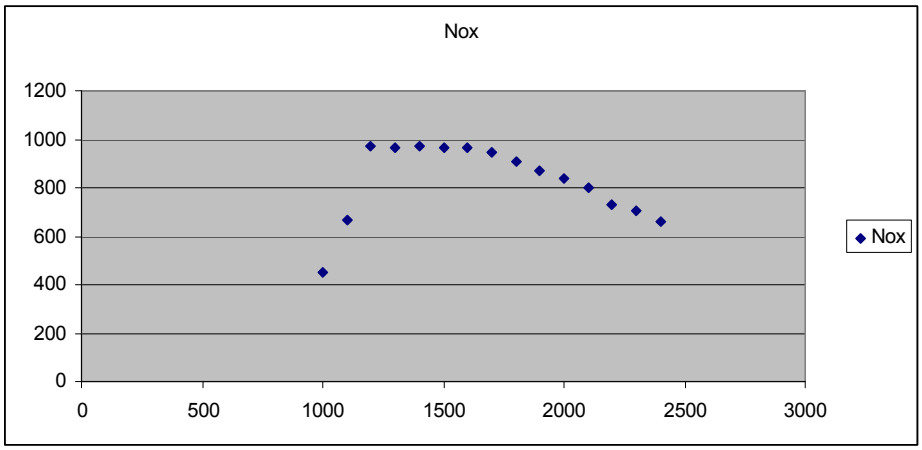
Şekil 7.22. 1000 devir için 6 çıkış parametresinin aynı anda optimizasyonu

Tüm devirler için optimizasyon işlemi tamamlandıktan sonra çok amaçlı optimizasyon NSGA II metodunun kullanmış olduğu öklite (noktaların merkeze olan uzaklık değeri) göre yani oklidin minimum olduğu noktalarda elde edilen değerler Ek 3'deki gibidir. Genel optimizasyonda amaç uygunluk fonksiyonunun 6 çıkış parametresinin her birininde minimum değere sahip olduğu ayrı ayrı çözüm kümelerince minimize edilmesidir. Dolayısıyla yük sabitlenmeden yapılan bu optimizasyon çalışması sadece 6 çıkışın her birisinin minimum olduğu noktalarda diğer giriş ve çıkış parametrelrinin ne olabileceği konusunda fikir vermektir. Bundan dolayı yükün sabitlenmeden gerçekleştirilen optimizasyon çalışmasında karşılaştırma yapabilmek için bir done yoktur. Ek 4 ve Ek 5'de sırasıyla çözüm kümesi içinde özgül yakıt tüketiminin ve HC değerinin minimum olduğu değerler ve bu değerlere karşılık gelen diğer giriş ve çıkış parametreleri sunulmuştur. Bu tablolardan Ek4 kullanılarak örneğin minimum emisyon değerini her bir devirde sağlamak için hangi yük ve diğer giriş parametrelerini sağlamamız gerektiği görülebilir. Ya da Ek 5 kullanılarak minimum HC sağlamak her bir devirde hava akış oranı ve yakıt miktarı gibi giriş değişkenleri ile yük ne olmalıdır sorusuna cevap bulunabilir. Fakat doğrulama donesi olmadığı için sonuçların geçerliliği tartışmaya açıktır.

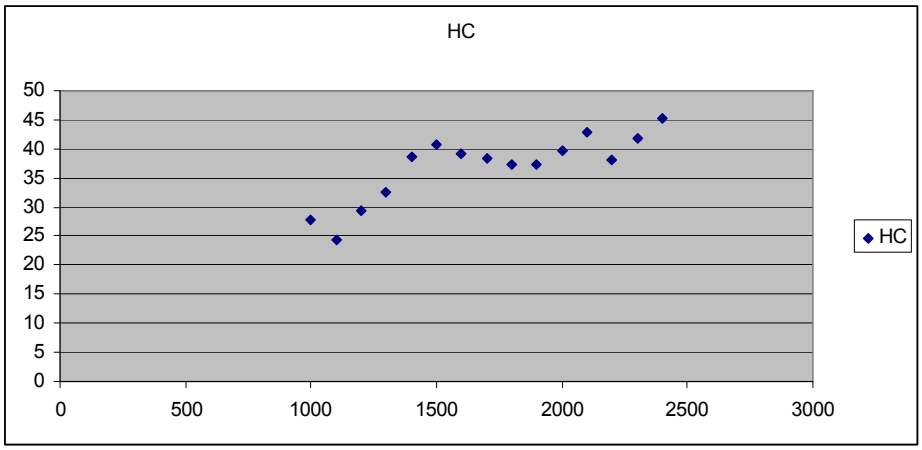
Bu çalışmada amaç yakıt optimizasyonu ve beraberindeki emisyon değerlerini belirlemek olduğu için yapılması gereken yükün sabitlenmesidir. Dolayısıyla tam yükte tüm devirlerde minimum yakıt tüketimi ve buna karşılık gelen optimum emisyon değerlerini hesaplamak için program yeniden çalıştırılmıştır. Her bir devir için tam yük değeri alınarak Ek 6'daki optimum yakıtm tüketimi ve emisyon değerleri ile bunlara karşılık gelen diğer parametreler elde edilmiştir. Tam yükte optimum yakıt tüketimi, NO_x, HC, güç ve tork grafikleri Şekil 7.23 ile Şekil 7.27 arasında verilmiştir.



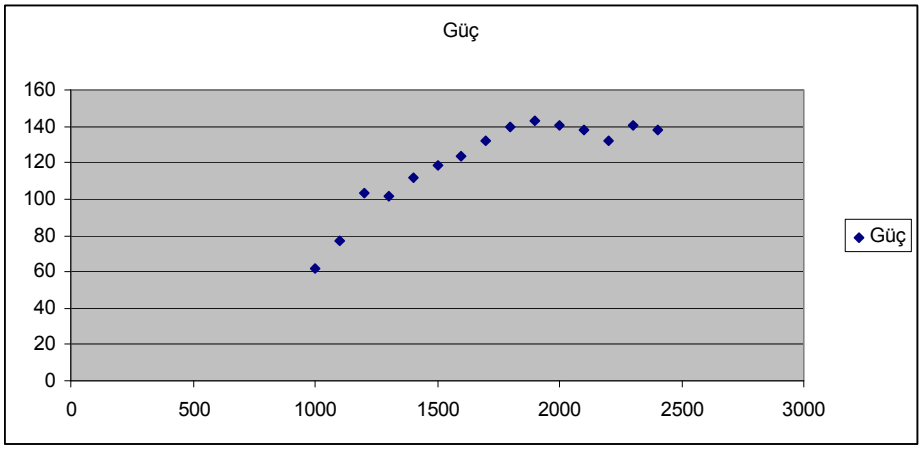
Şekil 7.23. Dizel motor için tam yükte optimum yakıt tüketim noktaları



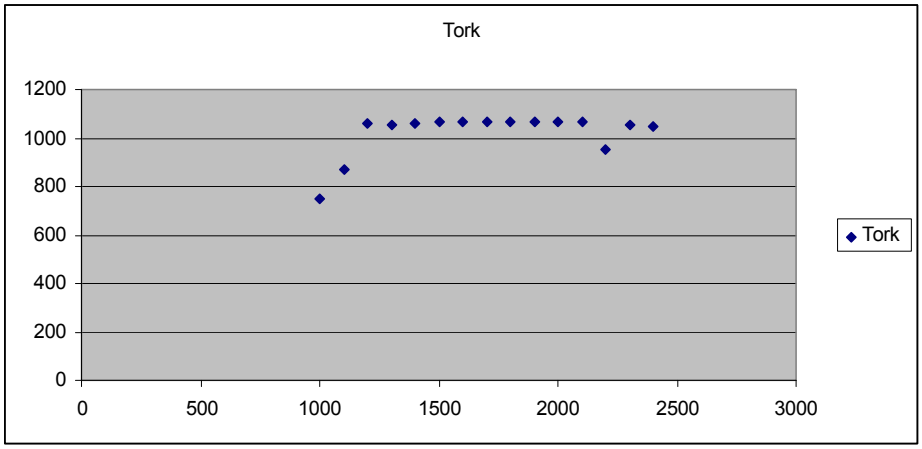
Şekil 7.24. Dizel motor için tam yükte optimum yakıtta NO_x değerleri



Şekil 7.25. Dizel motor için tam yükte optimum yakıtta HC değerleri



Şekil 7.26. Dizel motor için tam yükte optimum yakıtta güç değerleri



Şekil 7.27. Dizel motor için tam yükte optimum yakıtta tork değerleri

Ek 6 ve Ek 1'deki deneysel motor verileri karşılaştırılınca görülmüştür ki HC, CO_2 , güç ve özgül yakıt tüketimi sırasıyla %17.6, %30.05, %31.8 ve %14.5 azalırken NO_x değeri %13 artmıştır. Yakıt tüketiminin %14.5 azalıp diğer emisyon değerlerinide düşürmesi beraberinde NO_x emisyonunda artışı getirmiştir.

7.2.2.2. Briggs ve Stratton Vanguard Benzinli Motor Motor Veri Kümesinde Çok Amaçlı GA Uygulaması

Sağ ve ark (2009) tarafından hazırlanan çok amaçlı genetik algoritma programı kullanılarak tüm çıkışlar için bölüm 5.2'de oluşturulan ilgili YSA ağırlık değerleri programa yüklenmiştir. Tüm çıkışların aynı anda optimizie edilmesi

istendiğinden amaç fonksiyonu 4 adet seçilmiştir. NSGA II kullanılarak tüm devirler için (1200-3400 arası) program çalıştırılmıştır. Tüm devirler için dört çekirdekli mikroişlemciye sahip bir bilgisayarda sonuç kümesi yaklaşık 2 saatte elde edilmiştir. Tüm devirler için optimizasyon işlemi tamamlandıktan sonra çok amaçlı optimizasyon NSGA II metodunun kullanmış olduğu öklite (noktaların merkeze olan uzaklık değeri) göre yani oklidin minimum olduğu noktalarda elde edilen değerler Ek 7'deki gibidir. Genel optimizasyonda amaç uygunluk fonksiyonunun 4 çıkış parametresinin her birininde minimum değere sahip olduğu ayrı ayrı çözüm kümelerince minimize edilmesidir. Dolayısıyla avans sabitlenmeden yapılan bu optimizasyon çalışması sadece 4 çıkışın her birisinin minimum olduğu noktalarda diğer giriş ve çıkış parametrelerinin ne olabileceği konusunda fikir vermektir. Bundan dolayı avansın sabitlenmeden gerçekleştirilen optimizasyon çalışmasında karşılaştırma yapabilmek için bir done yoktur. Ek 8 ve Ek 9'da sırasıyla çözüm kümesi içinde özgül yakıt tüketiminin ve HC değerinin minimum olduğu değerler ve bu değerlere karşılık gelen diğer giriş ve çıkış parametreleri sunulmuştur. Bu tablolardan Ek 8 kullanılarak örneğin minimum emisyon değerini her bir devirde sağlamak için hangi yük ve diğer giriş parametrelerini sağlamamız gerektiği görülebilir. Ya da Ek 9 kullanılarak minimum HC sağlamak her bir devirde hava akış oranı ve yakıt miktarı gibi giriş değişkenleri ile yük ne olmalıdır sorusuna cevap bulunabilir. Fakat doğrulama donesi olmadığı için sonuçların geçerliliği tartışmaya açıktır. Bu çalışmada amaç yakıt optimizasyonu ve beraberindeki emisyon değerlerini belirlemek olduğu için yapılması gereken yükün sabitlenmesidir. Dolayısıyla 10 avansta minimum yakıt tüketimi ve buna karşılık gelen optimum emisyon değerlerini hesaplamak için program yeniden çalıştırılmıştır. Her bir devir için avans değeri 10 alınarak Ek 10'daki optimum yakıtm tüketimi ve emisyon değerleri ile bunlara karşılık gelen diğer parametreler elde edilmiştir.

Ek 10 ve Ek 2'deki deneysel motor verileri karşılaştırılınca görülmüştür ki yakıt tüketiminde ve HC'da ortalama %1.7 ve HC'da %21 artış olmuştur. Bununda sebebi 2 giriş ve 4 çıkışlı verilere sahip olmamızdır. Girişlerden tüm devirler için hesaplama yapmamız gerekmekte olup bu yüzden her bir hesaplamada devri sabit tutmaktayız. İkinci değişkenimizde avans olup optimizasyonun doğruluğunu hesaplayabilmek için sabit avans değerinde hesaplama yapmamız gerekmektedir.

Dolayısıyla iki sabit değerden ve dört çıkışdan oluşan bir çoklu optimizsyon problemine sahip olmaktayız. Çıkışlardan özgül yakıt tüketimi (Sfc) ve HC yüksek değerlere sahip olduğu için optimizasyonda bu iki değerde oynama yaparak çok amaçlı genetik algoritmanın optimizasyonu sağlanmaya çalışılmaktadır. Buda beraberinde her iki değer içinde artış getirmektedir.

SONUÇ: Her iki motor veri türü içinde tek amaçlı ve çok amaçlı GA uygulanmış ve benzinli motor için her iki türde de iyi sonuç alınamamıştır. Bununda sebebi sadece 2 girişli veriden oluşmasıdır. Verinin birisi devir olup diğeride avanstır. Her devir için ayrı hesaplama yapmak gerektiğinden devrin sabitlenmesi gerekmektedir. Karşılaştırma yapabilmek içinde avansın sabitlenmesi gerekmektedir. Dolayısıyla optimizasyon için uygun veri giriş sayısına sahip değildir. Dizel motor için hem tek amaçlı hem de çok amaçlı genetik algoritmada iyi sonuçlar elde edilmiştir. Tek amaçlı GA'da özgül yakıt tüketimi %7.7, NO_x %8.51, güç %30, tork %4 ve afr %7.4 azalırken HC %10.5 artmıştır. NSGA II ile gerçekleştirilen çok amaçlı GA'da HC, CO_2 , güç ve özgül yakıt tüketimi sırasıyla %17.6, %30.05, %31.8 ve %14.5 azalırken NO_x değeri %13 artmıştır. YSA ve NSGA II birlikte daha önce literatürde optimizasyon amaçlı olarak hiç kullanılmamıştır. NSGA II ile elde edilen %14.5'luk yakıt optimizasyonuna karşın güçteki düşüş %31 değerinde kalmış olup bu değerlerde literatürde elde edilememiştir.

8.SONUÇ VE ÖNERİLER

8.1. Sonuçlar

Bu çalışmada bir İYM olan dizel ve benzinli motorun performans ve emisyon karakteristiklerinin modellenmesi ve yakıt optimizasyonu amaçlanmıştır.

Bugüne kadar farklı YZ teknikleri kullanılarak hava-yakıt oranı, yanma zamanlaması, emisyon vb. içten yanmalı motor performans ve emisyon karakteristiğinin modellenmesi ve kontrolü bir çok çalışma gerçekleştirilmiştir. Yanmanın doğrusal olmayan yapısı, performans ve emisyon karakteristiklerinin formulasyona sahip olmaması YZ tekniklerinin doğrusal olmayan problemlere çözüm getirme doğsaı nedeniyle bu alanda sıkça kullanılmasını sağlamıştır. Literatürde YZ teknikleri genellikle benzinli ve hibrit motorlarda üzerinde uygulanmıştır. Dizel motorlar üzerinde yapılan çalışmalar sınırlıdır. Dizel, benzin ya da hibrit motorlar üzerinde yapılan çalışmalar modelleme, kontrol ve optimizasyona dayanmaktadır.

Bu çalışmada iki ayrı motor veri kümesi üzerinde YZ teknikleri ile motor performans ve emisyon karakteristiğinin noktasal ve aralıksal modellemesi ile yakıt optimizasyonu gerçekleştirilmiştir.

Noktasal modelleme sonucunda;

YSA çoklu regresyon ve ANFIS'ten hem benzinli (ortalama %98,5) hem de dizel (ortalama % 99,5) motor veri kümesinde deneysel verilere daha yüksek yakınlıkta sonuçlar üretmiştir.

İleri ve geri yönlü aralıksal modelleme sonucunda;

Dizel ve benzinli motor için her iki yönde de % 100 başarı sağlanmış giriş ve çıkış değerleri noktasal yerine aralık olarak modellenmiştir.

Genetik algoritma kullanılarak gerçekleştirilen optmizasyon çalışması ile yakıt tüketim değeri azaltılırken emisyon değerlerinin kabul edilebilir sınırlarda

tutulması sağlanmıştır. Tek amaçlı ve çok amaçlı GA ile dizel motor veri türünde başarı sağlanmıştır. Benzinli motor verisinin sadece 2 grişli olmasından ötürü her iki metotlada başarı sağlanamamıştır

Çalışmada literatürde yer alan çalışmalara göre farklı olarak;

- Motorun ileri ve ters yönlü modellemesi optimum aralıksal olarak ilk defa yapılmıştır. Literatürde böyle bir çalışma yapılmamıştır. Optimum aralıksal modelleme ile giriş parametrelerine bağlı olarak çıkış parametrelerinin ya da tersi hangi optimum aralıkta olması gerektiği dizel ve benzinli motor veri kümesinde % 100 doğrulukta tespit edilmiştir. Böylelikle araştırmacılar, eğitimciler ve öğrenciler için hem araştırma hem de eğitim amaçlı olarak gerçekleştirilen optimum aralıksal modelleme kullanılabilecektir.
- Farklı mimari, eğitim, aktivasyon ve nöron sayısına sahip YSA kullanılarak dizel motor için daha önce elde edilmemiş oranda deneysel sonuçlara yaklaşık sonuç veren (ortalama %99.5) performans ve emisyon modellemesi yapılmıştır. Benzinli motor için ise yine daha önceden bu motor verisi üzerinde yapılmış uygulamalarda elde edilen değerden daha yüksek deneysel sonuçlara yaklaşıklık (ortalama %98,5) elde edilmiştir.
- YSA ve NSGA II kullanılarak elde edilen yakıt ve emisyon optimizasyonu dizel motor verisi üzerinde başarılı olup benzinli motorda başarıya ulaşmamıştır. Bununda sebebi benzinli motor verisinin sadece 2 girişe sahip olması ve optimizasyonun karşılaştırmasını yapabilmek için bu iki verinin de sabit tutulması gerektiğidir. YSA ve NSGA II literatürde ilk kez bu çalışmada optimizsyon amaçlı olarak kullanılmıştır.

Doğrusal olmayan ve herhangi bir formulasyona sahip olmayan problemlerin çözümünde kullanılan ve eksik veri ile çalışabilen YSA'nın bu çalışmada kullanılan dizel motorlar üzerinde literatürde elde edilen en düşük modelleme hatasına sahip olduğu görülmüştür. Dolayısıyla bu alanda modelleme için kabul edilebilir hata oranına sahip en uygun modelleme araçlarından birisi olarak gözükmektedir.

8.2. Öneriler

Bu çalışmada optimizasyon ve modelleme statik olarak yapılmıştır. Bir dizel motor çalıştırılmış ve dinamo vasıtasıyla yük değişimi sağlanmış ve farklı devirlerde performans ve emisyon değerleri ölçümü yapılmıştır. Çalışma boyunca karşılaşılan en büyük zorluk veri elde edilmesi olmuştur. Konya TÜMOSAN, Bursa Ford ve Koç Tofaş ile yazışmalar yapılmış ve çalışmanın dinamik veriler üzerinde gerçekleştirilmesi için motor deneylerinin bu kurumlarda yapılması ve/veya yaptırılması istenmiştir. Konya TÜMOSAN'da gerekli ölçüm aletlerinin bulunmaması ve diğer kurumlarında ilgili deneyleri yapmaya veya tarafımıza yaptırmaya sıcak bakmaması yüzünden bir kez yapılmış motor deneyinden elde edilen veriler üzerinde modelleme ve optimizasyon yapılmıştır. Dolayısıyla;

Sonraki çalışmalarda modelleme ve optmizasyon dinamik veriler üzerinde gerçekleştirilebilir. Buda bir dizel motorun farklı yol, hava, ve sürücü istekleri şartlarında çalıştırılması ve gerekli verilerin ilgili sensörlerden alınarak dinamik modelleme ve optimizasyonu sağlayacaktır.

Ayrıca kapalı kontrol döngüsü ve geri besleme gerektiren dizel motor kontrolü bu çalışmada deney imkanı olmadığı için gerçekleştirilmemiştir. Yine farklı hava, yol ve şartlarda yapılacak olan motor sürüşleri ve motora aksamlarına yapılacak olan fiziksel müdahalelerle kontrol gerçekleştirilebilir. Örneğin yokuş tırmanan bir araç için yapılan modelleme sonucu elde edilen anlık değer ile o an EMS tarafından üretilen değer karşılaştırılabilir ve yakıt tüketimi modelleme sonucu elde edilenden fazla ise motorun yakıt basıncı düşürülerek yakıt tüketimi azaltılabilir. Bu ve buna benzer uygulamalar kontrol ve optimizasyon amaçlı olarak gerçekleştirilebilir.

9. KAYNAKLAR

Allahverdi N. 2002. Uzman Sistemler. Bir yapaya Zeka Uygulaması, Atlas, Istanbul.

Alonso J. M., Alvarruiz F., Desantes M. J., Hernández L., Hernández V., ve Molto G. 2007. Combining Neural Networks and Genetic Algorithms to Predict and Reduce Diesel Engine Emissions. Ieee Transactıons On Evolutıonary Computatıon, Vol. 11, No. 1.

Arcaklıoğlu E. ve Çelikten İ. 2005. A diesel engine's performance and exhaust emissions Applied Energy; 80:11-22.

AS 2008. http://www.aydinsari.com.tr/motor_dersi_konular_2.htm, son erişim tarihi 06.08.2008.

Balcı M. 1986. Dört Zamanlı Türboşarjlı Direk Püskürtmeli Bir Dizel Motorunun Bilgisayar İle Simülasyonu, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Bezdek J. C. 1981. Pattern recognition with fuzzy objective function algorithms, Plenum Press, NewYork.

Bishop C. M. 1995. Neural Network for Pattern Recognition, Oxford University Pres, England.

Borat, O., Sürmen A. ve Balcı M. 2000. İçten Yanmalı Motorlar, Cilt 1, Uludağ Üniv. Vakfı Yayınları, İstanbul, Bursa, Ankara.

Chang F.J. and Chang Y.T. 2006. Adaptive neurofuzzy inference system for prediction of water level in reservoir. Advances in Water Resources; 29:1-10

Çelik V. ve Arcaklıoğlu E. 2005. Performance maps of a diesel engine, Applied Energey; 81:247-259

Çelikten I. 2003. An experimental investigation of the effect of the injection pressure on engine performance and exhaust emission in indirect-injection diesel engines. Appl. Thermal Eng; 23:2051–2060.

Çetinkaya S. 1987. Dört Zamanlı Buji İle Ateşlemeli Bir Motor Performansının Bilgisayar Yardımıyla Simülasyonu, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Deb K., Agrawal S., Pratab A., and Meyarivan T. 2002. A fast elitist nondominated sorting genetic algorithm for multiobjective optimization: NSGA-II, IEEE Trans. on Evolutionary Computation 6 (4) 182–197.

DeNicolao G., Scattolini R. and Siviero C. 1996. Modeling the volumetric efficiency of IC engines: parametric, nonparametric and neural techniques. Control Engng. Pract; 10:1405–15.

Du H., Zhang L. and Shi X. 2001. Reconstructing cylinder pressure from vibration signals based on radial basis function networks. Proc Inst Mech Engnr, Part D: J Automobile Engng; 215(D6):761–7.

Emel G. G. ve Taşkın Ç. 2002. Genetik Algoritmalar ve Uygulama Alanları, Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt XXI; Sayı.1:129-152

Fahlman, S.E. 1988. An empirical study of learning speed in back-propagation networks. Technical report, Carnegie Mellon University.

Fausett, L.V. 1994. Fundamentals of Neural Networks: Architectures, Algorithms And Applications, Prentice Hall Publ.

Fırat M., Yurdusev M. A. ve Mermer M. 2008. Uyarlamalı sinirsel bulanık mantık yaklaşımı ile aylık su tüketiminin tahmini, Gazi Üniv. Müh. Mim. Fak. Der. Cilt 23, No 2, 449-457.

Fonseca C. M. and P.J.Fleming. 1995. An overview of evolutionary algorithms in multiobjective optimization, IEEE Transactions On Evolutionary Computation, ,Vol.6,No. 6.

Gielmo L. and Santini S. 2001. A two-time-scale infinite-adsorption model of three way catalytic converters during the warm-up phase. J Dyn Syst Measure Control: Trans ASME; 123(1):62–70.

Hafner M., Schuler M., Nelles O. Ve Isermann R. 2000. Fast neural networks for diesel engine control design. Control Engng Pract; 8(11):1211–21.

Hamosfakidis V. and Reitz R. D. 2003. Optimization of a hydrocarbon fuel igniton model for two single component surrogates of diesel fuel, Combustion and Flame; 132:433-450.

Haykin, S. 1999. Neural Networks A Comprehensive Foundation, Prentice Hall publishing, New Jersey.

Hebb, D.O. 1949. The Organization of Behaviour: A Neurophsychological Theory, New York: Wiley.

Heister F. and Froehlich M. 2001. Non-linear time series analysis of combustion pressure data for neural network training with the concept of mutual information. Proc Inst Mech Engnr, Part D: J Automobile Engng; 215(D2):299–304.

Hiroyasu T., Miki. M., Nakayama S., Hanada Y.,2005. MultiObjective Optimization of Diesel Engine Emissions and Fuel Economy Using SPEA2+. *GECCO'05,* June 25–29, Washington, DC, USA.

Hopfield, J.J. 1982. Neural Networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences, USA, vol. 79, pp. 2254-2258.

Howlett R. J., Howson P. A., Walters S. D. and Pashley N. 1996. Determination of air fuel ratio in an automotive ignition system using neural networks, International symposium on automotive technology and applications, Florence, Italy.

Howlett R. J. 1998. Monitoring and Control Of Internal Combustion Engine Air-Fuel Ratio using Neural and Fuzzy Techniques, Conference on the Engineering of Intelligent Systems, EIS'98, Tenerife, Spain.

Isermann R. and Hafner M. 2001. Mechatronic combustion engines: from modeling to optimal control, Eur J Control; 7(2/3): 220–47.

Kaji H., and Kita H., 2008. "Individual Evaluation Scheduling for Experiment-Based Evolutionary Multi-objective Optimization," IEEJ Transactions on Electronics,Information and Systems, Vol. 128-C, No. 6, pp. 986–996.

Kesgin U. 2004. Genetic algorithm and artificial neural network for engine optimisation of efficiency and NOx emission. Fuel 83 (2004) 885–895.

Kılıcarslan A. 2001. The exhaust-gas analysis of Helmholtz-type flapper-valve gas-fired pulse combustion, ECOS'0l, Istanbul, Turkey.

Koçer E. 2007. İris deseninin yapay zeka yöntemleri ile tanınması, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

Kohonen T. 1982. Self-organized formation of topologically correct feature maps. Biological Cybernetics, vol. 43, pp. 59-69.

Korb R., Jorgl H. P. and Lutz B. 1999. Nonlinear dynamic modeling of a gas engine using an RBF-network. Math Comput Modeling Dyn Syst; 5(2):133–51.

Laukonen E. G., Passino K. M., Krishnaswami V., Luh G. C. and Rizzoni G. 1995. Fault-detection and isolation for an experimental internal combustion engine via fuzzy identification, IEEE Trans Control Syst Technol; 3(3):347–55.

Lee S. H., Howlett R. J., and Walters S. D. 2003. Fuzzy air-fuel ratio control of a small gasoline engine, Lecture Notes in Computer Science, Springer Berlin / Heidelberg, Volume 2773/2003

Lee S. H., Howlett R. J., and Walters S. D. 2004. Engine fuel injection control using fuzzy logic, Proceedings of the 3rd IMechE Automobile Division Southern Centre Conference on Total vehicle technology : finding the radical, implementing the practical, 26-27th April 2004, University of Sussex, Brighton, UK. Professional Engineering Pub, U.K., pp. 287-296.

Li X. Q. and Yurkovich S. 2000. Neural network based, discrete adaptive sliding mode control for idle speed regulation in IC engines, J Dyn Syst Measure Control: Trans ASME;122(2): 269–75.

Lucas A., Duran A., Carmona M. and Lapuerta M. 2001. Modeling diesel particulate-emissions with neural Networks, Fuel; 80:539–48.

MacQueen B. 1967. Some Methods for classification and Analysis of Multivariate Observations, Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, University of California Press, 1:281-297,

McCulloch, W. S. and Pitts, W. H. 1943. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5:115-133.

Massie D. D. 2001. Neural-network fundamentals for scientists and engineers, ECOS'0l proceedings p. 123, Istanbul, Turkey.

Matsumoto H., Morita S. and Takiyama T. 1994. Application of fuzzy control to internal combustion engines, JSME Int J Ser B, Fluids Thermal Engng; 37(1):159–64.

MMO 2007. http://www.mmo.org.tr/muhendismakina/arsiv/2001/ekim/Genetik_Algoritma.htm, son erişim tarihi: 13.03.2007

Morita S. 1993. Optimization control for combustion parameters of petrol engines using neural networks: in the case of online control, Int J Vehicle Des; 14(5/6):552–62.

Muller R. Hemberger H. H. and Baier K. 1997. Engine control using neural networks: a new method in engine management systems, Mechanica; 32(5):423–30.

Nabiyev, V. 2005. Yapay Zeka Problemler – Yöntemler – Algoritma, Seçkin Yay.

Nakakita K., Kondoh T., Ohsawa K., Takahashi T. and Watanabe S. 1994. Optimization of pilot injectionpattern and its effect on diesel combustion with high-pressure injection, JSME Int J Series B – Fluids Thermal Eng; 37:966–73.

Nam S. K., Kim J. S. and Yoo W. S. 1994. Fuzzy sliding mode control of gasoline fuel-injection system with oxygen sensor, JSME Int J Ser, C: Dyn Control Robot Des Manufact; 37(1): 100–6.

NC 2008. http://www2.chass.ncsu.edu/garson/PA765/regress.htm#biblio, son erişim tarihi 06.08.2008

OBITET. 2008. http://www.obitet.gazi.edu.tr/, son erişim tarihi 06.08.2008

Obodeh. O., Ajuwa. C. I. 2008. Calibration of Aging Diesel Engine with Artificial Neural Networks. European Journal of Scientific Research ISSN 1450-216X Vol.24 No.4, pp.520-531

Ortmann S. and Glesner M. 1998. Development and implementation of a neural knock detector using constructive learning methods, Int J Uncertainty Fuzziness Knowledge-Based Syst; 6(2):127–37.

Osyczka A. 2002. Evolutionary Algorithms for Single and Multicriteria Design Optimization, New York: Physica Verlag. 2002

Owens M., Segal C. 2001. Development of a hybrid-fuzzy air temperature controller for a supersonic combustion test facility, Exp Fluids; 31(1):26–33.

Öğüçlü Ö. 1998. Thermodynamics Model Of The Cycle Of Spark Ignition Engine, Msc. Thesis, Graduate School Of Natural And Applied Sciences Of Dokuz Eylül University, İzmir.

Özbay, Y., Karlık B. 2001. A Recognition of ECG Arrhythmia Using Artificial Neural Networks. 23rd Annual International Conference IEEE Engineering in Medicine and Biology Society, Istanbul, Turkey.

Öztemel, E. 2003. Yapay Sinir Ağları, Papatya Yayınevi, İstanbul.

Palau A., Veto E. and Puigjaner L. 1999. Use of neural networks and expert systems to control a gas/solid sorption chilling machine, Int J Refrig; 22:59–66.

Park S., Yoon P. and Sunwoo M. 2001. Feedback error learning neural networks for spark advance control using cylinder pressure, Proc Inst Mech Engnr, Part D: J Automobile Engng; 215(D5):625–36.

Polifke W., Geng W. Q. and Dobbeling K. 1998. Optimization of rate coefficients for simplified reaction mechanisms with genetic algorithms. Combust flame; 113(1/2):119–34.

Rajagopalan A., Washington G., Rizzoni G. and Guezennec D. 2003. Development of Fuzzy Logic and Neural Network Control and Advanced Emissions Modelling for Paralel Hybrid Vehicles, NREL/SR-540-32919 subcontractor Report.

Rosenblatt, F. 1958. The perceptron: A probabillstic model for information storage and organization in the brain. Psychological Review, 65:386-408.

Rumelhart, D. E., Hinton, G. E., and Williams, R. J. 1986. Learning representations by back-propagating errors. Nature, 323:533—536.

Sağıroğlu, Ş., Beşdok, E. ve Erler, M. 2003. Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları, Ufuk Yayıncılık, Kayseri.

Saerens B., Vandersteen J., Persoons T., Swevers J., Diehl M. and Van den Bulck E. 2009. Minimization of the fuel consumption of a gasoline engine using dynamic optimization. Applied Energy 86 (2009) 1582–1588.

Sağ T. and Cunkas M. 2009. A tool for multiobjective evolutionary algorithms. Advances in Engineering Software In Press

Sekmen P., Yakup S. ve Çınar C. 2004. Yakıt Olarak Ch4 Kullanan Değişken Sıkıştırma Oranlı Buji İle Ateşlemeli Bir Motorun İdeal Hava-Yakıt Çevrim Analizi İle Teorik Simülasyonu Teknoloji, Cilt 7, Sayı 2, 211-218

Sharkey A. J. C., Chandroth G. O., Sharkey N. E. 2000. A multi-net system for the fault diagnosis of a diesel engine, Neural Comput Appl; 9(2):152–60.

Sharkey A. J. C., Sharkey N. E. and Chandroth G. O. 1996. Diverse neuralnet solutions to a fault diagnosis problem, Neural Comput Appl; 4(4):218–27.

SN 2008. http://www.soylenasil.com/makine/benzinlimotor3.htm, en son erişim tarihi 06.08.2008.

Srinivas N. ve Deb K. 1994. Multiobjective Optimization Using Nondominated Sorting Genetic Algorithms, Journal of Evolutionary Computation, Vol. 2, No.3, pp 221-248.

Soliman A., Rizzoni G. And Kim Y. W. 1998. Diagnosis of an automotive control system using fuzzy inference.1998. Control Engineering Practice 7(1999) 209-216

Stevens S. P., Shayler P. J. and Ma T. H. 1995. Experimental-data processing techniques to map the performance of a spark-ignition engine, Proc Inst Mech Engnr, Part D: J Automobile Engng; 209(4):297–306.

Şen Z. 2004. Mühendislikte Bulanık (Fuzzy) Mantık ile Modelleme Prensipleri, ISBN: 9756455101, 193 p, Su Vakfı Yayınları, 2004.

Taşdemir Ş. 2004. Benzinli bir motorun performans ve emisyon karakteristiklerinin belirlenmesi için bulanık uzman sistem tasarımı, Y. Lisans Tezi, S.Ü. Fen Bilimleri Enstitüsü, Elektronik Ve Bilgisayar sistemleri Eğitimi ABD, Konya.

Taşdemir Ş., Sarıtaş I., Ciniviz M., Çınar C. ve Allahverdi N., 2004. Application Of Artificial Neural Network For Definition Of A Gasoline Engine Performance, 4th İnternational Advanced Technologies Symposium, p:1030-1034, Konya, Turkey.

Thompson G. J., Atkinson C. M., Clark N. N., Long T. W. and Hanzevack E. 2001. Neural network modeling of the emissions and performance of a heavy-duty diesel engine. Proc Inst Mech Engnr, Part D: J Automobile Engng; 214(D2): 111–26.

Trebi-Ollennu A., Dolan J. M. ve Khosla P. K. 2001. Adaptive fuzzy throttle control for an all-terrain vehicle, Proc Inst Mech Engnr, Part I: J Syst Control Engng; 215(I3):189–98.

Tutuncu K. and Allahverdi A. 2007. Reverse modeling of a diesel engine performance by FCM and ANFIS, International Conference on Computer Systems and Technologies – CompSysTech'07, Rousse-Bulgaria.

Türkoğlu, İ., Arslan, A. 1996. Yapay Sinir Ağları ile Bozuk Örüntü Tanıma, F.Ü. Fen ve Mühendislik Bilimleri Dergisi, 8, 147 – 158.

Vossoughi G. R. And Rezazadeh Siavash. 2005. Optimization of the Calibration for an Internal Combustion Engine Management System Using Multi-Objective

Genetic Algorithms.The 2005 IEEE Congress on Evolutionary Computation, Volume 2, Issue , 2-5 Sept. 2005 Page(s): 1254 - 1261 Vol. 2

Wang W., Chirwa E. C., Zhou E., Holmes K. and Nwagboso C. 2001. Fuzzy neural ignition timing control for a natural gas fueled spark ignition engine, Proc Inst Mech Engnr, Part D: J Automobile Engng; 215(D12):1311–23.

Widrow, B. And Hoff, M.E. 1960. Adaptive switching circuits. IRE WESCON Convention record, pp. 96-104.

Yang H. C., Ryou H. S., Hong K. B., Kim H. S. and Park S. K. 1997. Application of the ring k–model to the analysis of flows and spray characteristics. Atomiz Sprays; 7:581–601.

Yang H. C., Ryou H. S., Jeong Y. T., Choi Y. K. 1996. Spray characteristics in a direct-injection diesel engine, Atomiz Sprays; 6:95–109.

Yang Z. Z., Wei J. Q., Fang Z. Y. and Li J. D. 2002. An investigation of optimum control of ignition timing and injection system in an in-cylinder injection type hydrogen fueled engine. Int J Hydrogen Energy; 27(2):213–7.

Yücesu H. S. 1999. Bir Stirling Motorunda Isıtıcı ve Soğutucu Boyutlarının Belirlenmesi İçin Bir Matematik Model, Turkish Journal of Engineering & Environmental Sciences, Vol. 23, No. 2, Say. 105-120.

Zilouchian A. Juliano M. Healy T. And Davis J. 2000. Design of a fuzzy logic controller for a jet engine fuel system, Conltrol Engng Pract; 8(8):873–83.

Zitzler E., Deb K., and Thiele L. 2000. Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. *Evolutionary Computation*, 8(2):173-195, Summer.

EKLER

Ek 1. 300PS E1 J1 Yüksek Torklu Dizel Motor Veri Kümesi

GİRİŞ PARAMETRELERİ					ÇIKIŞ PARAMETRELERİ					
Devir (Cy)	Hava akış oranı (Afr)	Yakıt akış oranı (Fr)	Yük (L)	Boost basıncı (Pb)	Tork (Tq)	CO_2	Güç (P)	HC	NO_x	Spesific yakıt tüketimi (sfc)
2400	1549,6	49,48	100	1711,52	891,2	7,47	224,05	48,71	479,41	220,9
2300	1474	47,11	100	1668,58	906,6	7,5	218,4	47,49	516,91	215,7
2200	1421,8	46,33	100	1672,78	948,3	7,66	218,44	47,84	560,24	212,1
2100	1359,2	45,19	100	1658,68	981,4	7,84	215,79	49	597,65	209,5
2000	1280,3	43,65	100	1624,39	1007,1	8,03	210,92	48,38	636,55	206,9
1900	1204,1	42,46	100	1590,04	1039,9	8,32	206,93	48,57	687,12	205,2
1800	1122,3	41	100	1542,63	1068,4	8,65	201,47	47,31	742,59	203,5
1700	1021,3	38,37	100	1438,64	1067,8	8,92	190,08	48,03	808,84	201,8
1600	915,8	35,91	100	1319,34	1069,8	9,32	179,21	49,99	903,62	200,4
1500	813,9	33,75	100	1208,59	1068	9,85	167,74	51,36	950,73	201,2
1400	727,1	31,97	100	1110,15	1070	10,43	156,87	48,62	955,04	203,9
1300	626	29,88	100	966,91	1054,5	11,3	143,5	42,91	989,57	208,2
1200	526,4	27	100	801,39	995,1	11,99	125,05	35,39	925,82	215,7
1100	431,6	24,17	100	603,2	897,7	12,27	103,44	27,03	671,43	233,5
1000	346,5	20,79	100	421,29	766,7	11,63	80,26	31,16	453,95	259,1
2400	1351,8	37,7	88,8	1342,43	668	6,52	167,92	65,04	370,2	224,5
2300	1270,4	35,86	84,7	1287,32	680,1	6,58	163,75	62,01	411,11	219,1
2200	1203,1	35,04	78,4	1256	710,9	6,8	163,82	59,09	466,43	213,9
2100	1142,1	34,21	74,8	1233,55	735,7	7,01	161,77	56,62	490,27	211,4
2000	1076	33,01	73,7	1198,15	755,2	7,2	158,13	55,22	520,52	208,9
1900	1018,6	32,19	70,2	1184,11	780,1	7,45	155,22	53,98	538,13	207,4
1800	948,9	31,04	72,5	1138,95	800,8	7,73	151,02	54,42	586,56	205,4
1700	862,3	29,11	72,4	1056,42	801,1	7,99	142,66	54,41	628,97	204,3
1600	770,6	27,28	71,9	953	802,4	8,39	134,49	56,92	704,06	202,6

GİRİŞ PARAMETRELERİ					ÇIKIŞ PARAMETRELERİ					
Devir (Cy)	Hava akış oranı (Afr)	Yakıt akış oranı (Fr)	Yük (L)	Boost basıncı (Pb)	Tork (Tq)	CO_2	Güç (P)	HC	NO_x	Spesific yakıt tüketimi (sfc)
1500	684	25,59	72,5	854,28	802,4	8,87	126,09	56,1	769,67	202,8
1400	625,1	24,54	74,1	812,02	801,6	9,35	117,62	51,21	669,46	208,7
1300	531,7	22,7	75,1	667,63	801,9	10,17	109,12	45,43	853,12	208,2
1200	450,2	19,82	71	516,84	745,9	10,54	93,74	42,89	934,07	211,5
1100	375,8	16,82	68,4	375,1	672,9	10,44	77,51	45,24	901,8	216,8
1000	322,9	16,3	79,7	304,61	673	10,46	70,5	37,23	787	231,3
2400	1125,5	26,38	62,9	948,08	445,9	5,44	112,05	87,62	262,26	235,5
2300	1041,9	24,82	55,5	869,69	452,9	5,54	109,06	86,64	323,75	227,6
2200	975,8	24,09	51,4	827,43	473,9	5,74	109,22	87,26	400,22	220,7
2100	926,2	23,6	49,5	809,93	490,8	5,94	107,97	85,25	409,12	218,7
2000	871,7	22,81	48,5	778,95	504,2	6,09	105,57	83,26	429,42	216,1
1900	820,9	22,2	46,5	755,67	520	6,31	103,47	80,5	433,69	214,4
1800	762,7	21,38	48,3	715,63	533,9	6,55	100,59	79,64	464,47	212,6
1700	690,5	20,09	47,8	646,89	534,2	6,8	95,12	82,89	502,41	211,3
1600	620,6	18,81	47,6	576,26	534	7,12	89,54	90,01	554,38	210
1500	557,9	17,57	47,7	507,07	533,9	7,39	83,88	92,31	605,63	209,5
1400	508	16,62	47,9	468,24	534	7,68	78,26	98,54	570,87	212,3
1300	445,2	15,08	47,2	375,06	526,8	8,01	71,7	104,29	712,46	210,4
1200	389,5	13,32	46,2	300,84	498,5	8,12	62,7	109,86	717,61	212,2
1100	336,7	11,04	43,3	212,62	449	7,63	51,71	108,58	748,28	213,4
1000	283,9	8,61	38,2	134,2	383,3	7,19	40,15	111,22	845,93	214,3
2400	874,2	15,26	36,5	511,21	223,2	4,04	56,09	133,23	186,28	272,1
2300	805,8	14,27	32,6	445,97	227,1	4,09	54,7	130,61	233,97	261
2200	754	13,78	31,5	408,37	236,7	4,21	54,55	126,83	286,02	252,6

Devir (Cy)	Hava akış oranı (Afr)	Yakıt akış oranı (Fr)	Yük (L)	Boost basıncı (Pb)	Tork (Tq)	CO_2	Güç (P)	HC	NO_x	Spesific yakıt tüketimi (sfc)
2100	708,9	13,36	30,6	383,61	244,8	4,34	53,84	124,56	297,25	248
2000	665,4	12,89	29,8	358,61	252	4,45	52,79	124,45	308,97	244,5
1900	625,8	12,47	29,1	339,5	260,1	4,59	51,77	123,06	315,49	240,7
1800	583,9	11,92	29,7	317,74	267	4,7	50,35	121,75	341,41	236,7
1700	538,6	11,14	29	282,91	267	4,77	47,51	122,79	362,75	234,6
1600	497,8	10,4	29	252,97	266,9	4,83	44,75	124,87	379,94	232,4

Ek 2. Briggs ve Stratton Vanguard Benzinli Motor Veri Kümesi

GİRİŞLER		ÇIKIŞLAR			
Devir	**Avans**	**Tork**	**Güç**	**Sfc**	**Hc**
1200	0	7,7	0,968	650	206
1400	0	7,775	1,14	608,77	180
1600	0	8,875	1,487	521,18	176
1800	0	9,75	1,838	446,14	173
2000	0	10,125	2,121	422,44	162
2200	0	10,625	2,448	383,17	104
2400	0	10,825	2,721	371,19	80
2600	0	11,05	3,009	364,57	83
2800	0	11,125	3,262	355,3	71
3000	0	10,95	3,44	373,26	55
3200	0	10,325	3,46	393,06	76
3400	0	10,2	3,632	393,45	105
1200	10	8,775	1,103	591,12	206
1400	10	9,075	1,33	526,32	170
1600	10	9,58	1,6	487,5	163
1800	10	9,85	1,857	471,9	130
2000	10	10,2	2,136	453,18	107
2200	10	10,725	2,459	410,33	93
2400	10	11,3	2,84	368,66	90
2600	10	11,275	3,07	387,62	80
2800	10	10,15	2,976	420,7	74
3000	10	9,5	2,985	441,54	68
3200	10	9,2	3,083	441,78	103
3400	10	8,85	3,151	453,19	150
1200	20	9,5	1,194	551,1	180
1400	20	9,775	1,433	538,73	175
1600	20	9,8	1,642	506,09	144

1800	20	9,875	1,861	483,61	108
2000	20	10,3	2,157	458,97	96
2200	20	10,95	2,523	414,98	65
2400	20	10,9	2,739	388,1	78
2600	20	10,175	2,77	426,35	93
2800	20	9,475	2,778	438,81	47
3000	20	9	2,827	446,78	88
3200	20	8,95	2,999	452,82	125
3400	20	8,525	3,035	461,94	162
1200	30	9,75	1,225	572,25	183
1400	30	10,075	1,477	526,07	164
1600	30	10,25	1,717	495,05	156
1800	30	10,3	1,941	489,44	117
2000	30	10,75	2,251	451,36	91
2200	30	11,4	2,649	398,26	83
2400	30	10,575	2,658	398,8	74
2600	30	9,85	2,682	425,8	63
2800	30	9,325	2,734	426,48	89
3000	30	9,2	2,89	432,87	113
3200	30	8,65	2,899	453,95	117
3400	30	7,875	2,804	487,52	158

Ek 3. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II öklit minimizasyonu

Devir	Öklit	HC	SFC	Güç	Tork	Nox	CO2	Afr	Fuel Rate	Yük	Pboost
1000	274,7232	60,8729	240,9978	65,84632	2,202284	96,57895	4,39329	1403,605	16,400469	99,72239	134,2
1100	271,31079	64,0759	242,5008	61,76042	2,434556	82,80038	4,58358	1298,44	16,320567	100	134,2
1200	270,27283	56,128	241,3288	64,49063	2,540667	86,42833	4,70164	1269,983	18,637732	99,65298	134,2
1300	268,32949	60,2176	241,9618	62,33595	2,416457	76,91123	4,69926	1237,815	18,717634	100	134,2
1400	266,50877	55,3552	244,4411	57,61938	4,030123	69,61923	5,3093	997,7894	19,676461	98,95894	134,2
1500	265,80994	55,5867	245,6245	55,53559	4,521843	64,02166	5,49903	917,3686	20,155875	99,79179	134,2
1600	266,42684	64,393	243,239	49,74352	10,28474	71,16568	5,18318	548,6701	23,951232	62,52199	134,2
1700	263,38008	57,7877	244,9392	55,47654	3,569176	53,99223	5,37617	916,1314	21,634066	100	134,2
1800	261,21705	36,9643	242,7111	57,00476	10,54545	67,5459	6,0099	561,0425	27,78654	82,37146	134,2
1900	259,93163	34,815	241,3271	63,41117	4,504737	63,55665	5,73621	840,6595	27,746588	99,86119	134,2
2000	258,93553	38,3024	242,8742	55,71535	9,579205	57,97048	6,01065	510,3155	29,104927	82,92669	135,7419
2100	258,20926	32,2495	244,1046	58,34457	6,986885	50,52204	6,29003	610,5323	29,144878	99,9306	134,2
2200	257,50119	25,9562	240,5375	64,74184	5,808261	59,26585	6,09719	679,8179	32,261065	99,86119	134,2
2300	256,36511	29,4773	242,384	60,48722	6,046166	48,69071	6,17345	604,346	31,781652	99,9306	134,2
2400	255,78358	23,1165	241,5839	62,53578	7,410681	50,21203	6,41744	528,8742	34,258622	100	134,2

Ek 4. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II sfc optimizasyonu

Devir	Öklit	HC	SFC	Güç	Tork	Nox	CO2	Afr	Fuel Rate	Yük	Pboost
1000	1469,2584	37,2176	150,4967	137,417	1069,983	985,3307	7,9237	283,9	34,058866	100	1711,52
1100	1468,4187	38,3272	151,3153	135,4937	1069,98	984,1812	7,78971	285,1372	34,138768	100	1711,52
1200	1467,3901	39,6044	152,1222	133,3161	1069,976	982,7737	7,6541	285,1372	34,138768	100	1711,52
1300	1466,0698	39,6547	152,9123	132,8161	1069,972	980,7497	7,54623	283,9	34,857889	100	1711,52
1400	1464,5847	42,393	153,7394	128,8473	1069,964	978,8236	7,38449	283,9	34,138768	100	1711,52
1500	1462,0555	39,9645	154,6257	131,4014	1069,958	974,6638	7,31846	283,9	36,136325	99,9306	1709,978
1600	1459,1184	40,1631	155,4331	130,6861	1069,948	970,2236	7,20447	285,1372	36,735591	100	1711,52
1700	1457,4521	47,7638	156,2624	121,6437	1069,928	968,4396	6,97961	283,9	33,978964	100	1711,52
1800	1452,1134	43,5051	157,1085	125,3207	1069,913	959,9946	6,94027	283,9	36,415982	100	1711,52
1900	1449,2892	51,2629	158,0122	117,3962	1069,877	956,232	6,73058	283,9	34,138768	99,86119	1711,52
2000	1440,9222	45,5168	158,8556	121,8552	1069,848	943,1229	6,71406	283,9	36,895396	99,9306	1711,52
2100	1434,1359	47,7559	159,7464	119,0225	1069,792	932,8886	6,5908	283,9	36,69564	99,86119	1711,52
2200	1421,7495	42,9587	160,629	123,0367	1069,734	913,3519	6,57563	283,9	39,292463	99,9306	1711,52
2300	1413,9556	47,0224	161,4898	118,1722	1069,621	901,6012	6,43596	283,9	38,253734	100	1711,52
2400	1404,8726	51,6986	162,3809	113,4807	1069,456	887,6788	6,30037	283,9	37,294907	100	1711,52

Ek 5. 300PS E1 J1 Yüksek Torklu Dizel Motor değişken yük NSGA II HC optimizasyonu

Devir	Öklit	HC	SFC	Güç	Tork	Nox	CO2	Afr	Fuel Rate	Yük	Pboost
1000	896,58977	2,47634	224,2517	123,3618	732,597	448,9811	8,81609	283,9	49,400098	100	134,2
1100	811,99137	2,52692	224,6199	121,5276	648,6344	416,2887	8,81775	283,9	49,48	100	134,2
1200	723,25077	2,58864	225,0685	119,4422	557,3656	383,9646	8,80637	283,9	49,48	99,9306	134,2
1300	636,88774	2,66036	225,6262	117,128	466,0017	351,7926	8,78488	283,9	49,400098	100	134,2
1400	561,07535	2,73505	225,9986	115,2361	381,5471	323,7104	8,7611	283,9	49,48	100	134,2
1500	495,39309	2,82463	226,4582	113,106	305,661	296,3533	8,72458	283,9	49,48	100	134,2
1600	441,71344	2,92977	226,9596	110,8522	241,1156	270,354	8,67691	283,9	49,440049	100	134,2
1700	400,87039	3,0431	227,3759	108,8122	189,2521	247,502	8,62316	283,9	49,48	100	134,2
1800	369,2417	3,17593	227,8333	106,654	147,9088	226,0443	8,55767	283,9	49,48	100	134,2
1900	345,22509	3,32769	228,2895	104,4919	115,795	206,529	8,48198	283,9	49,48	100	134,2
2000	327,1148	3,51287	228,7073	102,2945	90,66569	189,552	8,38794	283,9	49,48	99,72239	134,2
2100	312,81912	3,70364	229,1877	100,1586	72,19355	173,2125	8,29723	283,9	49,48	99,9306	134,2
2200	301,70192	3,92893	229,6474	98,01026	57,88665	158,8921	8,19234	283,9	49,48	100	134,2
2300	292,68488	4,19981	230,1345	95,75301	46,77263	145,8197	8,07328	283,9	49,440049	100	134,2
2400	285,93709	4,49496	230,5412	93,72053	38,39112	135,1665	7,94767	283,9	49,48	100	134,2

Ek 6. 300PS E1 J1 Yüksek Torklu Dizel Motor tam yük NSGA II sfc (yakıt tüketimi) optimizasyonu

Devir	Öklit	HC	SFC	Güç	Tork	Nox	CO2	Afr	Fuel Rate	Yük	Pboost
1000	906,097	27,65114	233,8984	61,82898	748,1322	449,402	7,223595	346,5	20,79	100	421,29
1100	1115,77	24,27987	212,8897	76,90536	867,3783	663,857	7,434332	431,6	24,17	100	603,2
1200	1450,08	29,40383	184,5192	103,6069	1057,999	968,331	7,609597	445,2	29,88	100	966,91
1300	1445,33	32,5911	185,3493	101,4109	1053,668	965,923	7,484791	445,2	29,88	100	966,91
1400	1455,96	38,5895	179,4199	111,3987	1061,974	972,561	7,152752	508	31,97	100	1110,2
1500	1454,63	40,70671	176,8623	118,3243	1064,151	967,746	6,845566	557,9	33,75	100	1208,6
1600	1455,39	39,18441	172,1033	123,4068	1067,948	964,994	6,883664	497,8	35,91	100	1319,3
1700	1443,28	38,45618	169,7975	131,7616	1068,596	945,22	6,641025	538,6	38,37	100	1438,6
1800	1420,32	37,40433	168,6246	139,7042	1068,761	908,664	6,447987	583,9	41	100	1542,6
1900	1395,62	37,36232	169,284	143,0119	1068,314	869,429	6,2791	625,8	42,46	100	1590
2000	1373,67	39,72984	170,3294	140,5832	1067,357	835,058	6,056182	665,4	41,66548	100	1624,4
2100	1349,86	42,76408	171,5281	137,621	1065,719	797,591	5,834215	708,9	40,64286	100	1658,7
2200	1221,57	38,06784	188,4955	132,3657	951,8341	729,195	5,51841	848,00117	42,71333	100	1238,5
2300	1290,21	41,8479	175,9425	140,6208	1056,291	704,539	5,57507	805	42,93984	100	1668,6
2400	1258,22	45,18775	177,7874	138,1536	1046,923	659,011	5,345632	874,2	41,87556	100	1711,5

Ek 7. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II öklit minimizasyonu

Devir	Öklit uzaklık	HC	SFC	Güc	Tork	Avans
1200	577,8656579	166,564015	553,249915	1,234248	9,907354	30
1400	558,0195838	153,429361	536,417391	1,463711	9,976333	30
1600	525,4314441	141,446041	505,935681	1,653699	9,877851	20,52785924
1800	485,336907	134,218238	466,297624	1,856829	10,02277	11,5542522
2000	437,1954165	149,542672	410,692223	2,12971	10,20704	0
2200	401,4356079	132,869787	378,648697	2,502777	10,72695	0
2400	384,633998	127,914287	362,563801	2,807267	10,9935	0
2600	380,4084129	123,041791	359,777037	3,033893	11,07056	0
2800	386,2017701	119,256291	367,149333	3,216422	10,98937	0
3000	397,1661107	118,145487	379,01972	3,368764	10,73623	0
3200	414,7880293	131,762395	393,154774	3,550795	10,22233	0
3400	414,7880293	131,762395	393,154774	3,550795	10,22233	0

Ek 8. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II sfc minimizasyonu

Devir	Öklit uzaklık	HC	SFC	Güc	Tork	Avans
1200	577,8877231	166,664379	553,24403	1,237147	9,834531	29,09090909
1400	558,6430837	163,49786	534,095663	1,427374	9,504218	19,58944282
1600	526,2019289	152,763348	503,445005	1,598867	9,612496	12,69794721
1800	487,0610337	155,512248	461,46675	1,774848	9,469942	0,674486804
2000	437,1954165	149,542672	410,692223	2,12971	10,20704	0
2200	401,4356079	132,869787	378,648697	2,502777	10,72695	0
2400	384,633998	127,914287	362,563801	2,807267	10,9935	0
2600	380,4084129	123,041791	359,777037	3,033893	11,07056	0
2800	386,2017701	119,256291	367,149333	3,216422	10,98937	0
3000	397,1661107	118,145487	379,01972	3,368764	10,73623	0
3200	414,7880293	131,762395	393,154774	3,550795	10,22233	0
3400	414,7880293	131,762395	393,154774	3,550795	10,22233	0

Ek 9. Briggs ve Stratton Vanguard Benzinli Motor değişken avans NSGA II HC minimizasyonu

Devir	Öklit uzaklık	HC	SFC	Güc	Tork	Avans
1200	577,8656579	166,564015	553,249915	1,234248	9,907354	30
1400	558,0195838	153,429361	536,417391	1,463711	9,976333	30
1600	525,4314441	141,446041	505,935681	1,653699	9,877851	20,52785924
1800	485,336907	134,218238	466,297624	1,856829	10,02277	11,5542522
2000	437,1954165	149,542672	410,692223	2,12971	10,20704	0
2200	401,4356079	132,869787	378,648697	2,502777	10,72695	0
2400	384,633998	127,914287	362,563801	2,807267	10,9935	0
2600	380,4084129	123,041791	359,777037	3,033893	11,07056	0
2800	386,2017701	119,256291	367,149333	3,216422	10,98937	0
3000	397,1661107	118,145487	379,01972	3,368764	10,73623	0
3200	414,7880293	131,762395	393,154774	3,550795	10,22233	0
3400	414,7880293	131,762395	393,154774	3,550795	10,22233	0

Ek 10. Briggs ve Stratton Vanguard Benzinli Motor 10 avans NSGA II sfc (yakıt tüketimi) optimizasyonu

Avans	Öklit	HC	SFC	Guc	Tork
10	615,554683	205,49985	580,17108	1,088458	8,815644
10	565,861622	160,58163	542,52071	1,33577	9,078089
10	615,554683	205,49985	580,17108	1,088458	8,815644
10	486,723128	142,38605	465,32047	1,846034	9,953306
10	451,499405	131,01084	431,94308	2,164879	10,40977
10	428,952041	127,85677	409,30602	2,47265	10,72244
10	418,586216	124,75687	399,40624	2,695453	10,84142
10	420,07666	122,22476	401,74906	2,833771	10,7319
10	431,283628	121,27091	413,74429	2,92918	10,2967
10	447,288673	123,52245	429,77669	3,018456	9,604343
10	462,321627	131,19527	443,21187	3,123185	9,086999
10	474,068499	146,23731	450,84902	3,247628	8,955579