

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**GEMİ YAPILARINDA GERİLME YIĞILMASI ÖNGÖRÜLERİNİN KABA
AĞ YAPISI VE MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

**Burçin ATEŞ
(508171104)**

Gemi ve Deniz Teknolojileri Mühendisliği Ana Bilim Dalı

Gemi ve Deniz Teknolojisi Mühendisliği Programı

TEMMUZ 2020



İSTANBUL TEKNİK ÜNİVERSİTESİ ★FEN BİLİMLERİ ENSTİTÜSÜ

**GEMİ YAPILARINDA GERİLME YIĞILMASI ÖNGÖRÜLERİNİN KABA
AĞ YAPISI VE MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

**Burçin ATEŞ
(508171104)**

Gemi ve Deniz Teknolojileri Mühendisliği Ana Bilim Dalı

Gemi ve Deniz Teknolojisi Mühendisliği Programı

Tez Danışmanı : Dr. Öğr. Üyesi Serdar Aytekin KÖROĞLU

TEMMUZ 2020



İTÜ, Fen Bilimleri Enstitüsü'nün 508171104 numaralı Yüksek Lisans Öğrencisi Burçin ATEŞ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "GEMİ YAPILARINDA GERİLME YIĞILMASI ÖNGÖRÜLERİNİN KABA AĞ YAPISI VE MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Dr. Öğr. Üyesi Serdar Aytekin KÖROĞLU**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Dr. Öğr. Üyesi Bilge TUTAK**
İstanbul Teknik Üniversitesi

Doç. Dr. İsmail BAYER
Yıldız Teknik Üniversitesi

Teslim Tarihi : 14 Haziran 2020

Savunma Tarihi : 20 Temmuz 2020





Aileme,



İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ	vii
İÇİNDEKİLER	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ	xiii
ŞEKİL LİSTESİ	xv
ÖZET	xvii
SUMMARY	xix
1. GİRİŞ ve LİTERATÜR	1
1.1 Tezin Amacı ve Kapsamı.....	1
1.2 Literatür	1
1.2.1 Yapı	1
1.2.2 Makine öğrenmesi.....	4
2. YORULMA	7
2.1 S-N Eğrileri ile Yorulma Analizi.....	10
2.2 Gerilme Yığılma Faktörü ile Analiz	13
2.3 Sıcak Nokta (Hot-Spot) Analizi	14
3. SONLU ELEMENLAR YÖNTEMİNİN GEMİ YAPISAL ANALİZİNDE KULLANIMI	19
3.1 Klas Kuralları	21
3.1.1 BV : Bureau Veritas - Fransa Loydu.....	21
3.1.2 ClassNK : Nippon Kaiji Kyokai - Japon Loydu	26
3.1.3 DNV-GL : Det Norske Veritas - Germanischer Lloyd - Norveç-Alman Loydu	28
3.2 Ağ Hassasiyetinin Önemi.....	31
4. PARAMETRİK ANSYS MODELİ	35
5. MAKİNE ÖĞRENMESİ	37
5.1 Makine Öğrenmesi Nedir.....	37
5.2 Çeşitleri - Uygulama Alanları	38
5.2.1 Denetimli öğrenme.....	39
5.2.2 Denetimsiz öğrenme	41
5.2.3 Yarı denetimli öğrenme.....	41
5.2.4 Takviyeli öğrenme.....	42

5.3 Regresyon Modelleri ve Kullanımı.....	43
5.3.1 Doğrusal regresyon	43
5.3.2 Lojistik regresyon	45
5.3.3 Polinom regresyonu.....	46
5.3.4 Destek vektör regresyonu	46
5.3.5 Karar ağacı regresyonu	48
5.3.6 Rastgele orman regresyonu	48
5.3.7 Bayes regresyonu.....	50
5.3.8 Gauss süreci regresyonu	52
5.3.9 Regresyon için kernel makineleri	54
5.3.10 Transformasyon	57
6. MAKİNE ÖĞRENMESİ İLE KABA AĞ ÜZERİNDEN TAHMİN	61
6.1 Modelin Oluşturulması ve Veri Üretimi	61
6.2 Verilerin İşlenmesi.....	72
6.3 Algoritma Kullanımı.....	75
7. SONUÇLAR VE TARTIŞMA	79
KAYNAKLAR	87
ÖZGEÇMİŞ	91

SEMBOLLER

$\Delta\sigma_R$: Doğrudan gerilme aralığı

$\Delta\tau_R$: Kesme gerilmesi aralığı

N : Gerilme aralığı hatasına ilişkin tahmini döngü sayısı

$\Delta\sigma$: Mpa birimi ile gerilme aralığı

m : S-N eğrisinin negatif ters eğimi

$\log a$: LogN ekseninin S-N eğrisiyle kesişimi

δm : Yanlış hizalama, eksantrisitedir ve t plaka kalınlığı

δo : 0.1 t alın kaynaklarına özgü yanlış hizalama

δt : $1/2 (T - t)$, kalınlıktaki değişiklik nedeniyle oluşan eksantriklik

T : Kalın plaka kalınlığı

t : İnce plaka kalınlığı

$K_{g_{Loc}}$: Yerel geometrik gerilme yığılma faktörü

Nom_{Loc} : Nominal lokal gerilme aralığı

$K_{g_{hg}}$: Gövde kirişi geometrik gerilme yığılma faktörü

Nom_{hg} : Nominal gövde kiriş gerilme aralığı

σ_{VM} : Ortalama Von Mises eşdeğer gerilmesi

σ_{master} : İzin verilen ana gerilme değeri

K_{sc} : Tarama faktörü

λ_{sc} : Kullanım faktörü

σ_{FM} : Ele alınan detay için N / mm^2 cinsinden Von Mises ince ağ yapısı gerilmesi

σ_{CM} : Ele alınan detay için N / mm^2 cinsinden Von Mises kaba ağ yapısı gerilmesi

σ_c : Von Mises kaba ağ gerilmesi, N / mm^2

$\lambda_{f_{perm}}$: İnce ağı izin verilen gerilme değeri verim kullanım faktörü

R_y : Nominal verim gerilmesi, $235 / k$ 'ye eşit



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Üç boyutlu modelin tamamının sınır koşulları.	22
Çizelge 5.1 : Scikit-learn kütüphanesinde kullanılan transfromasyon teknikleri.	59
Çizelge 6.1 : Modelde kullanılan bağımsız parametreler.	62
Çizelge 6.2 : Parametrelerin kullanımına bir örnek.	63
Çizelge 6.3 : Modelde kullanılan bağımlı parametreler.	64
Çizelge 6.4 : Metrik sistemler..	78
Çizelge 7.1 : Değişen yarıçapa göre hata oranları.....	79
Çizelge 7.2 : Veri sayısı 2000 olan modelin hata sonuçları.	80





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Katodik korumalı deniz suyunda S-N eğrileri ve sınıfları.	12
Şekil 2.2 : Halkalı takviyeli eleman.	15
Şekil 2.3 : T eklemünde sıcak nokta türleri; çentik gerilmesi, sıcak nokta gerilmesi, nominal gerilme.	16
Şekil 2.4 : Kaynaklı yapılarda sıcak nokta çeşitleri.	16
Şekil 2.5 : Kenar mesafesi belirtilen farklı yapılar.	17
Şekil 3.1 : Bir konteyner gemisinin tipik küresel sonlu eleman modeli.	21
Şekil 3.2 : Referans koordinat sistemi.	23
Şekil 3.3 : Sonlu elemanlar modelleme kriterleri.	24
Şekil 3.4 : Sonlu eleman analizinin minimum gereksinimleri.	27
Şekil 3.5 : Sıcak nokta gerilmesinin türetilmesi örneği.	29
Şekil 3.6 : Kabuk sonlu eleman modeli kullanarak sıcak nokta gerilmesinin türetilmesi.	30
Şekil 3.7 : Sıcak nokta hesaplaması için vinç tabanı ince aralıklı ağ yapısı.	32
Şekil 3.8 : Bir açıklığın etrafında ince ağ örülmüş bölge.	32
Şekil 3.9 : Braket etrafına örülü ince ağ.	33
Şekil 5.1 : Makine öğrenmesinin basit bir ifadesi.	37
Şekil 5.2 : Çeşitli makine öğrenim yöntemlerinin örgütsel özeti.	38
Şekil 5.3 : Denetimli öğrenme araçlarından en sık kullanılanlar.	40
Şekil 5.4 : En küçük kare yöntemi grafiği.	44
Şekil 5.5 : Sigmoid fonksiyonu olarak adlandırılan lojistik fonksiyon.	45
Şekil 5.6 : Polinom regresyonu grafik örneği.	46
Şekil 5.7 : Destek vektör regresyonu örneği.	47
Şekil 5.8 : Destek vektör regresyonu hata-duyarsız fonksiyonu.	47
Şekil 5.9 : Rastgele orman regresyon örneği.	49
Şekil 5.10 : Farklı α ve β değerleri için Bayes regresyonu.	51
Şekil 5.11 : Bir standart sapma hata çubuğu ile Gauss işlemi regresyonu: (a) Doğrusal kernel, (b) Kuadratik kernel, (c) Yayılmış Gauss kerneli.	53
Şekil 5.12 : Kernel işlevi.	54
Şekil 5.13 : Kernel bazlı regresyon ve cezalı regresyon gösteren sentetik bir örnek.	56
Şekil 5.14 : Yeo-Johnson dönüşümünün matematiksel gösterimi.	58
Şekil 5.15 : Box-Cox dönüşümünün matematiksel gösterimi.	58
Şekil 6.1 : Gövde stifneri.	61
Şekil 6.2 : Ansys modeli.	65
Şekil 6.3 : Modelin yükleme durumları ve sınır koşulları.	65
Şekil 6.4 : Aynı parametre seti için kaba ağ (üst) ve ince ağ (alt) yapıları örneği.	66
Şekil 6.5 : İnce ağ yapısı detaylı görünüm.	67
Şekil 6.6 : Kaba ağ yapısı detaylı görünüm.	67
Şekil 6.7 : Aynı parametre seti için ince ağ (üst) ve kaba ağ (alt) yapıları Von Mises gerilmesi kontur gösterimi.	68
Şekil 6.8 : Her parametre setinde değişen model tipleri için birkaç örnek.	69
Şekil 6.9 : Ansys çıktı dosyası değerleri.	70
Şekil 6.10 : Ansys programında gerilme sonuçlarının listelenmesi.	71
Şekil 6.11 : Ansys programında düğüm noktalarının koordinatlarının listelenmesi.	72

Şekil 6.12 : Verilerin filtrelenmesi için kullanılan kod.	73
Şekil 6.13 : Makine öğrenmesi için kullanılacak verilerin hazırlandığı kod.....	74
Şekil 7.1 : Gauss süreci regresyonu çizimi.....	81
Şekil 7.2 : Değişen parametrelere bağlı hata değerleri.....	82
Şekil 7.3 : Değişen parametrelere göre R2 hata değeri.....	82
Şekil 7.4 : Hata oranları arasındaki fark.	83
Şekil 7.5 : Ridge regresyonu değişen alfa parametre değeri.	83
Şekil 7.6 : Parametrelerin dağılım grafikleri.....	84
Şekil 7.7 : Tahmin ve gerçek gerilme değerlerinin dağılım grafikleri.....	85
Şekil 7.8 : Makine öğrenmesi verilerinin korelasyonu.....	85
Şekil 7.9 : Farklı regresyon modellerinde ortalama mutlak hata değişimi.	86



GEMİ YAPILARINDA GERİLME YIĞILMASI ÖNGÖRÜLERİNİN KABA AĞ YAPISI VE MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ

ÖZET

Gemi ve deniz yapılarının tasarımında dikkate alınması gereken limit durumlar vardır. Servis limit durumunda (SLD) global ölçekte ve kaba ağ yapısıyla analizler yapılır. Yorulma limit durumunda , SLD'de gözükmeyen ve yapının özellikle süreksizlikler veya ani değişim gösteren bölgelerinde bulunan gerilme yığılmalarına ve bu gerilmelerin yorulma ömrüne olan etkisine yoğunlaşılır.

Sıcak nokta gerilmesi denilen ve sonlu elemanlar analizi ile ekstrapolasyon kullanılan hesap yaklaşımında, yapının yerel ve SLD'de kullanılabilecek kıyasla çok daha yüksek çözünürlükte bir ağ yapısının kullanıldığı bir model üretilir. Bu modelin analiz süresi, ağ yapısı ve farklı yükleme durumlarının da katkısıyla yüksek hesaplama maliyetlerine yol açmaktadır. Bu durum özellikle tasarım için gerekli parametrik çalışmaların pratikte yapılmasını zorlaştırmaktadır.

Makine öğrenmesi, genel bir matematik model kullanımı yerine, deney yoluyla elde edilen veya karmaşık matematiksel modellerden üretilen verilerden yola çıkılarak kurulan yaklaşık modellerin anlam çıkarma, tahmin gibi amaçlarla kullanılmasını sağlayan istatistiksel yöntemleri ifade eder.

Gerilmeler, yapısal mekanik analizlerin çoğunda incelenir. Yorulma dayanımını etkileyen faktörlerden bazıları, malzeme tipi, ortalama ve artık gerilme, kalite ve kaynak kusurları gibi imalat faktörleri ve son olarak boyut ve plaka kalınlığıdır. Yorulma, yeterince yüksek bir güvenlik seviyesi sağlamak için gemilerde önemli bir tasarım kriteridir. Bir yapıda şekil veya kesitte ani bir değişiklik olan bölgeler süreksizlik nedenidir ve gemi söz konusu olduğunda kabaca birçok yapının birleşimi olduğu düşünülürse bu tarz süreksizlikler kaçınılmazdır. Çeşitli konumlardaki (örn. ambar kapağı köşelerinde, kaynak ağzlarında, perdelerde, takviye uçlarında, kiriş ağ plakalarında ve çift dipli sintine alanlarında, enine stifner bağlantılarında..vb) gerilme yığılmaları nedeniyle yorulma meydana gelir. Bu tür gerilme yığılmalarının değerlendirmesi yapısal tasarımda normal gerilme analizinden farklıdır. Buradaki amaç akma gerilmesinden ziyade süreksizlik bulunan noktada lokal bir değerlendirme yapıp yorulma nedeniyle oluşan kırılma ve çatlama gibi durumların değerlendirilmesidir.

Gemi yapılarında enine stifner bağlantıları veya T birleşim noktaları gibi çeşitli kaynaklı bölgelerde gerilme yığılmaları meydana gelir. Bu bölgelerden klas kuruluşları da incelendiğinde çok sık karşılaşılan bir problem olan, T şeklinde iki plakanın birleşiminden oluşan yapısal bir modelin gerilme yığılmaları bu çalışma kapsamında incelenmiştir. Modelin simülasyonu Ansys APDL Script programlama dilinde parametrik model kodu oluşturularak yapılmıştır. Seçilen bağımsız parametreler ile modelin boyutu, kalınlığı, yük durumu ve ağ boyutları düzgün dağılımlı rastgele değişmektedir. Aynı zamanda değişen parametrelerin sınırları gemi inşaatı alanında kullanılmaya uygun olacak şekilde genişletilmiştir. Böylece modelin çok değişkenli birden fazla durumunu gözlemek mümkün olmuştur. Modelde gemi tasarımı sırasında uyulması gereken klas kuruluşlarının belirlediği kurallara göre yapılan gerilme hesaplaması referans değerler olarak kabul edilmiştir. Bu gerilme hesaplamalarında plakaların kalınlığı kadar ($t \times t$) hassas bir ağ yapısı uygulanıp gerilme değerleri elde edilmiştir. Sonra aynı model ağ hassasiyeti azaltılarak daha kaba bir ağ ile analiz

edilmiştir. Yapılan analizlerde önce 200 farklı durum incelenmiş olup sonra veri sayısı arttırılarak 2000 farklı analiz yapılmıştır. Kaba ağ yapısına sahip modelden çekilen gerilme değerleri (aynı zamanda modeldeki gerilme yayılımını ölçmek için meta parametre olan) bir yarıçap kadar alanda taratılmıştır. Alan etkisi önemli bir parametredir. Çünkü yığılmanın meydana geldiği noktadan iki farklı yarıçap parametresi ile uzak ve yakın alanlardan mantıklı gerilmeler alınarak, etkisiz noktalardaki değerlerin modelde oluşturacağı sapmaların önüne geçilmiştir. Taratılan alanda oluşan gerilme dağılımının ortalaması ve standart sapması da makine öğrenmesi uygulaması için bir girdi oluşturacaktır. Amaç, kaba ağ yapılı bir analizden elde edilen gerilmelerin dağılımı, varyansı, ağ boyutu, maksimum gerilmesi gibi farklı etmenler ile makineye problemi öğretip referans gerilme değerini tahmin etmektir. Bu çalışma ile seçilen parametrelerin tahminde etkili olduğu gözlenmektedir. Örneğin ağ boyutu makine öğrenmesi girdilerinden çıkarıldığında kök ortalama kare hata dikkate alınırsa 2 kat artmaktadır, veya her iki model için ekstrapole edilmiş gerilme değerleri yerine maksimum gerilme değerlerine göre hata hesaplandığında yine 1,7 kat artış gözlemlenmektedir. Hesaplanan hata oranları makine öğrenmesi yöntemlerinden Gauss süreci regresyon analizi sonucunda elde edilen değerlerdir. Sonuç olarak, bir regresyon analizi yapılarak hassas ağ yapılı modelin gerilme sonuçları tahmin edilmekte ve böylece büyük ölçekli yapıların tasarımında zaman ve bilgi tasarrufu sağlanmaktadır.

THE FORECASTING OF STRESS CONCENTRATION IN SHIP BUILDINGS BY USING ROUGH MESH STRUCTURE AND MACHINE LEARNING METHOD

SUMMARY

Stress is studied in most structural mechanical analyzes. Ship structures are inclined to fatigue due to the high cyclic loading caused by waves, as well as changing cargo distributions and exciting vibrations. Apart from these, other factors are affecting fatigue strength such as; material type, average and residual stress, quality and welding defects of manufacturing factors, and size and plate thickness. Fatigue is an important design criterion for ships to provide a sufficiently high level of safety.

Regions with a sudden change in shape or cross-section in a building are the cause of discontinuity, and such discontinuities are inevitable when the ship is considered to be a combination of many structures. Cracking occurs due to stress build-up in various locations (e.g. hatch cover corners, weld mouths, curtains, stiffener ends, beam web plates and double bottom bilge areas, transverse stiffener connections, etc.). The evaluation of such stress concentrations differs from the normal stress analysis in structural design. It is important to make a local assessment at the point where there is discontinuity rather than yield stress and to evaluate the conditions such as breakage and cracking caused by fatigue. Using the finite element method, stress concentrations that may occur in the discontinuities in the ship structure are calculated due to internal loads such as bending moments and shear forces. Multi-node mesh structure (fine mesh) is required for analysis of regions with stress concentrations such as a source or the perimeter of a crack in local calculations.

Calculations on this subject require fine mesh, which is a very time-consuming analysis, it is also disadvantageous in terms of the space it takes up on the computer. For example, in the thesis work, the analysis time started with a fine mesh structure for 2000 data lasted 5 and a half hours, and the analysis with a rough mesh structure took only 35 minutes. In the study to be performed, the goal is to calculate with a coarse mesh, to reach usable results without the need to calculate with a fine mesh. At the same time, this will be considered as an optimization problem and applications will be made. Thus, the scope of application of shell finite element analysis will be expanded to further improve local approaches.

Stress concentration occurs in various welded areas such as transverse stiffener joints or T junctions in ship structures. When class institutions are also examined, the stress concentrations of a structural model consisting of two T-shaped plates, which is a very common problem, are investigated within the scope of this study. The simulation of the model was done by creating parametric model code in Ansys APDL Script programming language. Randomly distributed properly independent parameters are selected as; base plate thickness, top plate thickness, base plate width, base plate aspect ratio, top plate aspect ratio, mesh size random values, force in the x-direction, force in the y-direction, force in the z-direction. The change interval of parameters is respectively; 10 - 40 mm (thickness), 1 - 4 m (width), 1.2 - 2 (aspect ratio), 0 - 1 (mesh size), $6.00\text{E}+02$ - $6.00\text{E}+04$ N (forces). The force limits are chosen in this way to ensure that the maximum stress range is spread from 2,8 MPa to 280 MPa. Because of the observing all possible multivariate states of the model, the limits of the other independently changing parameters have been extended to be general usage in the shipbuilding area.

Stress calculations made according to the rules determined by the class organizations that should be followed during the ship construction are accepted as reference values. In these stress calculations, a mesh is applied to the model as much as the thickness of the plates ($t \times t$) and stress values are obtained. Then, the same model analyzed again with a coarser mesh, reducing mesh sensitivity. For fine mesh, ($t \times t$) is used as the plate thickness, while coarse mesh is used in the mesh size in the range of $(3t \times 3t) - (5t \times 5t)$. The structure is held on all four sides, it does not have a free edge. So there are restrictions on displacement in the x, y, z directions. The applied forces, on the other hand, were created in the middle of the upper plate using the mpc_gen function, and the main node was created and transmitted to other points. Mpc represents the multipoint restriction elements used to find node forces. These analyzes first examined 200 different situations and then 2000 different situations were investigated to observe the effect of the increase in the number of data. As a result of the analysis, each node coordinate, principal and Von Mises stresses were taken as an array format from the Ansys package program.

In the data discovery and cleaning step following the data collection step, the data of the model whose simulation is completed with the Ansys program and the output values are obtained will be done with the help of the Python program. A filtering operation will be carried out over the recorded stress values and node positions for each data set.

Filtering was done over the node where the maximum Von Mises stress occurred. The stress values taken from the model consisting of few nodes are also scanned in a field up to a radius which is the meta parameter to measure the stress spread in the model. Filtering effect is an important parameter. Because two different radius parameters from the point where the accumulation occurs, sensible stresses are taken from distant and close areas, and deviations from the values in ineffective points in the model are prevented. The mean and standard deviation of the stress distribution in the scanned area will also be an input for the machine learning application.

Machine learning is defined as usage algorithms and calculation statistics to learn data from them without being explicitly programmed. The variables (numerical or categorical) are evaluated and an output is presented to estimate the problem. It is a subdivision of the artificial intelligence field in computer science. Today, machine learning has come to the fore, abundance of data, more efficient data storage and faster computers. There are many different ways to enable a computer to learn from data, which can be divided into four main subdivisions of machine learning: supervised learning, unsupervised learning, semi-supervised learning and reinforcement learning.

Common algorithms in supervised learning include logistic regression, Bayesian approach, support vector machines, neural networks and random forests. In both regression and classification, the aim is to find specific relationships or structures that allow us to effectively produce the correct output data in the input data. Noisy or incorrect data labels will clearly reduce the effectiveness of the model. Model complexity refers to the complexity of the function that is tried to learn, similar to the degree of polynomial. The appropriate level of model complexity is usually determined by the quality of the training data. If you have a small amount of data or your data is not evenly distributed in different possible scenarios, a low complexity model should be preferred.

The Gaussian process regression (GPR) is a nonparametric Bayesian approach to regression that fluctuates in machine learning which is selected for the problem. There are several benefits that GPR works well in small data sets and can provide uncertainty measurements on estimates. The Bayesian approach determines a probability distribution on all possible values. In this approach, we see the parameters

as random variables distributed before. Other guided learning methods also learn exact values for each parameter. Calculates the probability distribution on all acceptable functions suitable for GPR data.

Machine learning algorithm was applied by using Scikit-learn, Numpy, Pandas libraries in python program. Data has 6 input values for x values; mesh size, the standard deviation of the strains filtered according to the parameter r1, the average of the strains filtered according to the parameter r1, the standard deviation of the values filtered according to the parameter r2, the average of the values filtered according to the parameter r2, the extrapolated tension value obtained from the coarse mesh results. For the y value, 1 output value is assigned to the extrapolated stress value obtained from the fine mesh results.

Values are classified as 20% test and 80% training data. After the data are separated as training and test data, the selected kernel function is defined. Kernel functions depend on the individual's choice, and in this problem, since the Gauss process will be regressed, the radial based kernel (RBF) function has been preferred. Other kernel functions were also tried and it was preferred to use a single kernel coefficient instead of multiple kernels. It is the radial basis function (RBF) kernel used in this equation, encoding the smoothness of functions, where the similarity of the inputs in space corresponds to the similarity of the outputs. The two parameters of this kernel are the length scale (l) and the lower and upper limit on this scale, respectively. If these limits are set to fixed, the length scale cannot be changed during the hyper parameter setting. If the data type is float, isotropic kernel and array is anisotropic kernel. After the kernel function is selected, the Gauss process regression model is assigned with Scikit-learn.

In the data set, x values and y values are scaled differently. Standard scalar conversion is applied to input values, and power transformation is applied to output value. Yeo-johnson method, which is one of the power transformations, was chosen because it produces more compatible data compared to other methods. After the model fit, y values were estimated according to the x values in the test data. Values converted by transformation were restored to their true size by inverse transformation. In order to measure the quality of estimates, the metric systems module in the scikit-learn library is based on and more than one method is applied.

The aim is to teach the machine the problem by estimating the reference stress value with different factors such as distribution, variance, mesh size, maximum stress of the stresses obtained from a rough mesh analysis. It is observed that the parameters selected with this study are effective in estimating. For example, when the mesh size is removed from the machine learning inputs, the root mean squared error increases 2 times, or when error is calculated according to maximum stress values instead of extrapolated stress values for both models root mean squared error again 1.7 times increase is observed. The calculated error rates are the values obtained as a result of the Gaussian process regression analysis, which is one of the machine learning methods. Consequently, the strain results of the fine mesh model are estimated by performing a regression analysis without the need for fine mesh analysis, thus time and information are saved in the design of large-scale structures.



1. GİRİŞ VE LİTERATÜR

1.1 Tezin Amacı ve Kapsamı

Bu projenin amacı büyük ölçekli yapıların tasarımında zaman ve bilgi tasarrufu sağlayabilmek için yöntemler geliştirmektir. Yapılacak tasarımlarda makine öğrenmesi yöntemlerini klasik analizlere uygulayarak dizayn aşamasında sürecin yavaşlamasını ve belki de açık ilerlemesini engelleyen insan faktörünün etkisi azaltılacaktır. Bu etkinin azaltılması için problemler daha parametrik hale getirilecek ve mümkün olduğunca kendini tekrar eden manuel uygulamalardan kaçınılacaktır. Gemi elemanlarını, katı eleman şeklinde ince ve kaba ağ örüntüleriyle analiz etmek ve aralarında ilişki kurmak için bir yöntem belirlenecektir. Bir geminin gövdesinin yapısal tasarımında, kabuk elemanlar küresel model için kullanılır. Çok düğüm noktasına sahip ağ ile, gerilme yığılma bölgeleri veya bir çatlağın çevresi analiz edilir. Bu gibi durumlarda modeller, küresel bir model analizinin sonuçları sınır koşulları olarak yerel bir analize aktarılır.

Yapının gerilme yığılması olan noktasında olabildiğince rafine, geri kalanında ise daha kaba bir ağ yapısı tercih edilir. Yapılan çalışmada ise ince ağ yapısı kullanmadan yapının tamamı kaba bir ağ ile değerlendirilmiştir. Önerilecek makine öğrenmesi yöntemi ile ince ağ yapısı sonuçlarına yaklaşılmaya çalışılacaktır.

Gerilme analizi sonunda yer yer subjektif yer yer kalitatif dizayn kararları için makine öğrenmesi yaklaşımıyla bir çözüm sunarak insan müdahalesinin mümkün olmayacağı optimizasyon çalışmalarına daha uygun kısıtların üretilmesi hedeflenmektedir.

1.2 Literatür

1.2.1 Yapı

Ağ yapısının ve model boyutunun sonuçları nasıl etkilediğine dair yayımlanan akademik kaynaklardan bulunan bilgiler şu şekildedir;

Femap ve NX-Nastran programlarını kullanarak bir çelik plakanın ağ boyutunun öneminin belirlendiği bir çalışmada, ağ boyutu 5 mm olan ve 10 mm ile 100 mm arasındaki değişime sahip yapı için, otomatik ağ tekniğine sahip dörtlü kabuk

elemanları kullanılarak 10 mm'lik ara adımla bir dizi sonlu eleman modeli oluşturulup eleman boyutunun statik analiz sonuçları üzerindeki etkisi incelenmiştir. Sabit yükleme ve tepki koşullarını kabul eden statik analiz için, modelden tatmin edici sonuçlar elde etmek ve daha az bilgisayar kaynağı ve bilgi işlem süresi harcamak için 40 mm boyutunda elemanlara ayrılması gerektiği bulunmuştur. Burkulma analizi için 30 ila 50 mm arasında değişen sonlu eleman modeli en iyi doğruluk ve verimlilik kombinasyonunu sağlamıştır. Bu sonuçlara dayanarak, sonlu eleman modellemesinde uygun ağ stratejisinin seçilmesine ilişkin yönergeler sunulmuştur [1].

Düzlemsel zorlanmada oluklu plak çekme numunesinin sünek kırılmasını simüle etmek için yarı-çift plastik teorisi ve mohr coulomb sünek kırılma modeli kullanılırken kabuk eleman modelinde ağ boyutu etkilerinin ortaya çıktığını gösterdi. Gerilme alanlarının lokalizasyon bölgesinde yüksek gradyanlara sahip olduğu ve sonlu eleman simülasyonlarında ağ boyutu etkilerinin lokalizasyon bölgesindeki klasik gerilme-gerinim ilişkisinin sürekli uygulanmasına neden olduğu bulunmuştur. Farklı ağ boyutları için yerel olmayan gerilme-gerinim ilişkisini kalibre etmek için eşdeğer bir eleman modeli geliştirilmiştir [2].

Farklı eleman boyutu ve tipine göre farklı sonlu eleman analizi doğruluğu elde edilen çalışmada yüksek mertebeden elemanın eğri ve yüzey sınırının sınıra yaklaşabildiği için, hexahedral elemanın hesaplama doğruluğunun tetrahedral elemandan daha yüksek olduğu, ve düğüm sayısının artırılması ile analiz hesaplama doğruluğunun arttırılabildiği gösterilmiştir [3].

Yapısal analizde ağ kalite parametrelerinin kiriş, kabuk ve 3d katı gibi elementler üzerindeki etkisinin tartışıldığı çalışmada tetrahedral elemanların ve altı yüzlü elemanların kullanımı araştırılmıştır. Diferansiyel ağ boyutları için eğilme, kesme, burulma ve eksenel deformasyonlar ve ince duvarlı yapılarda tetrahedral elemanların kalitesi ölçülmüştür. Çeşitli yapısal problemlerde lineer ve kuadratik tetrahedral elemanların ve hexahedral elemanların performansı karşılaştırıldığında (seçilen problemler kesme, burulma ve eksenel deformasyonlar gibi farklı davranış türlerini göstermektedir) kuadratik tetrahedral elemanlar ve hexahedral elemanlarla elde edilen sonuçların doğruluk açısından eşdeğer olduğu gözlenmiştir [4].

Sonlu eleman modellemesinde en iyi eleman boyutunun seçilmesine ilişkin kısa kılavuz ilkelere dayanarak, sonlu eleman boyutunun sayısal analiz sonuçlarının doğruluğu üzerindeki etkilerini bulma konusunda sistematik bir çalışma sunulmuştur. Sayısal analizde eleman boyutunun etkilerini tartışmak için bu çalışmaya statik ve burkulma analizleri dahil edilmiştir [5].

Yüksek performanslı hesaplama için oluşturulan kılavuzda ağ boyutu ile ilgili önceden gereksinimlerin belirlenmesi belirtilmiştir. Problemin büyüklüğündeki artış ile birlikte çözüm performansı azalır çünkü düğümler arasında büyük miktarda veri aktarımı olur. Ağ boyutu arttıkça hesaplamalar artar bu da daha fazla bilgisayar belleği gerektirir. Diğer yandan, daha küçük ağ boyutları çok sayıda düğümde çalıştırılmaz, sadece bellek nedeniyle değil aynı zamanda iletişimde fazladan zaman gecikmesi paralel performansta bir düşüşe neden olur. En iyi performans kaba ağ ile fazla sayıda çekirdek veya orta ağ orta sayıda işlemci çekirdeği ile elde edilebilir [6].

Uzay yapılarında statik arıza analizini inceleyen, yapışkan iz fonksiyonunda ağ boyutunun etkilerini düzelten bir yaklaşımda; daha kaba bir ağ ile sonlu elemanlar yöntemi analizi yapıldığında yapışkan bölge uzunluğu ve sonlu elemanlar yöntemi ile soyulma gerilmesi düzgün bir şekilde tahmin edilememiştir. Bunun yerine yapışkan bölge elemanlarının izin verilen soyma gerilmesinin ağ boyutu, yapışkan bölge uzunluğundaki net yapışkan sayısına uyarlanmış fonksiyonu olduğunda sonlu elemanlar yönteminin doğru sonuçlar vereceği gösterilebilir [7].

Ağ boyutunun girişin sonlu elemanlar analizi üzerindeki etkisi Dutt tarafından tanımlanmıştır. Bir giriş elemanında 2, 3, 4, 5 ve 6 mm den oluşan ardışık ağ boyutları kullanılmışlardır. Von Mises gerilmesi ve sapmaları analizden hesaplanmıştır ve 2 mm ağ büyüklüğünün hatasız çıktıya sahip olduğunu göstermişlerdir [8].

Ağ oluşturma algoritmasının, elemanların genel kalitesini iyileştirmek için bir tür son işlemden geçirilmeden optimal bir ağ tanımlayabilmesi nadirdir. Ağ geliştirmenin iki ana kategorisi yumuşatma ve temizlemeyi içerir. Çoğu yumuşatma prosedürleri, kenar açıları ve en boy oranları gibi öğelerin yerel kalitesini iyileştirmek için tek tek düğümleri yeniden konumlandıran yinelemeli bir süreci içerir. Temizleme genel olarak eleman bağlantısını değiştiren herhangi bir işlemi ifade eder. Pratik bir perspektiften bakılırsa neredeyse tüm popüler sonlu eleman analizi kodları, katı yapıların kabuk ve tetra elemanları için üç veya dört elemanlı otomatik ağ oluşturma imkanı sağlar. Ayrıca, çoğu kodda yerel ayrıntılandırmalar desteklenir, en boy oranı ve kenar açıları gibi kritik ağ parametreleri önceden tanımlanabilir [9].

Literatürden çıkarılacak sonuçlardan bazıları şöyledir;

- Çok kaba ağ, çok büyük hatalarla sonuçlara yol açabilir
- Ağ yoğunluk analizi, tatmin edici doğrulukta sonuçlar elde etmek için rafine ağ analizinde nasıl kullanılması gerektiğine karar verir.

- Büyük deformasyonların, gerilmelerin, kararsızlıkların meydana geldiği yerlerde eleman boyutlarını azaltmak, hesaplama süresinde büyük masraf olmadan büyük ölçüde artırılmış doğruluk sağlar.

1.2.2 Makine öğrenmesi

Makine öğrenmesi yöntemleri henüz gemi inşaatı sektöründe sık kullanılmamaktadır, fakat dünyada bu alana olan doğal yönelme gemi inşaatı sektörünü de etkileyecektir. Bu bölümde makine öğrenmesi ile alakalı sırasıyla diğer sektörlerdeki çalışmalar ve gemi sektöründeki çalışmalardan bazılarını kısaca yer verilecektir.

Çok disiplinli optimizasyon ve sinir ağları kullanılarak türbin disklerinin tasarımı için hızlı bir tepki stratejisi önerilen çalışmada bir optimizasyon yazılımı, belirli bir tasarımın sınır koşulları seti için optimum tasarımlar bulmak amacıyla ANSYS ile arayüz etmiştir. Farklı tasarım koşulları için yazılımdan elde edilen optimum tasarımlar, sinir ağı tekniği kullanılarak makine öğrenimi ve tasarım bilgisini tanıma için kullanılır. Bu çalışmada, Bayesian makine öğrenme paradigmaları, turbo makine bileşenlerinin ön tasarımıdaki davranışlarını tanımlamak için kullanılmıştır. Ayrıntılı çoklu fizik modelleri ve operasyonel bir ortam, hızlı düzeltme ve model ile tahmine dayalı analizler yapılmıştır [10].

Makine öğrenimi teknikleri kullanılarak metal borulardaki kusurların tespiti ve boyutlandırılmasını içeren bir çalışmada, Gauss Süreci (GP) modelleri gibi veriye dayalı çıkarım yöntemleri ile birlikte simülasyon modellerine dayalı çoklu kusurların varlığında kaçak akının yorumlanması genelleştirilmiştir. Bir manyetik akı kaçağı(MFL) cihazı hem COMSOL Multiphysics hem de ANSYS yazılımı kullanılarak simüle edilmiştir. GP ile metal borularda farklı kusur konfigürasyonlarını yakalayarak ters model problemi çözülmüştür [11].

Çelik kafes köprüler için, değişen çevresel ve yükleme koşullarında veriye dayalı bir yaklaşım kullanarak bir hasar tespit ve yerelleştirme algoritması önerilen çalışmada, Ansys'te simüle edilen kafes köprüsünde birkaç çubuğun sertliğini azaltarak hasar verilmiştir. Sağlıklı köprülerden toplanan titreşim verileri, model uzayında küçültülmüş boyut ağırlıklı özellik vektörlerini bulmak için temel bileşen analizi (PCA) ile işlenir. Çalışmada önerilen algoritmanın gürültüye duyarlılığı Gauss gürültüsü ile test edilir ve bu algoritma ile hasar yerini tanımlamak ve hasar endeksini değerlendirmek mümkündür [12].

Boru hatlarındaki korozyon ve yorulmadan kaynaklanan hasarları tespit etmek için makine öğrenme özelliğine sahip boru hattı muayene geyçleri (PIG) kullanılır. Destek Vektör Makinesinin (SVM) uygulanabilirliği ve gaz boru hatlarında bulunan çeşitli kusurların tespitinde titreşim tepkisi üzerine dalgacık analizinin incelendiği çalışmada hata bölgesine karşılık gelen veri segmentini ayırmak için SVM kullanılmış ve bu arızanın boru hattı üzerindeki fiziksel yerini tanımlamıştır. Farklı yükleme koşullarına ve denetim göstergesinin yük taşıma hızlarına karşılık gelen veriler ANSYS den elde edildikten sonra MATLAB ortamında işlenmiş ve sonuçların hassasiyeti iyi çıkmıştır [13].

Makine öğrenmesinin uygulama alanlarından inşaatla örnek olarak, olağan çok değişkenli doğrusal regresyon yöntemi (MLR) ve çok değişkenli uyarlanabilir regresyon spline yöntemi (MARS) gibi gelişmiş makine öğrenme yöntemlerini kullanarak yeni bir olasılıklı model seti analiz edilir ve döner mesnetli damperin gücü tahmin edilir [14].

Köpük betonun basınç dayanımını tahmin etmek için bir makine öğrenme modeli önerilen çalışmada, aşırı öğrenme makineleri (ELM) modelinin potansiyeli, çok değişkenli regresyon spline (MARS), M5 Ağacı modelleri ve destek vektör regresyonu (SVR) ile karşılaştırılarak doğrulanmıştır. ELM modelinin, köpüklü betonun basınç dayanımını tahmin etmek için güvenilir ve doğru bir veri akıllı yaklaşımı olarak kullanılabilir ve istenen ürün kalitesine ulaşmak için gereken zahmetli deneme gruplarından tasarruf edilebilir olduğu gösterilmiştir [15].

Prekast beton yapıların performansı kiriş-kolon bağlantılarının davranışından büyük ölçüde etkilenir. Birkaç yükün aynı anda aktarılması için tek bir bağlantı gerekebilir, böylece bu yüklerin her biri tasarımda dikkate alınmalıdır. Prestek kiriş-kolon bağlantılarının moment dönme tahmini için aşırı makine öğrenmesi (ELM) geliştiren ve uygulayan çalışma sonucunda ELM sonuçları genetik programlama (GP) ve yapay sinir ağı (YSA) ile karşılaştırılmış ve en uygun olanı seçilmiştir [16].

Bir malzeme veri tabanından çıkarılan 25 benzersiz özellik ve yorulma dayanımından oluşan ampirik bir veri seti ile makine öğrenimi yoluyla yorulma dayanımı için öngörücü modeller geliştirilmiştir. Tüm süreç, yorulma dayanımı ile ilgili herhangi bir fiziksel yasa veya ampirik denklemler dikkate alınmadan gerçekleştirilmiştir. En iyi model, en iyi doğrulukla sonuçlanan en yeni makine öğrenimi olan XGBoost algoritması kullanılarak tamamlandı. Malzemelerin özelliklerini doğru bir şekilde yansıtan bir malzeme modeli oluşturmak için verileri kullanan bir iş akışı önerilmiştir [17].

Çelik beton-kompozit bağlı(LSCC) kirişlerin yük ve sapma kapasitelerinin yaklaşık tahmini için makine öğrenme algoritmalarının potansiyel uygulaması yapılmıştır. Dört tanınmış makine öğrenme algoritması, destek vektör regresyonu (SVR), minimal olasılık makine regresyonu (MPMR), uygunluk vektör makinesi (RVM) ve çoklu genetik programlama (MGGP), yük ve sapma kapasitelerinin yaklaşık tahmini için performansı iyi tanımlanmış hata indeksleri açısından karşılaştırılmıştır. MGGP ve MPMR bu çalışma için iyi sonuç veren algoritma olmuştur [18].

Makine öğrenmesi yöntemlerinin gemi inşaatı alanında da uygulamaları vardır, bunlardan birkaç örnek aşağıda anlatılmıştır.

Birden çok gizli katmana sahip yapay sinir ağlarının yapısını ve parametrelerini aynı anda tahmin etme sorununu ele alan çalışmada hem sınıflandırma hem de regresyon için basit kıyaslama problemleri ve gemilerde atık ısı geri kazanımının tahmini için bir vaka çalışması üzerinde deneyler yapılmıştır. Önerilen sorun formülasyonu, en küçük kareler destek vektör makineleri ile güçlü benzerlikler gösterir, ancak yinelenen yeniden ağırlıklandırma prosedürü, modelde seyrekliği teşvik etmeyi mümkün kılar. Titiz bir yakınsama kanıtı bulmak hala açık bir sorun olmaya devam etmektedir [19].

Gemi tasarımında bilgisayar uygulamalarının geliştirilmesi ile birlikte, güçlü bir yaklaşım olarak optimizasyon, tasarım ve analiz sürecinde yaygın olarak kullanılmaktadır. Makine öğrenmesini optimizasyona yön vermek için etkili bir araç olarak kullanan çalışmada, makine öğrenimi tabanlı gemi tasarım optimizasyonu yaklaşımı önermektedir. Bu yöntemin gerçek dünyaya uygunluğunun değerlendirilmesi için bir dökme taşıyıcı yapısal tasarım optimizasyonu bir vaka çalışması olarak gerçekleştirilmiştir [20].

En küçük kare destek vektör makinesi (LS SVM) ve genetik algoritma (GA) ile güverte hareketi için bir tahmin yöntemi üretilmiştir. LS SVM tahmin için kullanıldığında, çekirdek parametresi, ceza faktörü, örnek sayısı ve geçmiş verilerin uzunluğu adı verilen dört parametre önceden belirlenmelidir. Optimize edilmiş parametreler elde etmek için GA tanıtılır ve GA'da kullanılan uygunluk fonksiyonu güverte hareketinin periyodikliğine göre de tasarlanır [21].

Makine Öğrenimi bağlamında daha doğru modeller hala mevcut değildir.

2. YORULMA

Yorulma mukavemeti, malzemenin ömrü ve makinelerin güvenilirliği ile doğrudan ilişkili olduğu için en önemli malzeme özelliklerinden biridir. Gerilme-yaşam ilişkisi, tasarımda en yaygın kullanılan malzeme özelliği olmasına rağmen, sadece gerilmenin değil, aynı zamanda çok karmaşık fiziksel ve kimyasal faktörlerin de yorulma dayanımının belirlenmesini etkilediği iyi bilinmektedir. Yapısal elemanların performansları, tasarım ömürleri boyunca yorulma için tatmin edici bir olasılık seviyesinde kalacak şekilde tasarlanmaktadır.

Yorulma analizi prosedürü, yorulma dayanımının belirlenmesinde sadece döngüsel gerilme aralıklarının dikkate alınmasının gerekli olduğu varsayımına dayanmaktadır [22].

Yorulma mukavemeti genellikle normal deniz koşullarında deniz gidiş modu için araştırılır. Araştırılacak yerdeki kaynak yönüne dik olan gerilme bileşenleri genellikle yorulma mukavemeti için baskın gerilmeler olarak tanımlanabilir. Bu nedenle, akma ve burkulma mukavemeti durumunda olduğu gibi, tüm düzlem içi gerilme bileşenlerinin eşzamanlı dağılımını belirlemek gerekli değildir [23].

Yorulma değerlendirmesi, ya ömrünün uzatılması için S-N eğrisi / kümülatif hasar yaklaşımı ya da çatlaklar tespit edildiğinde onarım kararı için kırık mekaniği analizi vasıtasıyla gerçekleştirilebilir. Çatlak ilerlemesi ve yorgunluk başarısızlığına yol açan döngüsel gerilmelerin baskın nedeni normalde dalga kaynaklı yüklerdir. Bununla birlikte, rüzgar, dönen makineler veya vinçler gibi diğer döngüsel yük kaynakları da önemli yorulma yüklerine neden olabilir ve ilgili olduğu durumlarda gerekli dikkate alınmalıdır.

Genelde aşağıdaki yorulma hatası modlarının meydana gelmesini önlemek için yapısal detaylara yorulma değerlendirmesi yapılır:

- Kaynak ağzı arızası
- Kaynak kökü hatası
- Kesme kenarı hatası
- Civatalı bağlantılar hatası.

Yorulma mukavemetinin araştırılmasında sorun haline gelen yük, maksimum yük değil, döngüsel yüküdür. Yorulma mukavemeti için baskın yükleri belirlemek zordur ve

bu nedenle açık deniz koşullarında karşılaşılmaması beklenen yüklerin dikkate alınması gerekir. Tekne detaylarının yorulma analizi için dikkate alınacak ortak yükler aşağıdaki gibidir [24]:

- Hidrostatik iç sıvı ve dış deniz basınçları
- Ataletsel iç sıvı basıncı ve dalga deniz basınçları
- Yer çekimine maruz kalan sabit ağırlıklardan kaynaklanan statik yükler
- Gemi hareketlerinin neden olduğu ivmelere maruz kalan sabit ağırlıklardan kaynaklanan atalet yükleri

Gemiler ve gemi şeklindeki açık deniz birimleri için dikkate alınacak tekne kiriş yükleri:

- Gövde kirişi, iç ağırlıklardan kaynaklanan eğilme momenti ve kesme kuvveti gibi durgun su yükleri (boş gemi, konteynerler, yükler, sıvılar) ve harici hidrostatik deniz basıncı
- Dalga bükülme momentleri, dalga torku ve atalet yüklerinden kaynaklanan kesme kuvvetleri (sadece dökme yük gemileri ve konteyner gemileri gibi büyük güverte açıklıkları olan gemiler için) ve dış dalga deniz basıncı gibi gövde kiriş dalgası kaynaklı yükler

Alakalı olduğunda, aşağıdaki ek yükler dikkate alınabilir:

- Kargo yükleme ve boşaltma nedeniyle yükler
- Çarpma, sıkma gibi darbe yüklerinden dolayı dinamik yükler
- Doğal gövde kirişi titreşimi nedeniyle dinamik yükler (yay tepkisi)
- Operasyonel yükler
- Ana motordan veya pervaneden kaynaklanan titreşim kuvvetlerinden kaynaklanan dinamik yükler
- Termal gerilmeler gibi geçici yükler.

Geminin ömrü boyunca her yükleme koşulu için yorulma analizinde dikkate alınması gereken yükleme koşulları, uyulacak klas kurallarına göre seçilmelidir.

Gerilmenin yüksek olduğu köşeler gerçek hayata göre modellenip keskinlikten kaçılarak eğrisellik verilebilir. Fakat bu şekilde model boyutu büyür. Geometriyi parçalama yaygın bir uygulamadır ve keskin köşelerin (tekilliklerin) modelde bulunmasının getirdiği güçlükler şunlardır [25];

- Model lineer değilse tekillikte sayısal problemler olabilir. Çok yüksek dereceli denklemlerin ortaya çıktığı problemlerde adım aralığını milisaniyeye indirmeye zorlamak gerekir. Aylar sürececek bir problem incelendiğinde ise tekilliği küçük bir elastik alanın içine alacak şekilde düzenlemek bir çözümdür.
- Adaptif ağ boyutu ile hata tahmininde, tekillik çözümün geri kalanını domine edeceğinden gerilme tepelerinin olduğu köşeler bu tür prosedürlerden uzak tutulmalıdır.
- Gerilmelerin fonksiyonun parçası olduğu bir optimizasyon problemi yürütülürken tekillik sadece fiziksel olmayan tepe gerilmesinin genliğini azaltmak için yardımcı olur. Bir karakterin optimizasyon probleminde braketin civatalandığı kısım maksimum gerilme arayışının dışında bırakılmıştır.
- Yüksek gerilme noktaları çözmek için daha ilginç (incelenmesi gereken) alanları sönümlemektedir.

Köşe çok keskin olduğunda yapı yüksek zorlanma nedeniyle hasar görür. Bu tür hasarlar çoğu durumda sadece gerilmelerin lokal olarak yeniden dağılımına neden olur. Eğrisellik çapını biraz değiştirmek kadar etkilidir. Yüksek lokalize gerilmeler döngüsel yüklendiğinde yorulma riski olur. Yorgunluk ömrü büyük ölçüde gerilme genliğine bağlıdır. Eğriselleştirilmiş köşe kısımları sadece geometrik olarak değil ağ yapısı olarak da düzgün ifade etmek gerekir. Model işlemek için çok büyük olursa alt modelleme kullanılabilir.

Kiriş elemana uygulanan noktasal yük veya kabuk elemana uygulanan düşey yük tekilliğe neden olmaz. Kabuk elemanın alanına uygulanan noktasal yük ise tekilliğe neden olur [25]. En kötü geometrik tekillik çatlaktan kaynaklanır. Bir çatlak köşe olarak düşünülebilir, bu nedenle köşe tekilliğinin birçok yönü buraya uygulanabilir. Tekilliklerden kurtulmak için,

- Modeli sınır koşullarının neden olduğu tekilliklerin alanının dışına çıkacak şekilde uzatmak veya genişletmek
- Elastik zemin koşulu uygulayarak daha yumuşak sınır koşulları belirlemek.
- Sonsuz eleman kullanımı, alanı genişletmek için basit bir yöntemdir.

Tekrarlı işletme yüklerinin uygulanması veya kaldırılması sırasında oluşan gerilmedeki değişim miktarı gerilme aralığı olarak adlandırılır. Basınçtan çekmeye geçen gerilme değişimlerinde gerilme aralığı, en büyük çekme ve basınç gerilmelerin mutlak değerlerinin toplamı alınarak hesaplanır. Kayma gerilmesi halinde ise gerilme

aralığı, verilen noktada birbirine ters yönde oluşan en büyük kayma gerilmelerinin mutlak değerlerinin toplamıdır. Gerilme aralığı çatlak başlangıcı olasılığı olan noktalarda hesaplanmalıdır [26].

Kaynaklı yapılarda yorulmaya karşı boyutlandırma önemlidir. Yerel geometri, kaynak boyunca ve nominal olarak aynı olması gereken iki parça üzerindeki kaynaklar arasında farklılık gösterir. Yapıdaki herhangi bir elemanın kaynaklı eklem, bağlantının ve diğer gerilme yığılma formlarının potansiyel olarak bir yorulma veya çatlak kaynağı olduğu bilinmeli ve ayrıca dikkate alınmalıdır.

Yorulmaya duyarlı alanlarda gerektiğinde artan kalınlıklar, geliştirilmiş detaylandırma, düzgün geçişler ve kaynak bağlantılarının uygun şekli ile elde edilen nominal gerilmelerde azalma kombinasyonu ile iyileştirilmiş bağlantı performansı elde edilecektir. Kaçınılmaz kesimler veya açıklıklar mümkün olduğunca yüksek gerilme alanlarının dışına yerleştirilmeli ve çentiklerin üst üste binmesinden kaçınılmalıdır. Kaynaklı bağlantıların yorulma mukavemeti bir dereceye kadar levha kalınlığına bağlıdır. Bu etki, bitişik plakaların kalınlığına bağlı olarak kaynak ayağının lokal geometrisinden kaynaklanmaktadır. Ayrıca kalınlık üzerindeki gerilme değişimine de bağlıdır [27].

Yorulma dayanımı, hesaplanan kümülatif yorgunluk hasarının izin verilen hasardan daha az olmasıdır. Uygun bir yorulma ömrü en iyi şekilde yeterli birleştirme detay tasarımı ve imalat kalite kontrolü ile elde edilir. Ortak detay tasarımı, mümkün olduğunca, ikincil gerilmeleri ve yerel kısıtlamaları, ani bölüm değişikliklerini, yeniden giriş köşelerini, çentikleri ve diğer gerilme yükselticilerini ortaya çıkaran eklem eksantrikliklerinden kaçınmaktır.

2.1 S-N Eğrileri ile Yorulma Analizi

Nominal gerilme, kesit kuvvetleri ve momentleri kullanarak veya kaba sonlu eleman modellerinden giriş teorisi ile elde edilebilir. Basit bir plaka örneğinde, nominal gerilme membran gerilmesidir. Bu prosedürü kullanan bir yorulma tasarımına örnek, bir güvertede enine alın kaynağı olabilir. Nominal gerilme aralıkları için yorulma mukavemeti, tipik detay kategorilerine karşılık gelen bir dizi $(\log \Delta\sigma_R) - (\log N)$ eğrileri ve $(\log \Delta\tau_R) - (\log N)$ eğrileri bir diğer adıyla S-N eğrileri ile temsil edilir. Her detay kategorisinde, 2 milyon döngüde, yorulma mukavemeti, birimi N / mm^2 olan ve $\Delta\sigma_R$ (doğrudan gerilme aralığı) ve $\Delta\tau_R$ (kesme gerilmesi aralığı) referans değerlerini temsil eden bir sayı ile belirtilir [28].

Uygulanan sabit gerilme aralığında S-N eğrileri, gerilme çevrimlerinin sayısının başarısızlığa bağımlılığının grafik sunumudur. Wöhler eğrisi olarak da bilinir. Yorulma analizi, uygun olduğunda plakalı yapılar için nominal S-N eğrilerini temel alabilir. Üretim toleransları, doğal S-N verisini aştığında, alın kaynakları ve haç biçimli birleşimler için imalat toleranslarından kaynaklanan ek gerilmeler dikkate alınmalıdır. Gerilmelerin, tanımı ile uyumlu belirli bir S-N eğrisi ile birlikte hesaplanması önemlidir. Üç farklı S-N eğrisi kavramı tanımlanmıştır [22];

- Nominal gerilme S-N eğrisi.
- Kaplama yapılar ve boru şeklindeki eklemler için tanımlanan sıcak nokta S-N eğrisi,
- Çentik gerilmesi S-N eğrisi. (Bu yaklaşım, sadece diğer yöntemleri kullanarak yorulma ömrünü güvenilir bir şekilde değerlendirmenin zor olduğu özel durumlarda kullanılır.)

Nominal gerilme basitçe yorulma testinden S-N verilerinin çizilmesi için kullanılan membran gerilmesidir. Kiriş teorisi gibi klasik teori ile türetilen bir bileşendeki bir gerilme olmaktadır. S-N eğrisinin seçimi ise, imalat sırasında muayene sıklığına ve türüne bağlıdır. Kalınlık boyunca çatlak büyümesi gibi kırılmalarda akma kriteri gerçek modeldeki çatlak boyutuna aktarılırsa gerilme dağılımının değişmesi mümkün olabilir. Bu, akma kriterinin plaka kalınlığından biraz daha az olan bir çatlak boyutu ile uyumlu olduğu anlamına gelir [22].

Pratik yorulma tasarımı için, kaynaklı eklemlerin her birine karşılık gelen bir S-N eğrisine sahip sınıflar vardır. Borudan plakaya dahil olmak üzere diğer bağlantı türleri, detayın geometrik düzeni, ayrıntıya yayılan gerilmenin yönü, detayların imalatı ve muayene yöntemleri gibi özelliklerine göre sınıflara yerleştirilmelidir. Örneğin, tüm boru şekilli bağlantıların T sınıfı olduğu varsayılır. Yorulma çatlaklarının gelişebileceği birkaç yer olabilir (birleştirilen parçaların her birinde kaynak ağzında, kaynak uçlarında ve kaynağın kendisinde) ve her konum ayrı ayrı sınıflandırılmalıdır. Şekil 2.1’de eğrilerin kullanımı ve sınıflarının belirlenmesine ilişkin bir örnek verilmiştir. Temel tasarım S-N eğrisi formülü şu şekildedir [22];


$$\log N = \log a - m \log \Delta \sigma \quad (2.1)$$

N = gerilme aralığı($\Delta\sigma$) hatasına ilişkin tahmini döngü sayısı

$\Delta\sigma$ = MPa birimi ile gerilme aralığı

m = S-N eğrisinin negatif ters eğimi, $\log a$ = $\log N$ ekseninin S-N eğrisiyle kesişimi

S-N curve	$N \leq 10^6$ cycles		$N > 10^6$ cycles $\log \bar{a}_2$ $m_2 = 5.0$	Fatigue limit at 10^7 cycles*)	Thickness exponent k	Stress concentration in the S-N detail as derived by the hot spot method
	m_1	$\log \bar{a}_1$				
B1	4.0	14.917	17.146	106.97	0	
B2	4.0	14.685	16.856	93.59	0	
C	3.0	12.192	16.320	73.10	0.05	
C1	3.0	12.049	16.081	65.50	0.10	
C2	3.0	11.901	15.835	58.48	0.15	
D	3.0	11.764	15.606	52.63	0.20	1.00
E	3.0	11.610	15.350	46.78	0.20	1.13
F	3.0	11.455	15.091	41.52	0.25	1.27
F1	3.0	11.299	14.832	36.84	0.25	1.43
F3	3.0	11.146	14.576	32.75	0.25	1.61
G	3.0	10.998	14.330	29.24	0.25	1.80
W1	3.0	10.861	14.101	26.32	0.25	2.00
W2	3.0	10.707	13.845	23.39	0.25	2.25
W3	3.0	10.570	13.617	21.05	0.25	2.50
T	3.0	11.764	15.606	52.63	0.25 for SCF ≤ 10.0 0.30 for SCF > 10.0	1.00



Şekil 2.1 : Katodik korumalı deniz suyuunda S-N eğrileri ve sınıfları [22].

Yapıların detaylı sonlu eleman analizinden, bir ayrıntıya bağlı yerel gerilmenin bir kısmı S-N eğrisinde açıklandığı için, S-N eğrileri ile birlikte kullanılacak nominal gerilmenin ne olduğunu değerlendirmek zor olabilir. Bu nedenle birçok durumda, sonlu elemanlar analizinden lokal gerilmeler elde edildiğinde yorulma hasarının hesaplanması için alternatif bir yaklaşım kullanmak daha uygun olabilir.

2.2 Gerilme Yığılma Faktörü ile Analiz

Genellikle sonlu elemanlar metoduna dayanan etkili hesaplama yöntemlerinin varlığı, gerilme yığılma faktörlerinin kullanımını ve ihtiyacını değiştirmiştir.

Bir gerilme yığılma faktörü, sıcak nokta gerilme aralığının nominal gerilme aralığına oranı olarak tanımlanabilir. Geometrik gerilme yığılmaları elemanların açıklıklarından, geometrideki geçişlerden, uç bağlantılardan ve diğer süreksizliklerden kaynaklanır. Genel analizde modellendiğinde, bu tür geometrik gerilme yığılmaları uygun gerilme yığılma faktörleri (SCF) ile açıklanabilir. SCF'ler, analitik çözümlerden, bazı durumlarda parametrik denklemlerden veya doğrudan gerilme analizi ile elde edilebilir. Aşağıda verilen 2.2, 2.3 numaralı formüller, takviye edilmemiş bir plakadaki alın kaynağı veya geniş yarıçaplı boru alın kaynağı için geçerlidir [22];

$$SCF = 1 + \frac{3(\delta m - \delta o)}{t} \quad (2.2)$$

δm = yanlış hizalama, eksantrisitedir ve t plaka kalınlığıdır.

δo = 0.1 t alın kaynakları için S-N verilerine ve kaplama yapıları için analiz prosedürüne özgü yanlış hizalamadır.

Bir plaka alanında farklı kalınlıktaki plakalar arasındaki kaynak için gerilme yığılması aşağıdaki formülden türetilir:

$$SCF = 1 + \frac{6(\delta m + \delta t - \delta o)}{t[1 + (T^{1.5}/t^{1.5})]} \quad (2.3)$$

δm = maksimum yanlış hizalamadır.

δt = 1/2 (T - t), kalınlıktaki değişiklik nedeniyle oluşan eksantriklik.

δo = 0.1 t alın kaynakları için S-N verilerine ve kaplama yapıları için analiz prosedürüne özgü yanlış hizalamadır.

T = kalın plaka kalınlığı

t = ince plaka kalınlığı

Maksimum gerilmenin yorulma analizindeki köşebent kesişme noktasına yakın olması bekleniyorsa, SCF'nin hesaplanması için kabuk sonlu elemanlar analizinden kaçınılmalıdır. Bir alternatif, üç boyutlu katı eleman analiz modeli kullanmaktır [22].

Bu faktörler, nominal gerilme aralığından sıcak nokta gerilme aralığını değerlendirmek için gereklidir. Tipik bağlantı ayrıntıları için hesaplanırlar ve daha sonra her ayrıntıyı değerlendirmek için tahmin edilirler. Basit ekstrapolasyonun yanı sıra geometrik gerilme yığılma faktörlerinin hesaplanma şekli, her takviye bağlantısının yorulma

dayanımına hızlı bir genel bakış sağlar. Daha sonra sonlu eleman yöntemi ile en kritik detayları yeniden rafine ağ yapısıyla hesaplanır.

Gerilme yığılma faktörü SCF, basit olarak, modeldeki tepe gerilmenin (veya bozuk bölgedeki gerilmenin) referans olarak alınan diğer gerilmelere oranı şeklinde tanımlanabilir. Gerilme yığılma faktörü teorik bir faktördür.[29]. Yani, modeldeki tepe gerilmesi esneklik teorisine dayanır veya bir laboratuvar gerilme analizi deneyinden türetilir.

Kaynak ucunun gerilme yığılması etkisinin levha kalınlığından, kalın levhalarda ince olanlardan daha şiddetli olacak şekilde etkilenmesi beklenebilir.

Genellikle mekanik bir cihazın hesaplamalı gerilme analizinde, yüksek gerilme altındaki bölgeler ve gerilme yığılma faktörlerinin açık kullanımından kaçınılmalıdır. Alternatif olarak, bir hesaplama analizi ile gerilme yığılması faktörü bulunabilir ve daha sonra geleneksel tasarım çalışmaları için kullanılabilir. Gerilme yığılma faktörlerini belirlemek için fotoelastisite gibi deneysel tekniklerin kullanımı, daha esnek ve verimli hesaplama teknikleriyle yer değiştirmiştir [29].

2.3 Sıcak Nokta (Hot-Spot) Analizi

Plaka yapıların tasarımı için sonlu elemanlar analizi yapılırken, analizden sıcak nokta gerilmesinin çekilmesi, nominal gerilmeye göre daha uygun bulunmuştur. Yorulma gerilmelerinin türetilmesi için hesaplanan sıcak nokta gerilmesi, sıcak nokta S-N eğrisi ile birleştirilir.

N / mm² cinsinden sıcak nokta gerilme aralığı, nominal gerilme aralıkları ve geometrik gerilme yığılma faktörlerine bağlı olarak her yük durumu ve her yükleme koşulu için 2.4 numaralı formül ile hesaplanmalıdır [30]:

$$\Delta\sigma_{Hotspot} = K_g Loc \Delta\sigma_{NomLoc} + K_g hg \Delta\sigma_{Nom hg} \quad (2.4)$$

K_g Loc: Yerel geometrik gerilme yığılma faktörü

Nom Loc: Nominal lokal gerilme aralığı


K_g hg: Gövde kirişi geometrik gerilme yığılma faktörü

Nom hg: Nominal gövde kiriş gerilme aralığı

Ekstrapolasyon kullanılmadığında sıcak nokta gerilmeleri, sıcak noktaya bitişik ilk elemanın merkezine göre hesaplanmalıdır. Detay bir açıklığın serbest kenarı olduğunda (örneğin, sıradan bir takviyenin birincil destek elemanı içinden geçişi için bir kesik) sıcak nokta gerilmelerinin serbest kenarda hesaplanması gerekir.

Boru şeklindeki bağlantıların tasarımı için, gerçek geometride sıcak nokta gerilmesini elde etmek üzere parametrik denklemler kullanılarak gerilme yığılma faktörlerinin türetilmesi standart bir uygulamadır. Daha sonra bu sıcak nokta gerilmesine boru şeklinde bağlantılar için ilgili bir sıcak nokta gerilme S-N eğrisi girilir.


Plaka kalınlığı boyunca gerilme alanının tanımının, sıcak nokta gerilme yönteminin basit haç biçiminde birleşme noktaları, plakalarda basit T-eklemleri veya sadece bir taraftan kaynaklı basit alın derzleri için önerilmediğine dikkat edilmelidir (Şekil 2.3). Bunun nedeni, kabuk elemanları ile bu tür bağlantıların analizinin, nominal gerilme eşit bir sıcak nokta gerilmesine yol açmasıdır.



Şekil 2.3 : T eklemünde sıcak nokta türleri; çentik gerilmesi, sıcak nokta gerilmesi, nominal gerilme.

Nominal gerilmeleri tanımlama zorluğu nedeniyle bazı yapısal şekillerin tasarımında bir sorun olduğu kanıtlanmaktadır. Aynı sorun sıklıkla sonlu elemanlar analizi (FEA) ile gerilme bilgisi elde edildiğinde ortaya çıkar. Bunu göz önünde bulundurarak, yorulma tasarımı için sıcak nokta gerilmelerinin kullanımına artan bir ilgi vardır. Böyle bir yaklaşımın FPSO yapılarının tasarımı için de uygun olması beklenmektedir [31].

Sıcak nokta gerilmesinin tanımında S-N eğrilerinin seçimi önemlidir. Sıcak nokta gerilme tasarım yaklaşımının potansiyel başarısızlık modu, bir kaynak ağzından yorulma çatlak büyümesi gibi durumlarda kullanılır. Genel olarak, üç tip kaynak ucu arızası tanımlanabilir. Şekil 2.4'te gösterilen iki durumda, (a) ve (c), kaynak ayağına yaklaşan gerilme dağılımının plaka kalınlığına bağlı olduğu genel olarak kabul edilmektedir. Diğer nokta olan (b) de ise, kaynak ayağından veya ucundan kenar çatlaması durumunda, kaynak ayağına yaklaşan gerilme dağılımı genellikle plaka kalınlığına bağlı değildir. (a) ve (c) kabuk elemanlar için aynıdır, katı elemanlar için ise değişir [27].




- a : Boyuna bağlantının sonundaki kaynak
- b : Plaka kenarı veya çevresindeki kaynak
- c : Yüke enine biçimindeki kaynak

Şekil 2.4 : Kaynaklı yapılarda sıcak nokta çeşitleri.

Sıcak nokta gerilmesi ya kaynak kalınlığından uzakta plaka kalınlığının bir oranıdır ya da kaynak ayağından uzakta plaka kalınlığının oranı olan mesafelerde bulunan gerilmelerden ekstrapolasyon ile elde edilir. Yorgunluk tasarımında sıcak nokta gerilme yaklaşımını kullanırken bir boyut etkisi için ne gibi bir karşılık verileceği konusundaki tüm sorun henüz çözülmemiştir.

Kaynak, uygulanan gerilmenin yönüne paralel olduğunda, yorgunluk çatlakları normal olarak kaynak uçlarında başlar. Kaynak, gerilme yönüne enine olduğunda kaynak ağzında genellikle çatlaklar başlar; ancak kaynak kökünde kaynak çatlakları da başlayabilir. Çatlaklar daha sonra gerilmeli elemana yayılır. Kaynaklar gerilmiş elemanın kenarında veya kenarına bitişik olduğunda, gerilme yığılması artar ve yorulma mukavemeti azaltılır; bu eklemlerin bazılarında 'kenar mesafesi' belirtilmesinin nedeni budur (Şekil 2.5).



Şekil 2.5 : Kenar mesafesi belirtilen farklı yapılar.

Kaynak boşluğu, kaynak sıçraması veya manuel dolgu kaynağında kazara aşırı kıvrılma sonucunda kaynaklanmamış kenarlarda lokal gerilme yığılmaları olasılığını sınırlamak için bir kenar mesafesi kriteri vardır. Bir kenar mesafesi sadece bir elemanın genişlik yönü için belirtilebilse de, örneğin kapak plakaları veya kutu kirişli flanşların kaynaksız köşelerinde kazara kaynak boşluğu olmasını engellemek de eşit derecede önemlidir. 10 mm'den küçük kenar mesafesi için, detay kategorisi bir S-N eğrisi ile indirilmelidir [22].

Yorgunluk verilerindeki saçılma azaltılmalıdır. Ortaya çıkan sıcak nokta gerilme S-N eğrisi bir tasarım eğrisi olarak sıcak nokta gerilmelerinin alt sınır sonlu eleman yöntemi tahminlerine göre daha az tutucu olacaktır. Ancak ölçülen gerilmelerin kullanılmasının avantajı, testlerde ikincil gerilmelere izin verilmesidir, örneğin sonlu eleman analizi tahminlerinde geometri idealleştirilmesi sonucu yanlış hizalamalara yer verilmemektedir. Sıcak nokta analizlerinde ise çoğu durum incelenmektedir.



3. SONLU ELEMANLAR YÖNTEMİNİN GEMİ YAPISAL ANALİZİNDE KULLANIMI

Sonlu elemanlar yöntemi, bir dizi kısmi diferansiyel denklemle tanımlanan veya fonksiyonel minimumu olarak formüle edilebilen mühendislik problemlerini çözmek için kullanılan sayısal bir tekniktir. Geometrik model oluşturulur ve bunu takiben malzeme özellikleri, yükler ve sınırlamalar tanımlanmaktadır. Bir sonraki adım, geometrinin sonlu elemanlar adı verilen küçük ve basit şekilli varlıklara ayrıldığı ayrıklaştırma işlemidir. Bu işlem yaygın olarak ağ oluşturma olarak bilinir. İlgilenilen bölge sonlu elemanlar topluluğu olarak gösterilmektedir. Sonlu elemanlardaki yaklaşık fonksiyonlar, araştırılan fiziksel alanın nodal değer terimlerinde belirlenmektedir.

Kuvvet gerçek hayatta noktasal değildir ve bir alana dağıtılır. Sonlu eleman analizi bu bölgeyi çözmeye değer olup olmadığını inceler. Bunun cevabı Saint-Venant prensibidir; statik olarak eşdeğer yüklerin dağılımı yüklü alanın boyutuna kıyasla yeterince uzun mesafede her zaman aynı sonucu verir. Yapısal değerlendirme, üç boyutlu veya iki boyutlu yapısal modellerin doğrusal sonlu elemanlar analizine dayanır [32].

Sonlu elemanlar modelinde bir çatlağa rastlandığında odak alanı burası olur. Tekillikler birçok farklı nedenden ötürü sonlu elemanlar modellerinde ortaya çıkar. Model boyutunun ve analiz süresinin azaltılması için genellikle geometrik detayların, yüklemelerin ve sınır koşullarının basitleştirilmesi gerekir [25].

Anizotropik elemanlar, eleman modelinde daha doğru bir gerilme dağılımı elde etmek için kullanılabilir, örn. enine yönde yüksek kullanımı olan ince plaka panelleri için. Anizotropik malzeme modeli, geometrik olarak kusurlu kaplamanın azaltılmış membran Poisson sertliğini temsil etmelidir. Çelik dışındaki malzemeler etkin yük taşıma elemanları olarak kullanılırsa, örn. alüminyum, kompozitler veya cam pencereler, bu tür malzemeler sonlu eleman modeline anizotropik malzemeler tarafından dahil edilebilir. Aşağıdaki yapılar daima izotropik malzeme özellikleri ile modellenmelidir [33];

- Birincil destekleyici üyelerin ağı
- Sıkı kirişler, sıkı zeminler veya çift cidarlı yapı içindeki sıkı sınırlar
- Korugeytlar


- Stifnerler
- Yerel yapısal analiz için, dikkate alınan alandan az olmayan bir mesafede kabuk elemanları
- Çok ince gözenek analizi için, dikkate alınan sıcak noktadan daha az olmayan bir mesafede kabuk elemanları.

Yüksek sıcaklık gradyanlarına, yani 100°C 'yi aşan yapılar için, sonlu eleman analizine termal gerilmelerin dahil edilmesi gerekli olabilir. Global bir sonlu eleman analizi tüm gemiyi kapsar ve tekne kirişinin yapısal tepkisi yeterince belirlenemiyorsa gerekli olabilir, gemiler için [34];

- Konteyner gemilerinde olduğu gibi, genel burulma deformasyonuna ve gerilmetepkisine maruz kalan geniş güverte açıklıkları
- Ro-Ro gemileri ve araba taşıyıcılarında olduğu gibi, tekne uzunluğu boyunca sınırlı enine perde yapıları
- Büyük yolcu gemilerinde olduğu gibi, gövde kirişinin kısmen etkili üst yapısı ($L > 150\text{ m}$)

Global analizler genel olarak akma, burkulma ve yorgunluk gerilmelerini temsil eden yük kombinasyonlarına dayanmalıdır. Gemilerde ambar kapakları, rampalar gibi yapıların ise genel olarak doğrudan bir çerçeve ve kiriş analizi yapılması yeterli olur.

Global sonlu eleman modeli tüm gemi uzunluğu, derinliği ve genişliği boyunca uzanacak ve geminin gerçek geometrisini kabul edilebilir bir doğrulukla temsil edecektir (Şekil 3.1). Tüm birincil destek elemanları, enine elemanlar, su geçirmez perdeler, çapraz güverte yapıları dahil olmak üzere tekne kiriş mukavemetine katkıda bulunan veya kısmen katkıda bulunan tüm ana yapılar modele dahil edilecektir. Küçük yapıların ihmal edilmesi, yapının gerilme tepkisini önemli ölçüde değiştirmemesi koşuluyla kabul edilebilir. Kısmi gemi analizi için sonlu eleman modeli, model sınırları değerlendirme alanından yeterince uzak olacak şekilde genişletilecektir.



Şekil 3.1 : Bir konteyner gemisinin tipik küresel sonlu eleman modeli.

Sonlu eleman yöntemi kullanan karmaşık problemler için elde edilen sonuçlar mühendisin bilgi, deneyim ve becerilerine bağlı olabilir. Sonlu elemanlar yöntemi, mühendislik problemlerini çözmek için güçlü bir araç olmasına rağmen, basitleştirmeler, uygun sınır koşulları veya simetri nedeniyle oluşan modelleme hatalarının veya yanlış varsayımların yapılmasından kaynaklanan sonuçlarda hatalar olabilir [35].

3.1 Klas Kuralları

3.1.1 BV : Bureau Veritas - Fransa Loydu

Fransa klas kuruluşunun kuralları incelendiğinde sonlu elemanlar yöntemindeki ayrıntılar, sınır koşulları, yorulma analizleri kısaca anlatılmıştır.

Dikkate alınan yapısal alt bölüm izostatik olmalıdır, böylece uygulanabilirliğini ince yapılara sınırlar. Sonlu eleman modeli kapsamındaki yapısal tepki, modellenmemiş parçaların çarpıklığından önemli ölçüde etkilenmemelidir, bu da eğilme ve kesme gecikmesi olan yapıları hariç tutar. Bu yöntem tipik olarak gemilerin ve gemi şeklindeki birimlerin ‘üç yol modeli’ için kullanılır. Kısmi bir yapısal model kullanılırsa, sonlu eleman modeline dahil olmayan yapı parçalarının uyguladığı kuvvetler ve momentler, yapısal modelin sınırlarına uygulanmalıdır [36].

İnce ağ yapısına sahip modelin sınırları, görder, stringer ve zeminler gibi bitişik birincil destek elemanlarında mümkün olduğu kadar dikkate alınmalıdır. Yerel modelin sınırlarındaki enine ağ çerçeveler, stringer plakaları ve görderler yerel modelde temsil edilmeyecektir [36].

Çizelge 3.1 : Üç boyutlu modelin tamamının sınır koşulları [37].


Sınır Koşulları	Yer Değiştirme Yönlerine Göre*		
	X	Y	Z
Simetri	serbest	sabit	serbest
Anti-Simetri	sabit	serbest	sabit

Sınır Koşulları	Eksenler Etrafında Dönme*		
	X	Y	Z
Simetri	sabit	serbest	sabit
Anti-Simetri	serbest	sabit	serbest

* X,Y,Z yönleri ve eksenleri Bölüm 1, Kısım 2 'de belirtilen referans koordinat sistemine göre düşünülmüştür (Şekil 3.2).

Sonlu eleman modeline Çizelge 3.1’de belirtildiği üzere sınır koşulları uygulanacaktır:

- Simetri koşulları, plaka flanşının uzunlamasına kesimi boyunca, ağ çerçevelerinde ve ağ takviyesinin üstünde enine ve dikey kesimler boyunca uygulanır.
- Model sabitlenmelidir;
 - yanal basınç yüklemesi için: tüm serbestlik derecelerinde hem ileri hem de arka uçlarda.
 - eksenel yükleme için: modelin arka ucunda uzunlamasına yönde yer değiştirme için zorlanmış eksenel yer değiştirme ileri uçta uygulanır, ya da tam tersi [23].




Şekil 3.2 : Referans koordinat sistemi.

Kesme modu altında yorulma mukavemeti değerlendirmesi, normalde sonlu eleman analizi ile çok ince ağ kullanılarak yapılır. Bununla birlikte çok sayıda bağlantı nedeniyle nominal gerilme aralıklarına dayanan basit bir yaklaşım olarak ekstrapolasyonlara izin vermek çok yararlı olabilir. Boyuna takviye uç bağlantılarının sıcak nokta gerilmesinin belirlenmesi, nominal gerilmelere ve gerilme yığılması faktörlerine dayanmaktadır. Tübüler bağlantı; kaynak ucundaki sıcak nokta gerilmesi, bir geometrik gerilme yığılma faktörü tarafından düzeltilen nominal gerilmeden türetilir. Eksenel gerilme, düzlemsel eğilme gerilmesi, düzlem dışı eğilme gerilmesi; bu üç nominal gerilme bileşeninin gerilme değişimleri ayrı tutulmalı ve birleştirilmemelidir. Kesme gerilmeleri ve burulma gerilmeleri ihmal edilebilir. Ardından, en kritik detayların doğru sonlu eleman analizi ile yeniden hesaplanması şiddetle tavsiye edilir. Sonlu eleman modeli aşağıdaki gerekliliklere göre inşa edilecektir [36];

- Ayrıntı yanlış hizalama yapılmadan gerçekleştirilmelidir.
- Sıcak noktanın yakınında bulunan sonlu elemanların boyutu, yapısal elemanın kalınlığının yaklaşık bir ila iki katı olacaktır. Detayların farklı kalınlıktaki iki veya daha fazla eleman arasındaki bağlantı olması durumunda, dikkate alınacak kalınlık en ince elemanın kalınlığıdır.
- Kaynak parmağına bitişik birinci elemanın merkezi, kaynak parmağı ile kaynak ile bağlanan en ince yapısal elemanın 0,4 katı kalınlığının arasına yerleştirilmelidir.
- Birincil ve ikincil elemanların kaplama, ağlar ve yüzey plakaları 4 düğümlü ince kabuk veya 8 düğümlü katı elemanlarla modellenmelidir. Dik gerilme gradyanı

söz konusu olduğunda, 8 düğümlü ince kabuk elemanları veya 20 düğümlü katı elemanlar önerilir.

- İnce kabuk elemanlar kullanıldığında, yapı plakaların orta yüzünde modellenecektir.
- Elemanların en boy oranı 2'den büyük olmamalıdır.



Şekil 3.3 : Sonlu elemanlar modelleme kriterleri [37].

Kaba ağ yapısı ile modellemek için; düğümlerin ve elemanların sayısı, modelin sertliği ve ataleti, gerçek gövde kiriş yapısını doğru bir şekilde temsil edilmesi ve yüklerin çeşitli yük taşıyıcı elemanlar arasındaki dağılımının dikkate alınması gerekir (Şekil 3.3). Bu amaçla yapısal model, aşağıdaki kriterlere göre inşa edilmelidir;

- Gövde kirişinin boylamasına mukavemetine katkıda bulunan ve modelde tek tek temsil edilmeyen sıradan takviyeler çubuk elemanlarıyla modellenecek ve düzenli aralıklarla gruplandırılacaktır.
- Birincil destek elemanlarının ağırları, boylarında yalnızca bir elemanla modellenebilir.
- Yüzey plakaları aynı enine kesite sahip çubuklarla simüle edilebilir.
- İki birincil destek elemanı arasındaki kaplama bir eleman şeridi ile modellenebilir.
- Sıradan takviye veya küçük boruların geçişi için delikler dikkate alınmayabilir.
- Birincil destek elemanlarının ağırlarındaki menholler göz ardı edilebilir.

Sık ağ yapısı ile yapısal detayları modellemek için, ilgi alanındaki gerilmelerin doğru bir temsilini elde etmek için aşağıdaki kriterlere dayanarak model inşa edilmelidir;

- Ağ boyutları, gerilme gradyanlarının sadık bir şekilde temsil edilmesini sağlayacak şekilde olmalıdır.
- İlgi alanındaki elemanların boyutu 50 mm x 50 mm'den fazla olmamalıdır.
- Rafine edilmiş alanın kapsamı, merkezinin çevresindeki herhangi bir yönde en az 10 eleman olmalıdır.
- Membran elemanlarının kullanımına sadece önemli burulma etkileri olmadığında izin verilir; diğer durumlarda, genel davranışa sahip elemanlar kullanılacaktır.
- Yüksek gerilme alanında doğrusal üçgen elemanların kullanımından mümkün olduğunca kaçınılmalıdır; dörtgen unsurlar mümkün olduğunca 90 ° açığa veya 60 ° ve 120 ° açılara sahip olmalıdır; en boy oranı 1'e yakın olmalıdır; doğrusal bir üçgen elemanın kullanımından kaçınılamıyorsa, kenarları aynı uzunlukta olmalıdır.
- Yerel ince ağ ya doğrudan küresel modele dahil edilebilir ya da ayrı bir alt modele ait olabilir; ağ boyutunun eğimi oldukça düşük olmalıdır.

Standart bir kafes modelinde, Von Mises değeri izin verilen ana gerilme değerinin (σ_{master}) yüzde doksan beşini aşan yüksek gerilme alanları, ince ağ yapısına sahip analiz ile araştırılır ve her iki kriter de kontrol edilir [37];

- Ortalama Von Mises eşdeğeri (σ_{vm-av}) $\leq \sigma_{master}$
- Her elementin eşdeğer gerilmesi (σ_{VM}) aşağıdaki formüle uymalıdır:

- kaynağa bitişik olmayan elemanlar için:

$$\sigma_{VM} \leq 1.53 \sigma_{master}$$

- kaynağa bitişik elemanlar için:

$$\sigma_{VM} \leq 1.34 \sigma_{master}$$


(50 mm x 50 mm) 'den daha ince ağ olması durumunda, eşdeğer gerilme σ_{VM} , eşdeğer bir alanın ortalamasının alınmasıyla elde edilecektir.

3.1.2 ClassNK : Nippon Kaiji Kyokai - Japon Loydu

Gerilme yığılmaları, çentikler ve malzeme yorgunluğunun zararlı etkilerini azaltan yapısal detayların tasarımında elemanların ve ilişkili braketlerin kesişme noktalarında uçların detayları, deliklerin şekli ve konumu, iç kısımlardaki yuvaların şekli ve takviyesi, kaynak ağzının ortadan kaldırılması veya kapatılması, braketlerin birleşiminin eğriselleştirilmesi, ani kesit değişikliklerinin veya yapısal süreksizliklerin azaltılması gereklidir. Motor, pervane veya dalga kaynaklı döngüsel gerilmelere bağlı yorulma tepkisini azaltmak için yapısal elemanların oranı ve kalınlığı, özellikle daha yüksek mukavemetli çelikler için gövde yapısının sonlu elemanlar analizi kullanılarak kuvvetlendirilmesi zorunludur.

Sonlu elemanlar analizi iki bölümden oluşur [23]:

- a) Boyuna tekne kirişli yapısal elemanların, birincil destekleyici yapısal elemanların ve enine perdelerin mukavemetini değerlendirmek için kargo tankı analizi.
- b) Yerel yapısal detaylardaki ayrıntılı gerilme seviyelerini değerlendirmek için ince ağ yapısına sahip analiz.



Şekil 3.4 : Sonlu eleman analizinin minimum gereksinimleri [23].

Boyuna tekne kiriş kesme kuvvetlerinin tekne kirişi dikey yüklerine karşı enine perdeler açısından mukavemet değerlendirmesi, uygun olduğunda palaka ve takviye özelliklerinin değişimi ile kargo tankı ortasında sonlu elemanlar modeline dayalı olabilir. Genel sonlu eleman analizi aşamaları Şekil 3.4'te gösterilmiştir.

3.1.3 DNV-GL : Det Norske Veritas - Germanischer Lloyd - Norveç-Alman Loydu

Norveç kuralları dört seviye sonlu elemanlar analizini kapsar ve bunlar:

- Gövde kiriş mukavemetini değerlendirmek ve kısmi gemi yapısal modellerine veya yerel sonlu eleman modellerine doğru sınır koşullarını vermek için küresel doğrudan mukavemet analizi.
- Kısmi gemi yapısal analizi, uzunlamasına gövde kirişli yapısal elemanların, birincil destekleyici yapısal elemanların ve perdelerin mukavemetini değerlendirmek.
- Nihai sınır durumu (ULS) için yerel gerilme seviyelerini değerlendirmek üzere yerel yapı analizi.
- Yorulma sınır durumu (FLS) için yerel yapısal detayları değerlendirmek için çok ince gözenek analizi.

Bir sonlu eleman modelinin yorulma analizinin uygulanmasındaki temel amaç, gerilme yanıtının daha doğru bir şekilde değerlendirilmesini sağlamaktır. Yöntemler, kabuk elemanlarını kullanarak birçok ayrıntı için uygulanabilir olarak kabul edilir, ancak bazı detaylar için özelleştirilmiş yöntemler gereklidir. Kabuk eleman, sabit kalınlıkta düzlem içi sertliğe ve düzlem dışı bükme sertliğine sahip yüzey elemanıdır ve plakaları temsil etmek için kullanılır. Takviyeler, eksenel, burulma, çift yönlü kesme ve bükülme sertliğine sahip kiriş elemanları ile modellenmelidir. Nötr eksenin eksantrikliği modellenmelidir. Keskin takviye elemanları ve birincil destek elemanlarının ve braketlerin yüzey plakaları kiriş veya çubuk elemanlar kullanılarak modellenmelidir.

Sonlu eleman analizi yapılırken tüm ana boyuna ve enine yapısal elemanlar, ağı takviyeleri dahil olmak üzere yapı üzerindeki tüm plakalar ve takviyeler modellenenecektir. Birincil destek elemanı gücüne katkıda bulunan ve boyutu tipik ağı boyutundan ($t \times t$) daha az olmayan braketler modellenenecektir. Modellemeler yapılırken dikkat edilmesi gereken unsurlar;


- Yüksek en boy oranından kaçınılmalı
- Üçgen kabuk eleman kullanımı minimum olmalı
- Yüksek gerilme alanlarında kabuk elemanın en boy oranı 1'e yakın olmalı
- Doğrusal eleman durumunda, düzlem gerilmesi veya kabuk elemanının şekil fonksiyonunun, modellenen elemanın geliştirilmiş bükülme davranışını sunan uyumsuz modlar içermesi gerekir [34].

Gerilmeler, ambar köşeleri gibi serbest bir plaka kenarında değerlendirilmeleri gerektiğinde, gerekli yerel kenar gerilme değerlerini elde etmek için ihmal edilebilir enine kesit alanına sahip kafes elemanlar kullanılmalıdır. Düzlem dışı bükülme durumunda, bitişik plaka kalınlığı ve göz ardı edilebilir genişliği ve genişlik ile aynı derinliğe sahip kiriş elemanları kullanılmalıdır [27].

Referans gerilme, σ_m , eleman merkezinde değerlendirilen plaka elemanının membran eksenel gerilme ve kayma gerilmelerine dayanır. Kabuk elemanlarının kullanıldığı yerlerde, gerilmeler elemanın orta düzleminde değerlendirilir. Genel olarak, iki düğüm çizgisi elemanı ve dört düğümlü izotropik kabuk elemanı, tekne yapısının temsili için yeterli kabul edilir.

Küresel olarak gemi kısmı ve ince ağ yapılı model analizleri için gerilme kabul kriterine karşı gelen değerlendirme kabuk elemanın düzlem içi gerilmelerine dayanır. Yorulma değerlendirmesi için de kabuk elemanın yüzey gerilmelerine bakılır. Membran yapıdaki elemanlarda tekillikler kafes sistemiyle engellenebilir, bu kafes kirişler tarafından herhangi bir yük aktarımından kaçınmak için zayıf yöndeki yükler bastırılmalıdır [34].

Düzlem davranışında iyileştirme için ilave iç serbestlik derecesine sahip 4 düğümlü kabuk elemanları için ve 8 düğümlü kabuk elemanları için ($t \times t$) ile ($2t \times 2t$) arasında bir ağ boyutu kullanılabilir. Sıcak nokta bölgesindeki daha büyük ağ boyutları konservatif olmayan sonuçlar sağlayabilir. Plaka veya kabuk elemanlarında, yüzey gerilmesi orta yan düğümlerinde değerlendirilebilir. Böylece, Şekil 3.5'teki A-B hattı boyunca orta yan düğümlerdeki gerilmeler, $0.5t$ ve $1.5t$ okuma noktalarında gerilme olarak doğrudan kullanılabilir.




Şekil 3.5 : Sıcak nokta gerilmesinin türetilmesi örneği.

Genelde üç boyutlu ve kabuk elemanlara sahip modeller kullanılarak yapılan sonlu eleman analizi, kabuk elemanlar kullanılarak ağ ile takviye edilmiş, huni bağlantılarında, kiriş tabanlarında ve güverte yapılarını gemi yapılarındaki dikey elemanlara bağlayan bağlantı noktalarında bulunan tipik haç biçimli birleşme yerleri üzerinde gerçekleştirilir. Kaynak ağzı uzunluğu bu analizlere dahil edilen bir parametredir. Bu analizlerin sonucuna dayanarak, kabuklu sonlu eleman modelleri kullanılarak kaynaklı bağlantılarda sıcak nokta gerilmesinin türetilmesi için bir yöntemi geliştirilmiştir. Kaynaklı nokta; iki boyutlu bir gerilme alanı olan plaka yapılarının modellenmesi için kabuk elemanları kullanılarak hesaplanır. Bu, elemanın koordinat sisteminde x ve y yönündeki gerilmeleri ve bir kesme gerilmesini ifade eder.

Gerilme dışarıda içeriden daha az olduğu için, halka takviye maddelerinin iç basınca maruz kalan bir kabuk yapısının dışına yerleştirilmesi tavsiye edilir. Bu, saf dış eksenel kuvvete maruz kalan boru şeklindeki elemanlardaki halka takviye cihazlarından farklı bir sonuçtur.

Şekil 3.6 'da gerilme okuma noktası sağa kaydırılırsa, kabuk analiz modelinden karşılık gelen azaltılmış bir okuma gerilmesi ile sonuçlanır. Bu, korunumlu olmayan bir sıcak nokta gerilmesi sağlayacaktır. Buna dayanarak, t_2 kalınlığı, kabuk elemanın analizinde kesişim çizgisinden okunan gerilme noktasına olan mesafeyi yönlendiren ilgili bir parametre olarak kabul edilmez.



Şekil 3.6 : Kabuk sonlu eleman modeli kullanarak sıcak nokta gerilmesinin türetilmesi.

Modelin büyüklüğü, hesaplanan sonuçların sınır koşulları ve yüklerin uygulanması için yapılan varsayımlardan önemli ölçüde etkilenmeyecek kadar büyük olmalıdır [34].

Yerel modelin kapsamı, dikkate alınan yapısal detay üzerindeki sınırlardan kaynaklanan etkilerin yeterince küçük olacağı ve makul sınır koşullarının formüle edilebileceği şekilde seçilmelidir [34].

Eleman boyutu daha küçükse, gerilme ortalaması yapılmalıdır. Bu gibi durumlarda, kısmi gemi modeli için gereken ağ büyüklüğüne eşdeğer bir alan içindeki Von Mises gerilmesi ağırlıklı alan, kaba ağın izin verilen sınır şartlarına uymaktır. Gerilme ortalaması, yapısal süreksizlikler ve bitişik yapı boyunca gerçekleştirilmemelidir [34].

Hem yorulma hem de lokal mukavemet değerlendirmesi gerekiyorsa, her iki analizde de yorgunluk için çok ince bir ağ modeli ($t \times t$) kullanılabilir. Bu durumda, lokal mukavemet değerlendirmesi için gerilmeler, belirtilen ağ boyutuna 50 mm x 50 mm'ye eşit bir alan üzerinde ağırlıklandırılmalıdır.

Kafes boyutu, eleman tipi, sınır koşulları ile ilgili tüm özellikler olması ve bu bilgilerin bilgisayardan elde edilmesi koşuluyla, herhangi bir tanınmış sonlu eleman yazılımı kullanılabilir. Bazı durumlarda kurallarda belirtildiği şekilde doğrudan yapısal mukavemet analizleri gerekir. Kılavuza uygun olarak yapılan analizler onaylanır.

3.2 Ağ Hassasiyetinin Önemi


Ağ boyutuna uygun sertlik gösterimi ve yük dağılımı dikkate alınarak karar verilmelidir. Standart ağ düzenlemesi normalde kafes noktaları birincil elemanların kesişimi şeklinde olacaktır. Genel olarak, eleman boyutu, uzunlamasına kirişler arasında bir eleman, enine yapılar arasında bir eleman ve kirişler ve güverteler arasında bir eleman olarak alınabilir. Birincil elemanların aralığı standart konfigürasyondan çok farklıysa, elemanların uygun bir en boy oranını ve modelin uygun ağ düzenlemesini sağlamak gereklidir [34]. Güverte evi ve baş kasara, birincil yapılar dahil olmak üzere benzer bir ağ idealizasyonu kullanılarak modellenmelidir.

Daha karmaşık geometriler için programın otomatik ağ boyutu oluşturmaya güvenmek gerekebilir. Genel olarak, otomatik ağ boyutu jeneratörleri, hexahedral elemanlardan ziyade tetrahedral elemanlardan yapılmış ağlar üretir. Bunun nedeni, genel bir üç boyutlu alanın her zaman bir tuğla grubuna ayrıştırılmamasıdır. Örneğin, doğrusal tetrahedral elemanların, beklendiği gibi, çok zorlanan elemanlar oldukları için çok iyi performans göstermedikleri bilinmektedir; bu nedenle tatmin edici bir doğruluk elde etmek için çok fazla eleman gereklidir. Özellikle, belirli sayıda düğüm


(veya serbestlik derecesi) için, hangi koşullar altında ikinci dereceden tetrahedra yerine tuğla (brick) eleman kullanmanın daha iyi olduğunu bilinmesi gerekir. Bu; bükülme, kesme, burulma ve eksenel davranış gibi farklı deformasyon kalıpları ile karakterize edilen çeşitli problemler altında bu tür elemanların doğruluğunu ve verimliliğini araştırmak gerektiği anlamına gelir.

İnce ağ analizi, kısmi gemi sonlu eleman modelinden veya küresel sonlu eleman modelinden elde edilen sınır koşulları ile bağlantılı olarak ince ağ yapıları bölgelere sahip ayrı bir yerel sonlu eleman modeli vasıtasıyla gerçekleştirilebilir. Alternatif olarak, ince ağ bölgeleri doğrudan küresel veya kısmi gemi modeline dahil edilebilir.


İnce ağ yapısına sahip bölge, yüksek gerilmenin lokalize alanını temsil eder. Bu bölgede kuadratik ağ kullanılmalı ve ince ağ bölgesine giden ağ yoğunluğunun yumuşak bir geçişi sağlanmalıdır. İnce gözenekli bölgelerin örnekleri Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da gösterilmektedir. İnce ağ yapısı olan bölgelerdeki sonlu eleman boyutu 50 mm x 50 mm'den büyük olmamalıdır.



Şekil 3.7 : Sıcak nokta hesaplaması için vinç tabanı ince aralıklı ağ yapısı [38].



Şekil 3.8 : Bir açıklığın etrafında ince ağ örülmüş bölge [39].



Şekil 3.9 : Braket etrafına örülü ince ağ [39].

Daha ince yapılı ağ ile azami kuvvet daha yüksek olduğundan gerilme alanındaki çoğu ayrıntı kaybolur. Ağ aralığı manuel ayarlanarak düzeltilebilir. Gerilme alanlarının fazla olduğu yerlerde ne kadar sık ağ yapısı olursa değerler o kadar yüksek çıkar. Gerçek çözüm değeri sonsuza gittiğinden sonuçlar yakınsak olmayacaktır.

Küresel veya kısmi gemi modelinde bir tarama analizi yapılabilir. Bu analizde dikkate alınan bir detayın ince ağ yapılı analiz için kritik yeri belirleme ve farklı konumlardaki bağıl gerilme seviyesini hesaplayarak benzer detayların yerel güç değerlendirmesini yapmak önemlidir.

Bir konum için ince ağ yapısı sonuçları biliniyorsa, tarama sonuçları benzer detayların yerel güç değerlendirmesini yapmak için kullanılabilir. Ancak bu ayrıntılar benzer geometriye, karşılaştırılabilir gerilme tepkisine ve yaklaşık olarak aynı ağa sahip olmalıdır. Bir tarama faktörü, K_{SC} , ince ağ analizinden ve buna karşılık gelen küresel veya kısmi gemi analiz sonuçlarından kaynaklanan gerilme sonuçlarına dayanarak aşağıda belirtilen 3.1 formülündeki gibi hesaplanır;

$$K_{SC} = \frac{\sigma_{FM}}{\sigma_{CM}} \quad (3.1)$$

σ_{FM} = Ele alınan detay için N / mm² cinsinden Von Mises ince ağ yapılı model gerilmesi

σ_{CM} = Ele alınan detay için N / mm² cinsinden Von Mises kaba ağ yapılı model gerilmesi.

(σ_{FM} ve σ_{CM} aynı düzlem pozisyonunda karşılık gelen elemanlardan alınmalıdır.)

Bir detay için tarama faktörü bulunduğunda, benzer detaylar için kullanım faktörü λ_{SC} aşağıdaki gibi hesaplanabilir;

$$\lambda_{SC} = \frac{K_{SC} \cdot \sigma_{SC}}{R_y} \leq \lambda_{fperm} \quad (3.2)$$

σ_c = Von Mises kaba ağ yapılı model gerilmesi, N / mm² cinsinden, detay olarak ele alınmıştır.

λ_{fperm} = İnce ağı yapı izin verilen verim kullanım faktörü.

R_y = Nominal verim gerilmesi, 235 / k'ye eşit olarak alınır.

Kullanım faktörü, λ_{SC} , sadece detayın geometrisinde, K_{SC} faktörünün belirlendiği ince ağda modellenen ilgili detay ile benzer olduğu yerlerde geçerlidir [34].

Lokal yapı mukavemet analizinden elde edilen sonucun, sonlu eleman analizinden elde edilen Von Mises gerilmelerinin ince ağ örülü olan bölgedeki maksimum izin verilen gerilmeyi aşmadığını göstermesi gerekir. Yorulma analizlerinde gerilme yığılma faktörü veya sıcak noktalar için kaba ağ yapısı ile kritik yerler belirlenir, sonrasında bu bölgelere kurallarda belirlenen kalınlıklara göre sık ağ yapısı uygulanır.

4. PARAMETRİK ANSYS MODELİ

ANSYS, sonlu eleman analizi ve tasarımı için genel amaçlı büyük bir bilgisayar programıdır; yapısal, mekanik, elektrik, elektromanyetik, termal, akışkan ve biyomedikal gibi mühendisliğin tüm disiplinlerinde onaylanmıştır. Kullanıcıların kişisel ihtiyaçlarına göre program tasarımlarına yardımcı olan geliştirme araçları sağlar. Araçlardan biri olarak APDL, ortak görevleri otomatikleştirmek veya modeli parametreler (değişkenler) açısından oluşturmak için kullanılabilen bir komut dosyası dili olan ANSYS Parametrik Tasarım Dili anlamına gelir.

APDL aynı zamanda bir komutun tekrarlanması, makrolar, if-then-else yapısı, döngüsü ve skaler, vektör ve matris işlemleri gibi çeşitli özellikleri de kapsar. Bu durumda, döngüye ve if-then-else komutlarına dayanan bir program, en uygun algoritmayı gerçekleştirmek için komut akışı dosyasına gömülür [40].

Parametrik analiz, gerilme, ısı akışı, kütle akışı ve diğer değişkenlere göre sistem performansı gibi tüm parametrelerin tasarım hedefleri üzerindeki etkisi hakkında doğru bilgi almanın mükemmel bir yoludur. Bu bilgilerle tasarım ekibi, özellikle erken kavramsal aşamada ürün geliştirme boyunca bilinçli kararlar verebilir. Parametrik analizin bir sonucu olarak, tasarım ekibi ayrıca dış kısıtlamalar (örneğin üretim) nedeniyle herhangi bir değişikliğe hızlı bir şekilde tepki verebilir [41].

Parametreleme işlemi, parametre oluşturulabilecek analiz işlemlerini tanımlayarak başlar. Bu, verimli bir yönetim gerçekleştirmek ve zaman ve kaynakları optimize etmek için önemli bir süreçtir.

Basit 2 boyutlu grafikler (tek veya çok değişkenli), tasarım değişkenlerine göre performans değişimi hakkında bilgi anlamak ve aktarmak için en kolay grafiklerdir. Hassasiyet grafikleri (çubuk veya pasta grafikler) ayrıca tasarım değişkenlerinin her birinin ürün performansı üzerindeki ağırlığı hakkında anında bilgi sağlar. Mühendisin temel parametreleri tanımlamasını ve odak noktasının nerede olması gerektiğini bilmesini sağlar. Bu tür bir yaklaşım, tasarımı etkilemeyen değişkenler üzerinde harcanan zamanı veya parayı azaltmaya ve ortadan kaldırmaya yardımcı olur.




5. MAKİNE ÖĞRENMESİ

5.1 Makine Öğrenmesi Nedir

Makine öğrenimi, uygulanmak istenen konu hakkında bilgiye dönüştürülebilecek verilerden bilgi elde etmek için çok sayıda teknik sunar. Bu yöntemlerin güçlü yönleri ve sınırlamaları, verileri modelleme, deneyler ve simülasyonlarla ilişkilendiren bilimsel araştırma perspektifinden ele alınmaktadır. Makine öğrenimi, çoğu endüstriyel uygulamaların mevcut hatlarını arttırabilen ve hatta dönüştürebilen güçlü bir bilgi işleme çerçevesi sağlar. Örnek verileri veya geçmiş deneyimleri kullanarak bir performans ölçütünü optimize eder.

Veriye dayalı yöntemlerin yaygınlığının artmasıyla, yapısal mekanikte öğrenme algoritmalarından faydalanılmalı ve insan anlayışını, mühendislik sezgisini tamamlamak için bu algoritmalar ilerletilmelidir. Öğrenme problemi: bir öğrenme makinesi, çıktısının yaklaşık bir tahminini oluşturmak için bir örnek jeneratörden gelen girdileri ve bir sistemden gelen gözlemleri kullanır (Şekil 5.1). Öğrenme makineleri temelde stokastik ve öğrenme süreçleri bir risk fonksiyonunun en aza indirilmesi olarak özetlenmiştir [42].



Şekil 5.1 : Makine öğrenmesinin basit bir ifadesi.


Tüm süreci tanımlamak mümkün olmasa da, belirli kalıpları veya düzenleri tespit edebilmek mümkündür. Bu tür kalıplar süreci anlamaya yardımcı olabilir veya tahminlerde bulunmak için bu kalıplar kullanılabilir: geleceğin, en azından yakın geleceğin, örnek veriler toplandığında geçmişten çok farklı olmayacağını varsayarak, gelecekteki tahminlerin de doğru olması beklenir [43].

Bazı parametrelere kadar tanımlanmış bir model var ise öğrenme, eğitim verilerini veya geçmiş deneyimleri kullanarak modelin parametrelerini optimize etmek için bir bilgisayar programının yürütülmesi önemlidir. Makine öğrenimi istatistik teorisini matematiksel modeller oluştururken kullanır, çünkü temel görev bir örnekten çıkarım yapmaktır. Bilgisayar biliminin rolü iki yönlüdür: birincisi, eğitimde, optimizasyon problemini çözmek ve ayrıca genel olarak sahip olunan büyük miktarda veriyi depolamak ve işlemek için verimli algoritmalara ihtiyaç vardır. İkincisi, bir model öğrenildikten sonra, çıkarım için temsiline ve algoritmik çözümünün de verimli olması gerekir. Bazı uygulamalarda, öğrenme veya çıkarım algoritmasının etkinliği, yani onun alanı ve zaman karmaşıklığı, öngörücü doğruluğu kadar önemli olabilir.

Makinelerin öğrenmelerini sağlayacak ve tahmin gibi görevleri yerine getirmelerini sağlayacak bilgisayar programları ile öğrenmenin amacı, girdiyi alan ve istenen sonucu üreten bir model oluşturmaktır. Bazen model anlaşılabilir, ancak diğer zamanlarda, sezgisel olarak açıklanamayan bir kara kutu gibi de olabilir. Model, makinelerin taklit etmesini istediğimiz sürecin bir tahmini olarak düşünülebilir. Böyle bir durumda, bazı girdiler için hatalar elde etmek mümkündür, ancak çoğu zaman model doğru cevaplar sağlar. Dolayısıyla, bir makine öğrenme algoritmasının başka bir performans ölçüsü (hız ve bellek kullanımı metriklerinin yanı sıra) sonuçların doğruluğu olacaktır [44].

5.2 Çeşitleri - Uygulama Alanları

Çeşitli öğrenme algoritması türleri üç ana kategoriye ayrılabilir: denetimli, denetimsiz ve yarı denetimli. Bu ayrımlar, bir uzmandan dış denetim bilgilerinin öğrenme makinesi için ne derece kullanılabilir olduğunu gösterir (Şekil 5.2). Makine öğrenmesinin farklı öğrenme tekniklerinden denetimli öğrenme tekniği sınıflandırılmış verilerle çalışır. Bunun yanı sıra, denetimsiz öğrenme etiketlenmemiş verilerle, yarı-denetimli öğrenme sınıflandırılmış ve sınıflandırılmamış verilerin karışımı ile, takviyeli öğrenme ise verisiz çalışır.



Şekil 5.2 : Çeşitli makine öğrenim yöntemlerinin örgütsel özeti.

5.2.1 Denetimli öğrenme

Denetimli öğrenme, makine öğrenmesinde düzeltici bilgilerin bulunmasını gerektirir. En basit ve en yaygın haliyle, makine öğrenmesinin çıktısına karşılık gelen sınıflandırmalar ile etiketlenmiş eğitim verilerini ifade eder. Örtük olarak eğitim verilerine bağlı olan maliyet fonksiyonunun en aza indirilmesi, makine öğrenmesinin bilinmeyen parametrelerini belirleyecektir. Bu bağlamda, denetimli öğrenme, Gauss tarafından yüzyıllar önce önerilen regresyon ve enterpolasyon yöntemlerine dayanmaktadır. Yaygın olarak kullanılan bir kayıp fonksiyonu;

$$L(y, \phi(x, y, w)) = ||y - \phi(x, y, w)||^2 \quad (5.1)$$

Alternatif kayıp fonksiyonları, makine öğrenmesi üzerinde seyreklik gibi farklı kısıtlamaları etkileyebilir [42,45]. Yaklaşım fonksiyonunun seçimi veriler hakkındaki önceki bilgileri yansıtır ve doğrusal ve doğrusal olmayan yöntemler arasındaki seçim, öğrenme yöntemleriyle ilişkili hesaplama maliyetini doğrudan taşır.


Çıktı vektörü Y , eğitim verilerinde bulunan her örnek için etiketlerden oluşur. Çıktı vektörü için bu etiketler süpervizör tarafından sağlanır. Genellikle bu denetçiler insanlardır, ancak makineler bu tür etiketleme için de kullanılabilir. İnsan kararları makinelerden daha pahalıdır, ancak makineler tarafından etiketlenen verilerdeki daha yüksek hata oranları, insan kararının üstünlüğünü göstermektedir. Manuel olarak etiketlenmiş veriler, denetimli öğrenme için değerli ve güvenilir bir kaynaktır. Bununla birlikte, bazı durumlarda, makineler güvenilir etiketleme için kullanılabilir [44].

Denetimli öğrenmede yaygın algoritmalar lojistik regresyon, saf bayes, destek vektör makineleri, yapay sinir ağları ve rastgele ormanları içerir. Hem regresyon hem de sınıflandırmada amaç, girdi verilerinde doğru çıktı verilerini etkili bir şekilde üretmemize izin veren spesifik ilişkiler veya yapı bulmaktır. Gürültülü veya yanlış veri etiketleri, modelin etkinliğini açıkça azaltacaktır.

Model karmaşıklığı, polinom derecesine benzer şekilde öğrenmeye çalışılan işlevin karmaşıklığını ifade eder. Model karmaşıklığının uygun seviyesi genellikle eğitim verilerinin niteliğine göre belirlenir. Az miktarda veriye sahipseniz veya verileriniz farklı olası senaryolara eşit olarak dağıtılmamışsa, düşük karmaşıklıkta bir model tercih edilmelidir. Bunun nedeni, az sayıda veri noktasında kullanıldığında yüksek karmaşıklığa sahip bir modelin gereğinden fazla uyum sağlamasıdır (overfitting). Aşırı uyum, eğitim verilerine çok iyi uyan, ancak diğer veri noktalarını genelleştirmeyen bir işlevi öğrenmeyi ifade eder.

Sapma-varyans dengesi aynı zamanda model genellemesiyle de ilgilidir. Herhangi bir modelde, sabit hata terimi olan sapma ile varyans arasında, hatanın farklı eğitim setleri arasında değişebileceği miktar olan bir denge vardır. Sapma ve varyans tipik olarak birbirinin zıt yönlerinde hareket etmektedir; artan yanlılık genellikle daha düşük varyansa yol açar. Genel olarak, artan sapma (ve varyansın azaltılması), nispeten garantili temel performans düzeylerine sahip modellerle sonuçlanır. Ayrıca, iyi genelleştirilmiş modeller üretmek için, model varyansı, eğitim verilerinin boyutu ve karmaşıklığına göre ölçeklendirilmelidir. Küçük, basit veri setleri genellikle düşük varyanslı modellerle öğrenilmeli ve büyük, karmaşık veri kümeleri, verilerin yapısını tam olarak öğrenmek için genellikle daha yüksek sapmalı modeller gerektirir [46].

Sinir ağları, denetimli öğrenmede en iyi bilinen yöntemlerdendir. Temel doğrusal olmayan fonksiyon tahmin edicileridir. Evrensel yaklaşım teoremi, herhangi bir fonksiyonun yeterince büyük ve derin bir ağ ile yakınlştırılabileceğini belirtir. Son çalışmalar, seyrek bağlı derin sinir ağlarının çok çeşitli fonksiyonlar ve sistemler için bilgi teorik optimal doğrusal olmayan tahmin ediciler olduğunu göstermiştir [47].



Şekil 5.3 : Denetimli öğrenme araçlarından en sık kullanılanlar.

Denetimli öğrenme, regresyon ve sınıflandırma problemlerine ayrılabilir (Şekil 5.3). Sınıflandırma çıktıları ayrık sınıf etiketleri iken, regresyon sürekli miktarların tahmini ile ilgilidir. Örneğin, bir finansal uygulamada, bir emtia fiyatını faiz oranları, döviz kurları, kullanılabilirlik ve talebin bir fonksiyonu olarak tahmin etmeye çalışılabilir [48].

5.2.2 Denetimsiz öğrenme

Denetimsiz öğrenmede süpervizörlerden veya eğitim verilerinden yoksundur. Başka bir deyişle, sahip olduğumuz tek şey etiketlenmemiş verilerdir. Fikir, bu verilerde gizli bir yapı bulmaktır. Verilerin etikete sahip olmamasının birkaç nedeni olabilir. Manuel etiketleme için ödenecek fonların bulunmaması veya verilerin kendisinin doğası gereği olabilir. Çok sayıda veri toplama cihazı ile, veriler daha önce görülmemiş bir hızda toplanmaktadır. Süpervizör olmadan bu verilerden bir şeyler almak önemlidir. Bugünün makine öğrenimi uygulayıcısı için zorluk budur [42].

Kümeleme, verilerdeki benzer grupları tanımlayan denetimsiz bir öğrenme tekniğidir. En yaygın algoritma, verileri k kümelerine ayıran k -ortalama kümelemedir; en yakın merkezli kümeye ait bir gözlem, veri uzayının Voronoi hücrelerine bölünmesine neden olur. Vektör nicelleştiriciler ise, önceden belirlenmiş sayıda kümeye bölünebilen veriler için temsili noktaları tanımlar. Bu noktalar, daha sonra gelecekteki örneklerin kendileri tarafından tahmin edilebilmesi için tam veri seti yerine kullanılabilir [42].

Denetimsiz öğrenmedeki en yaygın görevler kümeleme, temsil öğrenimi ve yoğunluk tahminidir. Tüm bu durumlarda, açıkça sağlanan etiketleri kullanmadan verilerimizin doğal yapısı öğrenilir. Bazı yaygın algoritmalar arasında k -ortalamları kümeleme, temel bileşen analizi ve otomatik kodlayıcılar bulunur. Hiçbir etiket sağlanmadığından, çoğu denetimsiz öğrenme yönteminde model performansını karşılaştırmanın belirli bir yolu yoktur.

Denetimsiz öğrenme için diğer yaygın kullanım örnekleri, keşif analizi ve boyutsallığın azaltılmasıdır. Keşif analizinde çok yararlıdır çünkü verilerdeki yapıyı otomatik olarak tanımlayabilir. Bir insanın verilerdeki eğilimleri teklif etmesinin imkansız veya pratik olmadığı durumlarda, gözetimsiz öğrenme, daha sonra bireysel hipotezleri test etmek için kullanılabilecek ilk bilgileri sağlayabilir.

Temsili öğrenmede, daha fazla veri işlemeyi daha az yoğun hale getirebilir ve gereksiz özellikleri ortadan kaldırabilir.

Daha az sütun veya özellik kullanan verileri temsil etmek için kullanılan yöntemlere atıfta bulunan boyutsallık azalması, denetimsiz yöntemlerle gerçekleştirilebilir.

5.2.3 Yarı denetimli öğrenme

Bu tür bir öğrenmede, verilen veriler sınıflandırılmış ve sınıflandırılmamış verilerin bir karışımıdır. Etiketlenmiş ve etiketlenmemiş verilerin bu kombinasyonu, verilerin sınıflandırılması için uygun bir model oluşturmak için kullanılır. Çoğu durumda,

etiketlenmiş veriler azdır ve etiketlenmemiş veriler bol miktarda bulunur. Yarı denetimli sınıflamanın hedefi, gelecekteki test verilerinin sınıflarını, yalnızca etiketli veriler kullanılarak üretilen modelden daha iyi tahmin edecek bir model öğrenmektir [44].

5.2.4 Takviyeli öğrenme

Takviye öğrenme, makine öğrenimi alanında yapılan en güncel araştırmalarda incelenen öğrenme türü olan denetimli öğrenmeden farklıdır. Denetimli öğrenme, bilgili bir dış denetim otoritesi tarafından sağlanan bir dizi etiketli eğitimden öğrenmek ve sistemin yanıtları tahmin edebilmesi veya genelleştirmesi, böylece eğitim setinde mevcut olmayan durumlarda doğru hareket etmesidir. Bu önemli bir öğrenme türüdür, ancak tek başına etkileşimden öğrenmek için yeterli değildir. Etkileşimli problemlerde, istenen davranış örneklerini elde etmek genellikle pratik değildir. Kişinin öğrenmenin en yararlı olmasını bekleyeceği keşfedilmemiş bölgelerde, bir temsilci kendi deneyiminden öğrenebilmelidir. Takviye öğrenimi, makine öğrenimi araştırmacılarının denetimsiz öğrenme dediği şeylerden farklıdır; bu, tipik olarak etiketlenmemiş veri koleksiyonlarında gizlenmiş olan yapıyı bulmakla ilgilidir [49].

Yapay zekanın en aktif araştırma alanlarından biri olan takviye öğrenme, bir ajanın karmaşık, belirsiz bir ortamla etkileşime girerken aldığı toplam ödül miktarını en üst düzeye çıkarmaya çalıştığı hesaplamaya dayalı bir yaklaşımdır.

Öğretilen nesneye hangi eylemlerin gerçekleştirileceği söylenmez, bunun yerine hangi eylemlerin onları deneyerek en fazla ödül verdiğini keşfetmesi gerekir. En ilginç ve zorlayıcı durumlarda, eylemler sadece ani ödülü değil, aynı zamanda bir sonraki durumu ve bundan sonraki tüm ödülleri de etkileyebilir. Bu iki özellik; deneme-yanılma ve arama-gecikmiş ödül pekiştirici öğrenmenin en önemli iki ayırt edici özelliğidir.

Takviye öğrenimi aynı anda bir problem, bir problem üzerinde iyi çalışan bir çözüm yöntemleri sınıfı ve bu problemi ve çözüm yöntemlerini inceleyen alandır [49].

Bir öğrenme aracı, ortamının durumunu bir dereceye kadar algılayabilmeli ve devleti etkileyen eylemler yapabilmelidir. Temsilcinin ayrıca çevrenin durumu ile ilgili bir amacı veya hedefleri olmalıdır. Markov karar süreçlerinin hiçbirisi önemsizleştirilmeden sadece bu üç yönü (duyum, eylem ve amaç) mümkün olan en basit biçimlerine dahil etmesi amaçlanmıştır. Bu tür problemleri çözmek için uygun herhangi bir yöntem, pekiştirici bir öğrenme yöntemi olarak kabul edilir.

Takviye öğrenme yöntemi, ödülü en üst düzeye çıkaracak veya riski en aza indirecek eylemler yapmak için çevre ile etkileşimden elde edilen gözlemleri kullanmayı

amaçlamaktadır. Akıllı programlar üretmek için takviye öğrenimi aşağıdaki adımlardan geçer:

1. Giriş durumu ajan tarafından gözlenir.
2. Karar verme işlevi, aracının bir eylem gerçekleştirmesini sağlamak için kullanılır.
3. Eylem gerçekleştirildikten sonra, temsilci çevreden ödül veya takviye alır.
4. Ödülle ilgili durum-eylem çifti bilgileri saklanır.

Saklanan bilgileri kullanarak, eylem açısından belirli bir durum için ince ayar yapılabilir, böylece en uygun kararların alınmasına yardımcı olur.

5.3 Regresyon Modelleri ve Kullanımı

Regresyon analizi, bağımlı hedef ve bağımsız değişken arasındaki ilişkiyi araştıran bir tahmine dayalı modelleme tekniğidir. Bu teknik, tahminler, zaman serileri modellemesi ve değişkenler arasındaki nedensel etki ilişkisini bulmak için kullanılır. Örneğin, bir evin fiyatını dolar olarak tahmin etmek bir regresyon problemidir, bir tümörün kötü veya iyi huylu olup olmadığını tahmin etmek bir sınıflandırma problemidir. Regresyon analizinin avantajlarından bazıları şunlardır;

- Bağımlı değişken ile bağımsız değişken arasındaki anlamlı ilişkileri gösterir.
- Birden fazla bağımsız değişkenin bağımlı bir değişken üzerindeki etkisinin gücünü gösterir.
- Farklı ölçeklerde ölçülen değişkenlerin etkilerini de karşılaştırılmasını sağlar.

Bu faydalar, pazar araştırmacılarının, veri analistlerinin, veri bilimcilerinin tahmin modelleri oluşturmak için kullanılacak en iyi değişken setini ortaya çıkarması ve değerlendirmesine yardımcı olur. Regresyon için bağımsız değişkenlerin sayısı, bağımlı değişkenlerin türü ve regresyon çizgisinin şekline bakılarak yöntem belirlenebilir.

5.3.1 Doğrusal regresyon


Cebirde "doğrusallık" terimi, iki veya daha fazla değişken arasındaki doğrusal bir ilişki anlamına gelir. Bu ilişkiyi iki boyutlu bir alanda (iki değişken arasında) çizersek, düz bir çizgi elde ederiz. Basit bir doğrusal denklem örneğini ele alırsak;

$$y = mx + b \quad (5.2)$$

5.2 denkleminde belirtilen b kesişme noktasıdır ve m çizginin eğimidir. Temel olarak, lineer regresyon algoritması, iki boyutta kesişme ve eğim için en uygun değeri verir. Veri özellikleri oldukları ve değiştirilemedikleri için y ve x değişkenleri aynı kalır. Kontrol edilebilen değerler kesme noktası ve eğimdir. Kesişim ve eğim değerlerine bağlı olarak birden fazla düz çizgi olabilir. Temel olarak doğrusal regresyon algoritmasının yaptığı şey, veri noktalarında birden çok satıra sığması ve en az hata ile sonuçlanan satırı döndürmesidir.

Doğrusal regresyon, hedef ile bir veya daha fazla öngörücü arasındaki doğrusal ilişkiyi bulmak için kullanılır. Basit ve çoklu olmak üzere iki çeşidi vardır. Basit doğrusal regresyon iki sürekli değişkenden oluşur, bunlardan biri öngörücü veya bağımsız, diğeri yanıt veya bağımlı değişkendir. Basit doğrusal regresyon ve çoklu doğrusal regresyon arasındaki fark, çoklu doğrusal regresyonun birden fazla bağımsız değişkene sahipken, basit doğrusal regresyonun sadece 1 bağımsız değişkene sahip olmasıdır. Doğrusal regresyonda, özellik ölçeklendirmesine ihtiyacımız yoktur çünkü genelde program kütüphaneleri tarafından bu özellik sağlanır.

En küçük kare yöntemi, bir regresyon hattını tanımlamak için kullanılan en yaygın yöntemdir. Her veri noktasından çizgiye dikey sapmaların karelerinin toplamını en aza indirerek, gözlemlenen veriler için en uygun çizgiyi hesaplar (Şekil 5.4). Sapmalar ilk önce kareye alındığı için, pozitif ve negatif değerler eklendiğinde işlem iptali yoktur [50].



Şekil 5.4 : En küçük kare yöntemi grafiği.

Bunlar dışında doğrusal regresyon, aykırı değerlere çok duyarlıdır. Regresyon çizgisini ve nihayetinde öngörülen değerleri çok etkileyebilir. Çoklu doğrusallıkta ise, katsayı tahminlerinin varyansını artırabilir ve tahminleri modeldeki küçük değişikliklere

karşı çok hassas hale getirebilir [50]. Birden fazla bağımsız değişken olması durumunda, en önemli bağımsız değişkenlerin seçimi için ileriye doğru seçim, geriye doğru eleme ve adım adım yaklaşıma gidilmelidir.

5.3.2 Lojistik regresyon


Lojistik regresyon, iyi kalibre edilmiş olasılık veren tahmin yöntemidir. Lojistik regresyon, olay=başarı ve olay=hata olasılığını bulmak için kullanılır. Bağımlı değişken doğada ikili (0/1, Doğru / Yanlış, Evet / Hayır) olduğunda lojistik regresyon kullanılır (Şekil 5.5). Burada 0 ile 1 arasında değişen Y değeri aşağıdaki denklemle temsil edilebilir;

$$oran = \frac{\rho}{(1-\rho)} = \frac{\text{olayın meydana gelme olasılığı}}{\text{olayın meydana gelmeme olasılığı}} \quad (5.3)$$

$$\ln(oran) = \ln(\rho / (1 - \rho)) \quad (5.4)$$

$$\text{logit}(\rho) = \ln(\rho / (1 - \rho)) = b_0 + b_1X_1 + b_2X_2 + b_3X_3 \dots + b_kX_k \quad (5.5)$$

Yukarıda ρ , ilgilenilen özelliğin var olma olasılığıdır. Burada bir binom dağılımı (bağımlı değişken) olduğu için, bu dağıtımda en uygun bağlantı fonksiyonu Bernoulli örneklerinde kanonik bağlantı olan logit olarak seçilir. Denklemde parametreler, kare hataların toplamını minimize etmek yerine örnek değerlerini gözlemleme olasılığını en üst düzeye çıkarmak için seçilir [43,50].



Şekil 5.5 : Sigmoid fonksiyonu olarak adlandırılan lojistik fonksiyon.

Lojistik regresyon, bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki gerektirmez. Öngörülen olasılık oranına doğrusal olmayan bir günlük dönüşümü uyguladığı için çeşitli ilişki türlerini işleyebilir. Büyük örnek boyutları gerektirir, çünkü


maksimum olasılık tahminleri düşük örnek boyutlarında normal en küçük karelere göre daha az güçlüdür. Bağımsız değişkenler birbirleriyle ilişkilendirilmemelidir, yani çoklu eşzamanlılık olmamalıdır. Ancak, kategorik değişkenlerin etkileşim etkilerini analize ve modele dahil edilebilir.

5.3.3 Polinom regresyonu

Bağımsız değişkenin gücü 1'den fazlaysa, bir regresyon denklemi bir polinom regresyon denklemidir. Denklem 5.6, bir polinom denklemini temsil eder:

$$y = a + b * x^2 \quad (5.6)$$

Bu regresyon tekniğinde, en uygun çizgi düz bir çizgi değildir. Daha çok veri noktalarına uyan bir eğridir (Şekil 5.6). Düşük hata elde etmek için daha yüksek dereceli bir polinom eğrisi sığdırmak aşırı uyuma neden olabilir. Özellikle uçlara doğru eğriler ve eğilimlerin anlamlı ise denklem bulunmuştur. Daha yüksek polinomlar ekstrapolasyon konusunda garip sonuçlar doğurabilir [51].




Şekil 5.6 : Polinom regresyonu grafik örneği [51].

5.3.4 Destek vektör regresyonu

Makine öğreniminde destek vektör makineleri, verileri analiz eden ve sınıflandırma ve regresyon analizi için kullanılan kalıpları tanıyan ilişkili öğrenme algoritmalarına sahip denetimli öğrenme modelleridir. Her biri iki kategoriden birine ait olarak işaretlenmiş bir dizi eğitim örneği göz önüne alındığında, bir SVM eğitim algoritması bir kategoriye veya diğerine yeni örnekler atayarak onu tesadüfi olmayan ikili doğrusal sınıflandırıcı haline getirir. SVM modeli, örneklerin uzaydaki noktalar olarak eşlenmiş haliyle temsil edilmesidir, böylece ayrı kategorilerin örnekleri mümkün olduğunca geniş bir açıklık ile bölünür. Daha sonra yeni örnekler aynı alana haritalanır ve boşluğun hangi tarafına düştüklerine göre bir kategoriye ait olduğu tahmin edilir [52].

Destek vektör regresyonu (SVR), modelde ne kadar hatanın kabul edilebilir olduğunu tanımlama esnekliği sağlar ve verilere uyacak şekilde daha yüksek boyutlarda uygun bir çizgi veya köprü bulacaktır.


SVR, hem kabul edilebilir bir hata payı (ϵ) hem de kabul edilebilir hata oranının dışına çıkma toleransını (Şekil 5.7) ayarlayarak hatalara ne kadar tolerans gösterileceğini sağlayan güçlü bir algoritmadır [53].



Şekil 5.7 : Destek vektör regresyonu örneği.

Destek vektör makinesi (SVM) başlangıçta sınıflandırma problemi için ortaya atılmış, daha sonra regresyon için genişletilmiştir. Anahtar kavram, hata-duyarsız fonksiyonunun konseptidir, bu fonksiyon 5.7 denkleminde gösterilmiştir [48];

$$g_{\epsilon} = \{|z| - \epsilon \text{ if } |z| \geq \epsilon\}, \text{ diğ} \text{er durumlar için ise } g_{\epsilon} = 0 \quad (5.7)$$



Şekil 5.8 : Destek vektör regresyonu hata-duyarsız fonksiyonu.

Yukarıdaki şekilde (Şekil 5.8) görünen fonksiyon $\exp(-g_{\epsilon}(z))$ regresyon farkları için bir olasılık modeli olarak kullanılabilir ve bu bir Gauss modeline karşılık gelen kare hata fonksiyonudur.

Bununla birlikte, bunun farkların dağılımı için alışılmadık bir model seçimidir ve temel olarak destek vektör sınıflandırıcısında olduğu gibi seyrek bir çözüm elde edilir.

Hata modeli $\epsilon=0$ ise, en az mutlak değer regresyonuna karşılık gelen bir Laplacian dağılımıdır; bu aykırı değerlere karşı bir miktar koruma sağlar. Laplacian dağılımı,

varyanslar üzerinde belirli bir dağılıma sahip sıfır ortalama Gauss'ların sürekli bir karışımı olarak görülebilir. Hata duyarsız fonksiyonuna karşılık gelen olasılıklı bir model elde etmek için araçların $[-\epsilon, \epsilon]$ 'de eşit olarak kaymasına izin verilerek bu sonuç genişletilebilir.

Hata duyarsız fonksiyonu olan lineer regresyon durumu ve Gauss önsel değeri (prior), w 'nin değeri aşağıdaki fonksiyonda en aza indirilerek elde edilir;

$\frac{1}{2} |w|^2 + C \sum_{i=1}^n g_{\epsilon}(y_i - f_i)$, $f(x_*) = \sum_{i=1}^n \alpha_i x_i$ burada y_i hedef, w_i katsayı ve x_i tahmin unsurudur.

Destek vektör sınıflandırmasında, α_i katsayılarının çoğu sıfırdır. ϵ -tüpü içerisinde yer alan veri noktalarında $\alpha_i = 0$ iken, kenarda veya dışarıda olanlar sıfır olmayan α_i 'ye sahiptir.

5.3.5 Karar ağacı regresyonu

Karar ağacı, ağaç yapısı şeklinde regresyon veya sınıflandırma modelleri oluşturur. Bir veri kümesini daha küçük ve alt kümelere ayırırken, aynı zamanda ilişkili bir karar ağacı aşamalı olarak geliştirilir. Nihai sonuç karar düğümleri ve yaprak düğümleri olan bir ağaçtır. Karar düğümünde, her biri test edilen özellik için değerleri temsil eden iki veya daha fazla dal vardır. Yaprak düğümü ise sayısal hedefe ilişkin bir kararı temsil eder. En iyi tahmin unsuruna karşılık gelen en üst karar düğümüne kök düğüm adı verilir. Karar ağaçları hem kategorik hem de sayısal verileri işleyebilir [54].

Karar ağaçları, gürültülü gözlem ekleyerek bir sinüs eğrisine uymak için kullanılır. Sonuç olarak, sinüs eğrisine yaklaşan lokal lineer regresyonları öğrenir. Ağacın maksimum derinliği çok yüksek ise, karar ağaçları eğitim verilerinde çok ince ayrıntılardan ve gürültüden öğrenir yani aşırı uyum oluşur [55].

Karar ağacı, inşa edildikten sonra, tüm eğitim setini değil, sadece ağacın yapısını, karar düğümlerinin parametrelerini ve yapraklardaki çıktı değerlerini saklar; bu, tüm eğitim örneklerini saklayan örnek tabanlı parametrik olmayan yöntemlerin aksine, alan karmaşıklığının da çok daha az olduğu anlamına gelir [43].


5.3.6 Rastgele orman regresyonu

Rastgele orman, veri kümesinin çeşitli alt örnekleri üzerinde bir dizi sınıflandırma karar ağacına uyan ve tahmin doğruluğunu geliştirmek ve aşırı uyumu kontrol etmek için ortalama alma kullanan bir meta tahmincidir. Alt örnek boyutu kontrol edilir, aksi takdirde her bir ağacı oluşturmak için tüm veri kümesi kullanılır. Bireysel karar ağaçları

tipik olarak yüksek sapma gösterir ve aşırı uyuma (overfitting) eğilim gösterir. Ormanlara enjekte edilen rastgelelik, biraz ayrılmış tahmin hataları olan karar ağaçları verir. Bu tahminlerin ortalamasını alarak bazı hatalar iptal edilebilir. Rastgele ormanlar, çeşitli ağaçları birleştirerek, azaltılmış bir varyans elde eder. Uygulamada, varyans azalması genellikle önemlidir, bu nedenle genel olarak daha iyi bir model elde edilir [56].

Rastgele orman yöntemi, sınıflandırma için kullanıldığında her ağaçtan bir sınıf oyu alır ve daha sonra çoğunluk oyu ile sınıflandırır. Regresyon için kullanıldığında, hedef x noktasında her ağaçtan tahminlerin ortalaması alınır. Aynı zamanda sınıflandırmada, m için varsayılan pozitif korelasyon değeri $[\sqrt{p}]$ ve minimum düğüm boyutu birdir. Regresyon için ise, m için varsayılan korelasyon değeri $[p / 3]$ ve minimum düğüm boyutu beştir.

Bu parametreler için en iyi değerler probleme bağlı olacaktır ve ayar parametreleri olarak ele alınmalıdır [45].



Şekil 5.9 : Rastgele orman regresyon örneği.

Ağaç boyutunun rastgele orman regresyonunda hataya etkisi. Ağaç derinliği minimum düğüm boyutuyla kontrol edilir; minimum düğüm boyutu ne kadar küçük olursa, ağaçlar o kadar derin olur. Şekil 5.9 'da gerçek yüzey 12 değişkenin ikisinde toplanır ve buna Gauss gürültüsünün birim varyansı eklenir.

5.3.7 Bayes regresyonu

Bayesci doğrusal regresyon, yetersiz veri veya zayıf dağıtılmış verilerden kurtulmak için oldukça doğal bir mekanizmaya izin verir. Veri yokluğunda, önceliklerin belirlenebilmesi için katsayılar ve gürültüye yer vermenizi sağlar. Daha da önemlisi, Bayes doğrusal regresyonu ile, verilere uygunluğunun hangi kısımların kendinden emin olduğunu ve hangi kısımların çok belirsiz olduğunu öğrenebilirsiniz [57].

Bayes, hesaplama güçlerindeki ilerlemelerle posterior olasılıkların örneklenmesine veya yaklaşık olasılıklara yakınlaşmaya olanak tanır. Bu basitlik tercihi birçok bağlamda Bayesci yaklaşım, düzenleme, minimum açıklama uzunluğu olarak ortaya çıkar ve istatistiksel çıkarımın ve dolayısıyla makine öğrenmesinin merkezinde yer alır.

Tıpkı destek vektör makinelerinde olduğu gibi diğer bazı çekirdeklerin işlevleri (örneğin, ağırlıklı toplamalar) yeni çekirdekler olarak oluşturabileceğiniz yöntemler vardır ve bu ağırlıklar veya tip 2 maksimum çekirdek parametreleri maksimum olasılıkla optimize edilebilir [48].

Bayesci Doğrusal Regresyonun amacı model parametrelerinin tek “en iyi” değerini bulmak değil, model parametreleri için posterior dağılımı belirlemektir. Sadece bir olasılık dağılımından üretilen yanıt değil, aynı zamanda model parametrelerinin de bir dağılımdan geldiği varsayılmaktadır.

Bayes kuralını kullanılarak, prior ve olasılık birleştirilip posterior olasılık dağılımını hesaplanırsa [43];

$$\rho(\theta|X) = \frac{\rho(\theta)\rho(x|\theta)}{\rho(X)} = \text{posterior} = \frac{\text{olasılık} \cdot \text{prior}}{\text{normalleştirme}} \quad (5.8)$$

Prior; etki alanı veya model parametrelerinin ne olması gerektiğine dair bir tahmin varsa modele dahil edilebilir. Önceden tahmin yoksa, normal dağılım gibi parametreler için bilgilendirici olmayan öncelikler kullanılabilir.

Posterior: Bayesci doğrusal regresyon sonucu, olası model parametrelerinin verilere ve öncekine göre dağıtılmasıdır. Bu, model hakkındaki belirsizliğin ölçülmesini sağlar. Daha az veri noktası varsa, posterior dağılım daha fazla yayılacaktır.

$$r = w^T x + \varepsilon, \quad \rho(\varepsilon) \sim N(0, 1/\beta) \quad \text{ve} \quad \rho(r^t | x^t, w, \beta) \sim N(w^T x^t, 1/\beta) \quad (5.9)$$

Yukarıda formülü verilmiş olan β 'nin katkı gürültüsünün hassasiyetini ifade ettiği doğrusal regresyon modeli ele alınırsa,

Logaritmik olasılık; $L(r|X, w, \beta) = \log \prod_e \rho(r^t|x^t, w, \beta) = -N \log(\sqrt{2\pi}) + N \log \beta - \frac{\beta}{2} \sum_t (r^t - w^T x^t)^2$

Makine öğrenmesi çözümü; $w_{ML} = (X^T X)^{-1} X^T r$, $X = \{x^t, r^t\}_{t=1}^N$

Gauss eşlenik önsel(prior); $\rho(w) \sim N(0, 1/\alpha)$

Sonsal(Posterior); $\rho(w|X) \sim N(\mu_N, \Sigma_N)$, $\mu_N = \beta \Sigma_N X^T r$, $\Sigma_N = (\alpha I + \beta X^T X)^{-1}$


α : hiperparametre

β : gürültü

w : parametrelerin ağırlıkları

X : örnekler

Şekil 5.10'da farklı α ve β değerleri için Bayes lineer regresyonundaki değişim gösterilmektedir. Solda, çarpılar veri noktalarıdır ve düz çizgi makine öğrenmesi çözümüdür. Bir standart sapma hata çubuğuna sahip MAP çözümü de kesikli olarak gösterilir. Ortada, önsel (prior) yoğunluk sıfır merkezli ve varyansı $1/\alpha$ olmaktadır. Sağda, ortalaması MAP çözeltisi olan sonsal (posterior) yoğunluk gösterilmektedir. Önceki büzülmelerin ve çizginin varyansının α artırıldığında düz sıfır çizgisine yaklaştığını görülmektedir. Daha fazla gürültü olduğu varsayıldığında (β azaldığında) sonsal yoğunluk daha yüksek varyansa sahip olur.



Şekil 5.10 : Farklı α ve β değerleri için Bayes regresyonu.

Bayes doğrusal modeli kullanılarak tek bir veri noktası için çıktıyı tahmin ederken, tek bir değer değil bir dağılım elde ediliyor. Sınırlı veriye sahip olunan veya modelde kullanılmak istenen bazı ön bilgiler var ise bu problemlerde, Bayesci Doğrusal Regresyon yaklaşımı hem önceki bilgileri içerebilir hem de belirsizliği gösterebilir. Bir başlangıç tahmini oluşturulur ve daha fazla veri toplarken tahmin geliştirilir.

5.3.8 Gauss süreci regresyonu

Gauss süreci regresyon (GPR), makine öğrenmesi alanında dalgalanmalar yapan regresyona parametrik olmayan Bayesci bir yaklaşımdır. GPR'nin küçük veri kümelerinde iyi çalıştığı ve tahminler üzerinde belirsizlik ölçümleri sağlayabildiği çeşitli faydaları vardır. Bayesci yaklaşım olası tüm değerler üzerinde bir olasılık dağılımı belirler. Bu yaklaşımda parametreleri daha önce dağıtılmış rastgele değişkenler olarak görüyoruz. Diğer güdümlü öğrenme yöntemleri de her parametre için kesin değerleri öğrenir. GPR verilere uygun tüm kabul edilebilir fonksiyonlar üzerindeki olasılık dağılımını hesaplar. Ön şart noktası belirlenir, eğitim verileri kullanılarak posterior hesaplanır ve ilgili noktadaki tahmini posterior ile karşılaştırılır. Gaussian yönteminde gerçek y değerleri ile tahmin edilen y değerleri arasındaki farkın kareleri toplamının minimum olması gerekir.

Optimizasyon algoritmaları belirli veriler için bir modelin en iyi parametrelerini stokastik bir şekilde sunarken, Bayesian çıkarımı model parametrelerinin tam olasılık dağılımını sağlamayı amaçlamaktadır. Bayesian çıkarımının makine öğreniminden daha da güçlü bir dil olduğu ve tüm parametreler için olasılık dağılımları sağladığı ve genellikle klasik makine öğrenme algoritmalarında olduğu gibi tek değerlerden ziyade sağlam tahminlere yol açtığı iddia edilebilir. Bununla birlikte, Bayesci çıkarım için önemli bir dezavantaj, pahalı fonksiyon değerlendirmeleri (örneğin rüzgar tüneli deneyleri veya büyük ölçekli DNS) için engelleyici olabilen yüksek boyutlu alanlarda örnekleme ve entegrasyonu içerdiği için hesaplama maliyetidir [58].

Regresyon için çekirdek tabanlı yöntemlere benzeyen Gauss süreçlerinden (GP) bahsedilmelidir. Ancak GP'ler bu çekirdekleri mevcut verilere göre uyarlanabilir şekilde geliştirir. Ayrıca ilgili model parametreleri için olasılık dağılımları sağlar. GP'ler zamana bağlı problemlerde yaygın olarak kullanılmıştır ve daha pahalı olsa da rakip olarak düşünülebilir. GP'ler pahalı maliyet için taşıyıcı olarak da kullanılabilir [59].

Doğrusal bir model için ($y = w^T x$), x girişi için tek bir y çıkışı yerine, ağırlık dağılımı $p(w)$ 'ye dayalı sonuç elde edilir. $p(w)$ 'nin Gaussian olması durumunda, her y değeri hem Gaussianların doğrusal bir kombinasyonudur hem de Gaussian'dır.

Özellikle, N girdi veri noktalarında hesaplanan y değerlerinin ortak dağılımı ile ilgilenilir, $x_t, t = 1, \dots, N$.

Gauss önsel (prior) değerinin girdilerin sıfır ortalaması olduğu kabul edilir; $\rho(w) \sim N(0, 1/\alpha)$

$N \times d$ veri noktaları, X ve $d \times 1$ ağırlık vektörü göz önüne alındığında y değerleri;

$$y = Xw, \quad E[y] = 0 \text{ ve } Cov(y) = K \quad (5.10)$$

K, elementli Gram matrisi ile kovaryans fonksiyonudur; $K, K_{ij} = (x^i)^T x^j$

Bu, Gauss fonksiyon süreçleri literatüründe fikir olarak çekirdek fonksiyonları gibidir. Bir dizi temel fonksiyon kullanarak ($\phi(x)$), orijinal girdilerin skaler çarpımını temel fonksiyonun iç çarpımı olacak şekilde bir kernel tarafından genelleme yapılır;

$$\phi(x), K_{ij} = (\phi(x^i))^T \phi(x^j) \quad (5.11)$$

Gerçek gözlemlenen çıkış r, gürültü eklenmiş hat ile verilir;


$$r \sim N_N(0, C_N), \quad C_N = (1/\beta)I + K \quad (5.12)$$

Bir tahmin yapmak için yeni verileri ($N + 1$) veri noktası çifti (x', r') olarak kabul edilir ve ortak dağılım fonksiyonu şu şekilde yazılır; $x_{N+1}, r_{N+1} \sim N_{N+1}(0, C_{N+1})$

Burada; $k = [K(x', x^t)]^T$ ve $c = K(x', x') + 1/\beta$

$$C_{N+1} = \begin{bmatrix} C_N & k \\ k^T & c \end{bmatrix}$$

Bunlar sonucunda tahmin; $\rho(r'|x', X, r) \sim N(k^T C_{N-1}^{-1} r, c - k^T C_{N-1}^{-1} k)$



Şekil 5.11 : Bir standart sapma hata çubuğu ile Gauss işlemi regresyonu: (a) Doğrusal kernel, (b) Kuadratik kernel, (c) Yayılmış Gauss kerneli [43].

Yukarıda belirtilen şekilde çeşitli çekirdek parametreleri kullanılarak örnek verilmiştir (Şekil 5.11). İlk ikisi, karşılıklı gelen temel fonksiyonlarının iç çarpımı olarak tanımlanır; Gauss çekirdeği ise doğrudan şu şekilde tanımlanır;

$$K_G(x^i, x^j) = \exp \left[-\frac{\|x^i - x^j\|^2}{s^2} \right] \quad (5.13)$$


Bir Gauss çekirdeği söz konusu olduğunda, yalnızca yakınlarda çok az veri olan bir konum içinde örnekler etkilidir ve tahmin sapması yüksektir.

Kernel işlevleri, uygulamaya bağlı olarak tanımlanabilir ve kullanılabilir. Temel işlevlerin hesaplanması veya depolanması gerekmeden doğrudan çekirdek işlevlerini kullanma olasılığı büyük bir esneklik sunar [43]. Normalde, bir eğitim seti göz önüne alındığında, önce parametreler hesaplanır ve daha sonra parametreler tahmin yapmak için kullanılır, eğitim setine ihtiyaç duyulmaz. Bu mantıklıdır, çünkü genellikle parametrelerin boyutu, eğitim seti N'nin boyutundan çok daha düşüktür.

5.3.9 Regresyon için kernel makineleri

Kernel fonksiyonları, algoritmalar için doğrusallıktan doğrusal olmamaya basit bir köprü sağladığından birçok uygulamada kullanılabilir ve skaler çarpım olarak ifade edilebilir. Kernel yöntemleri, görüntü sınıflandırması ve nesne algılama gibi belirli uygulamalarda çok sık kullanılır. Örneğin analizinin genel görevi, genel veri türlerinde (diziler, metin belgeleri, nokta kümeleri, vektörler, görüntüler gibi) genel ilişki türlerini (kümeler, sıralamalar, temel bileşenler, korelasyonlar, sınıflandırmalar) bulmak ve araştırmaktır. Kernel yöntemleri, bu yüksek boyutlu alanda verilerin daha kolay ayrılabilirliği veya daha iyi yapılandırılabilirliği umuduyla verileri daha yüksek boyutlu alanlara eşler [60].

Giriş verileri daha yüksek boyutlu bir alana eşlenirse, bu alanda çalışan doğrusal bir algoritma orijinal giriş alanında doğrusal olmayan bir şekilde davranacaktır. Doğrusal olarak ayrılmaz verilerin doğrusal olarak ayrılabilir verilerle dönüştürülmesi gerekir (Şekil 5.12). Kernel işlevi, orijinal doğrusal olmayan gözlemleri ayrılabilirlikleri daha yüksek boyutlu bir alana eşlemek için her veri örneğine uygulanan işlevdir.



Şekil 5.12 : Kernel işlevi.

Algoritma sadece iki vektör arasındaki iç çarpım olarak ifade edilebilirse, bu iç çarpımı başka bir uygun alandan iç çarpımla değiştirmeye kernel hilesi denir. Skaler çarpımın kullanıldığı her yerde, bunun yerine kernel işlevi kullanılır. Kernel işlevi, özellik alanında bir iç çarpımı belirtir ve genellikle şu şekilde gösterilir;

$$k(z_i, z_j) = \langle \varphi(z_i), \varphi(z_j) \rangle \quad (5.14)$$

Burada k Gram matrisi veya gözlenen $\{z_1, \dots, z_n\}$ öznelikleri verilen çekirdek fonksiyonudur, (z_i, z_j) n boyutlu girdilerdir. φ , $n \times m$ boyutlu bir haritadır. $\langle z_i, z_j \rangle$ skaler çarpımı belirtir [61].

Kernel fonksiyonları sürekli, simetrik olmalı ve tercihen yarı-kesin artı bir Gram matrisine sahip olmalıdır. Mercer teoremini karşıladığı söylenen çekirdekler yarı-kesin artı tanımlıdır, yani çekirdek matrisleri sadece negatif olmayan Eigen değerlerine sahiptir. Kesin artı bir çekirdeğin kullanılması, optimizasyon probleminin dış bükey olmasını ve çözümün benzersiz olmasını sağlar.

Kernel seçimi modellenen probleme bağlıdır. Örneğin bir polinom kerneli, polinom sırasına kadar özellik bağlantılarını modellememizi sağlar. Radyal bazlı fonksiyon (RBF), yalnızca çizgileri seçmeye izin veren doğrusal çekirdeğin aksine daireler veya hiper küreler seçmeye izin verir. Veriler hakkında alınması gereken bilgiye bağlı olarak çok sezgisel ve anlaşılır olabilir. Doğrusal, polinom, gauss, üstel, laplacian, hiperbolik teğet (sigmoid) ve radyal bazlı çekirdek gibi çeşitleri vardır.

RBF çekirdeği sabit bir kerneldir. “Kareli üstel” kernel olarak da bilinir. Bir skaler (kernelin izotropik varyantı) veya girişlerle aynı sayıda boyutta (çekirdeğin anizotropik varyantı) olabilen bir uzunluk ölçeği parametresi ile parametrelendirilir. Üstel (Gauss) çekirdek gibi radyal bazlı fonksiyon (RBF) çekirdekleri, x, y vektörleri arasındaki Öklid mesafesinin işlevidir;

$$K_{RB}(x, y) = k(\|x - y\|_2^2) \quad (5.15)$$

Burada $k: \mathbb{R}_0^+ \rightarrow \mathbb{R}$ çekirdek profildir. Bunun önemli bir örneği olan üstel çekirdek;

$$K_{RB}(x, y) = \exp\left(-\frac{1}{2\sigma^2} \|x - y\|_2^2\right) \quad (5.16)$$

Bu tür çekirdekler, çeviri değişmez çekirdeklerinin belirli bir örneğidir ve şu şekilde yazılabilir;


$$K_{RB}(x, y) = \mathcal{K}_{RB}(\lambda), \quad \lambda = y - x \quad (5.17)$$

$\mathcal{K}_{RB}$ 'ye homojen durumla benzer şekilde çekirdek imzası denir, ancak burada imzanın d boyutlu girişi λ vardır. Ayrıca $\lambda = y - x$, x ve y 'ye logaritmik bağımlılıktan ziyade lineer

bir bağımlılığa sahiptir [60]. RBF çekirdeği sonsuz farklılaşabilir, bu da kovaryans fonksiyonu olarak bu çekirdeğe sahip Gauss süreçlerinin tüm derecelerin ortalama kare türevlerine sahip olduğunu ve bu nedenle çok pürüzsüz olduğunu ima eder. Farklı çekirdekler, farklı x alt kümelerini de kullanıyor olabilir. Bu nedenle, çekirdeklerin birleştirilmesinin, her bir çekirdeğin alanına göre benzerliği ölçtüğü farklı kaynaklardan gelen bilgileri birleştirmenin başka bir yolu olarak görebiliriz [43].

İki çekirdeğin toplamı, birleştirilmiş özellik vektörlerinde bir iç çarpım yapmaya karşılık gelir. Sınıflandırıcıların ortalamasını almaya benzer şekilde bir dizi çekirdeğe genelleme yapılabilir. Bu kez çekirdeklerin ortalaması alınır ve belirli bir çekirdek seçme ihtiyacı ortadan kalkar. Ağırlıklı bir miktar almak ve verilerden ağırlıkları öğrenmek de mümkündür. Buna, tek bir çekirdeği ağırlıklı bir toplamla değiştirdiğimiz çoklu çekirdek öğrenme yöntemi denir.

Örnek olarak, y özelliği ve bir skaler öznitelik z arasında doğrusal olmayan ilişki düşünülürse, $y = \sin(z)$, $(-\pi \leq z \leq \pi)$. 30 örnek için ($N=30$), $y_i = \sin(z_i) + \epsilon_i$, ($i = 1, 2, \dots, n$) modelini kullanarak sentetik veriler oluşturulmuştur. Burada her z_i değerleri $-\pi$ ve π arasında rastgele seçilmiştir ve ϵ_i değerlerine, sıfır ortalama ve varyans $\sigma^2 = 0.01$ ile Gauss dağılımı uygulanmıştır [61].



Şekil 5.13 : Kernel bazlı regresyon ve cezalı regresyon gösteren sentetik bir örnek.

Amaç, bilinmeyen $f(\cdot) = \sin(\cdot)$ fonksiyonunu gözlemlenen y_i özelliklerinden tahmin etmek ve her bir numune için kernel fonksiyonları kullanarak z_i ile ilişkilendirmektedir.

Şekil 5.13'te doğrusal kernel, kübik kernel, genişlik parametresi $p=0.1$ ve $p=1$ olan Gauss kerneli kullanılarak elde edilen sonuçların grafikleri gösterilmektedir [61].

Çekirdek işlevleri aşağıdaki üç ana öğrenme ve çıkarım sorununu ele almaktadır [62];

- Veri benzerliği kavramını resmileştirir,
- İlişkili bir çoğaltma Hilbert uzayında verilerin bir temsiliyi sağlar,
- Temsili teoremi ile tahmin için kullanılan fonksiyon sınıfını karakterize eder.

Çekirdek işlevlerinin kullanımı farklı bir veri temsili anlamına gelir, artık bir örnek kendi başına bir öznitelik vektörü olarak tanımlanmaz, ancak diğer örneklerle nasıl benzediği veya diğer örneklerden nasıl farklı olduğu açısından tanımlanır [43]. Bu, mesafe matrisi kullanan çok boyutlu bir ölçekleme ile bir alanda vektörleri kullanan temel bileşenler analizi arasındaki farka benzer.

5.3.10 Transformasyon

Problem hakkında önsel (prior) bilgiler (çeviriler, rotasyonlar, yeniden ölçeklendirme gibi basit geometrik dönüşümler ve çizgi kalınlığı dönüşümleri gibi) girdinin belirli dönüşümlerinin sınıf etiketini değiştirmedikçe belirtir. Yeterli veri alındığında, doğru girdi-çıkı eşlemesini öğrenmek mümkün olmalıdır, ancak gerekli eğitim verisi miktarını azaltmak için bu değişmezliklerden yararlanmaya çalışmak gerekir. Scikit – learn kütüphanesinde kullanılan dönüşüm örneklerine Çizelge 5.1’de yer verilmiştir.

Problemde kullanılan veriler doğru biçimde olmayabilir veya daha kullanışlı olması için dönüşümler gerektirebilir. Verileri dönüştürme faaliyetlerinde; kategorik kodlama, ölçekleme, sapmayı azaltma, çarpık verileri düzenleme, güç transformasyon fonksiyonları gibi teknikler kullanılır. Scikit-learn verileri temizleyen, azaltabilen, genişletebilen veya özellik temsili oluşturan bir transformatör kütüphanesi içerir. Bunlar fit yöntemine sahip sınıflarla temsil edilir. Bu yöntemlerde, bir eğitim setinden model parametrelerini (örn. normalizasyon için ortalama ve standart sapma) öğrenilir ve bu dönüşüm modeli görülmeyen verilere uygulanır.

Buna ek olarak, ‘fit_transform’ kodu ile kullanılan yöntem eğitim verilerinin aynı anda modellenmesi ve dönüştürülmesi için daha uygun ve verimli olabilir. Scikit-learn kütüphanesi için tahmin hedefini (y) dönüştürmek, hedef alanın dönüşümlerini dikkate alır (örneğin, kategorik etiketler).

Normallik birçok istatistiksel teknik için önemli bir varsayımdır. Güç dönüşümleri, varyansı stabilize etmek ve çarpıklığı en aza indirmek için herhangi bir dağıtımdan

Gauss dağılımına mümkün olduğunca yakın verileri eşleştirmeyi amaçlayan parametrik, monotonik dönüşüm ailesidir [63].

Güç transformasyonlarında çok sık kullanılan yöntemler Yeo-Johnson dönüşümü ve Box-Cox dönüşümüdür. Box-Cox dönüşümü, normal olmayan bağımlı değişkenleri normal bir şekle dönüştürmenin bir yoludur. Box Cox dönüşümünün özünde, -5 ile 5 arasında değişen bir üs (λ) bulunur. Tüm λ değerleri dikkate alınır ve verileriniz için en uygun değer seçilir. Optimal değer, normal dağılım eğrisinin en iyi şekilde tahmin edilmesi ile sonuçlanan değerdir (Şekil 5.14). Dönüşüm fonksiyonları şu şekildedir;

$$x_i^{(\lambda)} = \begin{cases} [(x_i + 1)^\lambda - 1]/\lambda & \text{if } \lambda \neq 0, x_i \geq 0, \\ \ln(x_i + 1) & \text{if } \lambda = 0, x_i \geq 0 \\ -[(-x_i + 1)^{2-\lambda} - 1]/(2 - \lambda) & \text{if } \lambda \neq 2, x_i < 0, \\ -\ln(-x_i + 1) & \text{if } \lambda = 2, x_i < 0 \end{cases}$$

Şekil 5.14 : Yeo-Johnson dönüşümünün matematiksel gösterimi [63].

$$x_i^{(\lambda)} = \begin{cases} \frac{x_i^\lambda - 1}{\lambda} & \text{if } \lambda \neq 0, \\ \ln(x_i) & \text{if } \lambda = 0, \end{cases}$$

Şekil 5.15 : Box-Cox dönüşümünün matematiksel gösterimi [63].

Box-Cox sadece kesinlikle olumlu verilere uygulanabilir. Yeo-Johnson ise hem olumlu hem olumsuz veriler ile kullanılabilir (Şekil 5.15). Her iki yöntemde de dönüşüm, maksimum olasılık tahmini ile belirlenir. Varsayılan olarak, dönüştürülen verilere sıfır ortalama, birim varyans normalizasyonu uygulanır.

Çizelge 5.1 : Scikit-learn kütüphanesinde kullanılan transfromasyon teknikleri.

	PowerTransformer	QuantileTransform	MinMaxScaler
Yöntem	Verileri Gauss benzeri yapmak	Nicelik bilgilerini kullanmak	Her bir özelliği belirli bir aralığa göre ölçeklemek
Kullanılma Nedeni	Bu, sabit olmayan varyans veya normalliğin istendiği durumlar ile ilgili sorunları modellemek için yararlıdır.	Bu dönüşüm, belirli bir özellik için en sık değerleri yayma eğilimindedir. Aynı zamanda (marjinal) aykırı değerlerin etkisini azaltır.	Bu dönüşüm genellikle sıfır ortalama, birim varyans ölçeklendirmesine alternatif olarak kullanılır.
	StandardScaler	RobustScaler	FunctionTransformer
Yöntem	Ortalamayı kaldırmak ve birim varyansına ölçeklendirmek	Aykırı değerlere kaba istatistikler kullanmak	Gerektiğinde çağrılabilir bir transformatör oluşturmak
Kullanılma Nedeni	Bir veri kümesinin standardizasyonu birçok makine öğrenimi tahmincisi için ortak bir gerekliliktir. Eğer bireysel özellikler az çok standart normal olarak dağıtılmış verilere benzemiyorsa kötü davranabilirler.	Bu ölçekleyici medyanı kaldırır ve verileri yüzdelik dağılıma göre ölçeklendirir.	Bir FunctionTransformer, x veya y argümanlarını kullanıcı tanımlı bir fonksiyona veya fonksiyon nesnesine iletir ve bu fonksiyonun sonucunu döndürür.
	Normalizer	Binarizer	BernoulliRBM
Yöntem	Örnekleri birim normlara göre ayrı ayrı normalleştirmek	Bir eşik değerine göre verileri ikili hale getirmek (özellik değerlerini 0 veya 1 olarak ayarlamak)	Belirli bir grafik modeli kullanarak verilerin olasılığını en üst düzeye çıkarmaya çalışır.
Kullanılma Nedeni	Girdileri birim normlarına göre ölçeklendirme, metin sınıflandırması veya kümelemesi için yaygın bir işlemdir.	Boolean rastgele değişkenlerini dikkate alan tahmin ediciler için bir ön işleme adımı olarak da kullanılabilir.	Kullanılan parametre öğrenme algoritması (Stokastik Maksimum Olabilirlik) gösterimlerin girdi verilerinden uzaklaşmasını önler.



6. MAKİNE ÖĞRENMESİ İLE KABA AĞ YAPISI ÜZERİNDEN TAHMİN


Tezin çalışma konusu, makine öğrenmesi yöntemini kullanarak kaba ağ yapılı model üzerinden ince ağ yapısı ile elde edilen referans gerilme değerinin bulunmasıdır. Önceki bölümlerde bahsedilen yöntemlerin seçilen probleme uygulanacaktır. Uygulanan çalışma dört aşamadan oluşmaktadır.

İlk olarak belirlenen model parametreleri belirlenecek ve gerekli verileri üretmek için seçilen simülasyon programı Ansys paketi ile Python programlama dili birlikte kullanılacaktır. İlk aşamadan elde edilen veriler python ile filtrelenecek ve her bir veri kümesinin filtrelenmiş hali kaydedilecektir. Bu filtreleme işlemi makine öğrenmesi yönteminde uygun parametreleri ve düzgün bir dağılımı sağlamak amacıyla yapılmaktadır.

Bir sonraki aşamada, makine öğrenmesi için kullanılacak parametreler dosyalardan çağırılıp işlenmeye uygun olacak şekilde bir dosyaya kaydedilecektir. Son olarak, nihai makine öğrenmesi verilerini içerek dosya üzerinden regresyon yapıp girdi parametreleri ile çıktı parametresi olan ince ağ yapısı gerilme değeri tahmin edilecektir. Bu adımda alınacak hata oranının küçük olması istenmektedir.

6.1 Modelin Oluşturulması ve Veri Üretimi

Bir yapının yeterli yorulma ömrüne, imalat ve işletme ömrü boyunca verimli denetim programlarına sahip olması gerekir. Yorulma analizlerinde kaynaklı yapılar genellikle ince plakalardan oluşur, bu nedenle bu çalışmada kabuk modelleri kullanılmıştır. Gemi yapılarında enine stifner bağlantıları veya T birleşim noktaları gibi çeşitli kaynaklı bölgelerde gerilme yığılmaları meydana gelir. Bu bölgelerden klas kuruluşları da incelendiğinde çok sık karşılaşılan bir problem olan, T şeklinde iki plakanın birleşiminden oluşan yapısal bir modelin gerilme yığılmaları bu çalışma kapsamında incelenmiştir ve kaynak yapılan alanda bir gerilme yığılması ortaya çıkar (Şekil 6.1).



Şekil 6.1 : Gövde stifneri [22].

Kaynak hattı boyunca her iki plakadaki gerilme alanında bir tekillik ortaya çıkar. Kaynaklı birçok yapı için (gemi gövdeleri, kargo vinçleri ve kamyon şasileri gibi) yorulmaya karşı boyutlandırma önemlidir.

Yapıyı parametrik Ansys modeli şeklinde hazırlamış olup, oluşturulan bağımlı ve bağımsız parametreler ile birçok değişken durumun incelenmesi sağlanmıştır. Her parametre setinde yük durumları, plaka kalınlıkları, boyutları, birbirine oranları, ağ boyutları değişkendir (Çizelge 6.1). Bu bağımsız parametreler akıllı ve verimli örnekleme tekniklerinden olan LHS kullanılarak rastgele oluşturulmuştur.

Benchmark fonksiyon üreticinde kullanılan LHS genellikle Monte Carlo simülasyonlarını çalıştırırken bilgisayar işlem süresinden tasarruf etmek için kullanılır. Rastgele değişken alanı her bir şeridin yalnızca bir kez örneklendiği şeritler halinde bölmeye denir. Bu prosedür örnekleme alanının seyrek fakat homojen bir örtüsünü garanti eder. Çalışmalar, iyi performans gösteren bir LHS'nin işlem süresini yüzde 50'ye kadar azaltabileceğini göstermiştir [64].

Çizelge 6.1 : Modelde kullanılan bağımsız parametreler.

Rastgele değişen bağımsız parametreler	Değişim aralığı
t1 : Taban plaka kalınlığı	10 - 40 mm
t2 : Üst plaka kalınlığı	10 - 40 mm
x1 : Taban plaka genişliği	1 - 4 m
asp1 : Taban plaka en-boy oranı	1,2 - 2
asp2 : Üst plaka en-boy oranı	1,2 - 2
msize : ağ boyutu için rastgele değerler	0 - 1
fx : x yönündeki kuvvet	6.00E+02 - 6.00e+04 N
fy : y yönündeki kuvvet	6.00E+02 - 6.00e+04 N
fz : z yönündeki kuvvet	6.00E+02 - 6.00e+04 N

Çizelge 6.2 : Parametrelerin kullanımına bir örnek.

ID	t1	t2	x1	asp1	asp2	msize	fx	fy	fz
1	0.0267	0.0104	0.4874	2.017	1.363	0.0483	3.28E+05	6.48E+05	1.23E+05
2	0.0288	0.0187	0.8146	1.865	1.788	0.8893	3.31E+05	8.44E+05	2.03E+05
3	0.0116	0.0487	0.2529	2.097	1.608	0.8365	5.67E+05	1.05E+05	4.81E+05
4	0.0537	0.0235	1.0960	1.316	1.737	0.1695	2.78E+05	8.73E+05	9.01E+05
5	0.0468	0.0402	1.0269	1.926	1.537	0.3116	7.45E+05	2.29E+05	5.44E+05
6	0.0222	0.0330	0.6009	1.730	1.928	0.8205	6.65E+05	8.13E+05	5.50E+05
7	0.0223	0.0305	0.8024	1.624	1.397	0.6329	6.73E+05	6.57E+05	9.44E+05
8	0.0138	0.0456	0.8318	1.257	1.555	0.8454	3.56E+05	6.72E+05	6.01E+05
9	0.0304	0.0446	0.6435	1.303	1.522	0.0773	1.47E+05	4.11E+05	6.55E+05
10	0.0338	0.0184	0.9617	1.883	1.495	0.9812	2.09E+05	5.04E+05	4.80E+05


Çizelge 6.2’de görüldüğü üzere ID numarası verilen her bir parametre seti kendi içinde değişmektedir ve bu parametreler 200 ve 2000 adet model üretmek için kullanılmıştır. Bağımsız parametrelerin değişim aralıkları mümkün olabilecek her koşulu simüle edebilmek için gemi inşaatı sektörü göz önünde bulundurularak seçilmiştir. Örneğin; f_x, f_y, f_z kuvvetlerine göre elde edilen Von Mises gerilme değerleri 2,8 MPa ile 280 MPa arasına yayılmıştır. Von Mises eşdeğer gerinim aralığı, kesme gerilmesi durumlarının ortalama bir ölçüsü olan ve hasar parametrelerini temsil etmesi gereken bozulma enerjisine dayanmaktadır. Bu dağılımın fazla olması (100 kat) toplanacak verilerin çeşitliliği açısından önemlidir.

Bağımlı parametreler genel olarak alt plaka kısa kenar uzunluğu ve rastgele değişen en-boy oranlarına göre değişmektedir (Çizelge 6.3). Plaka uzunlukları içerisinde düzgün veri oluşturacak kadar nokta bulunabilmesi için tabloda belirtildiği üzere modellenmiştir. Yani kaba ağ yapısına sahip modelde de olabildiğince düğüm noktası barındırmak amaçlardan biridir.


Çizelge 6.3 : Modelde kullanılan bağımlı parametreler.

Bağımlı parametreler	Bağımlı olduğu parametreler
z1 : Taban plaka uzunluğu	$x1 / asp1$
y1 : Taban plaka yüksekliği	t1
x2 : Üst plaka genişliği	$x1 - (x1*0,2)$
y2 : Üst plaka yüksekliği	$x1 / asp2$
z2 : Üst plaka derinliği	t2
e1 : x yönündeki kenar mesafesi	$x1 * 0,10$
e2 : z yönündeki kenar mesafesi	$(z1 - z2) / 2$
mesh : iki durum için değişen ağ boyutu	• ince ağ yapılı durum için : mesh = t1, eğer $t1 < t2$ mesh = t2, eğer $t2 < t1$ • kaba ağ yapılı durum için : mesh = $(3*t2*msize) + (2*t2)$, eğer $t1 < t2$ mesh = $(3*t1*msize) + (2*t1)$, eğer $t2 < t1$



Kenar mesafeleri (e1 ve e2) klas kuruluşlarında belirtildiği gibi 10 mm'den küçük olmayacak ve model şeklini koruyacak ölçüde alt plaka kısa kenarının %10'u kadar belirlenmiştir. Hesabı verilen ağ parametresi ise 0-1 aralığında değişen rastgele sayılardır, kaba ağ yapısı durumlarında $3t - 5t$ arasında boyutlandırılması ve rastgele dağılımı korumak adına tabloda görüldüğü gibi formülize edilmiştir. Yukarıdaki bağımlı ve bağımsız parametreler kullanılarak Ansys scripti hazırlanmış ve programda çizimi yapılmıştır (Şekil 6.2). Yapı dört tarafından da tutulmuştur, boşta bir kenarı yoktur (Şekil 6.3). Yani x,y,z yönlerinde yer değiştirme kısıtlamaları vardır. Uygulanan kuvvetler ise, üstteki plakanın ortasında mpc_gen fonksiyonu kullanılarak ana düğüm noktası oluşturulmuş ve onun üzerinden diğer noktalara iletilmiştir. Mpc, düğüm kuvvetlerini bulmak için kullanılan çok noktalı kısıtlama elemanlarını temsil eder.




Şekil 6.2 : Ansys modeli.




Şekil 6.3 : Modelin yükleme durumları ve sınır koşulları.



Şekil 6.4 : Aynı parametre seti için kaba ağ (üst) ve ince ağ (alt) yapıları örneği.





Şekil 6.5 : İnce ağ yapısı detaylı görünüm.



Şekil 6.6 : Kaba ağ yapısı detaylı görünüm.


Ağ yapıları arasındaki fark Şekil 6.4'te gösterilmektedir, ve anlaşılacağı gibi ince ağ yapısı uygulanan modelde vakit kaybı ve bilgisayarda kapladığı alan da aynı oranda artmaktadır. Her ne kadar süreci hızlandırmak için parametrik model kullanıp Python programıyla senkronize çalışılsa da hassas ağ yapısına sahip modellerin analizleri uzun sürmektedir. Detaylı ağ yapılarının belirtildiği şekillerden de (Şekil 6.5, Şekil 6.6) aynı alana düşen düğüm noktası sayısı görülebilmektedir. Yapıda kullanılan ağ olabildiğince düzgün dağıtılmış ve üçgen eleman kullanımından kaçınılmıştır.



Şekil 6.7 : Aynı parametre seti için ince ağ (üst) ve kaba ağ (alt) yapıları Von Mises gerilmesi kontur gösterimi.

Gerilme yığılmalarının modelde çoğu zaman üst plakanın alt plakayla bağlandığı başlangıç noktasında olduğu gözlemlenmektedir. Bu da sıcak nokta analizi için yapılacak 0.5t ve 1.5t uzaklıktaki gerilmelerden ekstrapolasyon ile bir gerilme değeri kullanma tekniğinin nereden uygulanacağını göstermektedir. Şekil 6.7'de kaba ağ yapısı ile ince ağ yapısı arasındaki sonuçların farklılığı da gözlenmektedir, referans model için Von Mises değeri 206 Mpa iken, aynı model kaba bir ağ ile örüldüğünde 149 Mpa dır. Bu model için düşünülürse bağıl hata oranı %27.66 çıkmaktadır. Toplanan her bir veriden elde edilen bilgiler ışığında tahmin edilecek modelde bu hata azaltılacaktır.

İncelenen ağ boyutu durumları için 200 ve 2000 veri kümesi oluşturulmuştur. Her bir veri setinin kimlik numarası vardır ve kimlik numarası değiştikçe ağ boyutu, yükleme koşulları, model boyutu, oranı ve kalınlığı değişmektedir (Şekil 6.8).



Şekil 6.8 : Her parametre setinde değişen model tipleri için birkaç örnek.

Python kullanılarak çalıştırılan sistemde, yazılan kod Ansys ile entegre biçimde işlemektedir. 200 ve 2000 veri kümesi için ayrı ayrı gerilmeler hesaplanmış ve çıktı dosyalarında her bir düğüm noktasının konumu, üzerindeki normal, kayma, Von Mises ve ekstrapole edilmiş gerilme değerleri bulunur. Tablo olarak gösterimi (Şekil 6.9);

Node N.	x	y	z	σ_1	σ_2	σ_3	τ_{12}	τ_{23}	τ_{13}	σ_{eqv}	σ_{extrp}
1	0.12488000	0.00000000	0.34908034	26193399.	-50709053.	26588803.	-9633527.5	-0.202791 E-08	16504798.	83905844.	44919443.
2	1.1239200	0.00000000	0.34908034	-20532682.	-67711655.	-10485326.	13617298.	0.23450515 E-09	-16493156.	64600261.	0.00000000
3	0.14304436	0.00000000	0.34908034	9186475.4	-0.1046292 E+09	23205011.	-13881659.	-0.1609458 E-08	15721016.	0.12675020 E+09	0.00000000
4	0.16120873	0.00000000	0.34908034	-11092403.	-0.1379521 E+09	20507114.	-9385707.7	-0.1021525 E-08	13700227.	0.14808130 E+09	0.00000000
5	0.17937309	0.00000000	0.34908034	-27175444.	-0.1590849 E+09	16989737.	-5832629.1	-0.7724556 E-09	11593421.	0.16025537 E+09	0.00000000
6	0.19753745	0.00000000	0.34908034	-37224384.	-0.1715733 E+09	13974405.	-4034238.4	-0.6088611 E-09	10014426.	0.16703087 E+09	0.00000000
7	0.21570182	0.00000000	0.34908034	-43580046.	-0.1790775 E+09	11559301.	-3026002.7	-0.4948041 E-09	8749814.6	0.17066990 E+09	0.00000000
8	0.23386618	0.00000000	0.34908034	-47683486.	-0.1838335 E+09	9721120.6	-2358525.0	-0.4122942 E-09	7666574.3	0.17274439 E+09	0.00000000
9	0.25203055	0.00000000	0.34908034	-50451165.	-0.1868744 E+09	8336381.1	-1920374.3	-0.3516412 E-09	6713618.7	0.17387837 E+09	0.00000000
10	0.27019491	0.00000000	0.34908034	-52322991.	-0.1888854 E+09	7306849.3	-1576770.4	-0.3073456 E-09	5880109.5	0.17452613 E+09	0.00000000

Şekil 6.9 : Ansys çıktı dosyası değerleri.

Ansys programında ayrı ayrı listelenen koordinat bilgileri (Şekil 6.10) ve gerilme değerleri (Şekil 6.11) aşağıdaki ansys script komutlarını kullanarak bir array oluşturup Şekil 6.9'da verilen formata dönüştürülür.

```
*GET,n_count,NODE,,COUNT,,,,
*DIM,nr,array,n_count-1,11,1, , ,
*VGET,nr(1,1),NODE,,LOC,X,,,
*VGET,nr(1,2),NODE,,LOC,Y,,,
*VGET,nr(1,3),NODE,,LOC,Z,,,
*VGET,nr(1,4),NODE,,S,X,,,
*VGET,nr(1,5),NODE,,S,Y,,,
*VGET,nr(1,6),NODE,,S,Z,,,
*VGET,nr(1,7),NODE,,S,XY,,,
*VGET,nr(1,8),NODE,,S,YZ,,,
*VGET,nr(1,9),NODE,,S,XZ,,,
*VGET,nr(1,10),NODE,,S,EQV,,,
*SET,nr(1,11),extrp
*MWRITE,nr(1,1),%id%,dat,,
(11G16.8)
```

Burada %id% her bir parametre setini ait olduğu kimlik numarasına göre kaydetmeyi sağlamaktadır. n_count parametresi ise her dosya için düğüm sayısını belirtiyor ve satır sayısı buna eşit olmaktadır. Bu kod ile her bir noktadan çağırılan değer text dosyasına Şekil 6.9'da verilen sütunlar halinde yazılıyor. Satırlar node numarası sütunlar ise gerilme değerleri ve koordiantlardan oluşuyor. Bu dosya tipinden her bir kimlik numarasına sahip parametre seti için bir adet dosya oluşturuluyor. Bu işlemler sırasında Ansys programını manuel çalıştırmaya hiç gerek görülmemiştir. İşlemler Python programlama dili kullanılarak ansys scripti ve parametre dosyası ile Ansys arayüzünde otomatik olarak gerçekleştirilmiştir.

NODE	S1	S2	S3	SINT	SEQU
33670	0.0000	-0.88521E+008	-0.56152E+009	0.56152E+009	0.52291E+009
33670	0.57211E+009	0.70345E+008	0.0000	0.57211E+009	0.54038E+009
33671	0.0000	-0.81417E+008	-0.55913E+009	0.55913E+009	0.52319E+009
33671	0.56208E+009	0.63041E+008	0.0000	0.56208E+009	0.53336E+009
33672	0.0000	-0.74437E+008	-0.55625E+009	0.55625E+009	0.52302E+009
33672	0.55267E+009	0.57617E+008	0.0000	0.55267E+009	0.52623E+009
33673	0.0000	-0.67911E+008	-0.55300E+009	0.55300E+009	0.52236E+009
33673	0.54388E+009	0.53488E+008	0.0000	0.54388E+009	0.51921E+009
33674	0.0000	-0.62089E+008	-0.54909E+009	0.54909E+009	0.52083E+009
33674	0.53609E+009	0.50128E+008	0.0000	0.53609E+009	0.51286E+009
33675	0.0000	-0.57042E+008	-0.54476E+009	0.54476E+009	0.51859E+009
33675	0.52912E+009	0.47212E+008	0.0000	0.52912E+009	0.50717E+009
33676	0.0000	-0.52647E+008	-0.54012E+009	0.54012E+009	0.51582E+009
33676	0.52287E+009	0.44666E+008	0.0000	0.52287E+009	0.50203E+009
33677	0.0000	-0.48871E+008	-0.53532E+009	0.53532E+009	0.51263E+009
33677	0.51720E+009	0.42354E+008	0.0000	0.51720E+009	0.49738E+009
33678	0.0000	-0.45585E+008	-0.53044E+009	0.53044E+009	0.50918E+009
33678	0.51198E+009	0.40276E+008	0.0000	0.51198E+009	0.49308E+009
33679	0.0000	-0.42736E+008	-0.52556E+009	0.52556E+009	0.50555E+009
33679	0.50712E+009	0.38371E+008	0.0000	0.50712E+009	0.48907E+009
33680	0.0000	-0.40237E+008	-0.52072E+009	0.52072E+009	0.50182E+009
33680	0.50254E+009	0.36639E+008	0.0000	0.50254E+009	0.48526E+009
33681	0.0000	-0.38042E+008	-0.51595E+009	0.51595E+009	0.49802E+009
33681	0.49818E+009	0.35049E+008	0.0000	0.49818E+009	0.48161E+009
33682	0.0000	-0.36095E+008	-0.51127E+009	0.51127E+009	0.49421E+009
33682	0.49400E+009	0.33593E+008	0.0000	0.49400E+009	0.47808E+009
33683	0.0000	-0.34363E+008	-0.50667E+009	0.50667E+009	0.49040E+009
33683	0.48996E+009	0.32253E+008	0.0000	0.48996E+009	0.47465E+009
33684	0.0000	-0.32809E+008	-0.50218E+009	0.50218E+009	0.48660E+009
33684	0.48604E+009	0.31020E+008	0.0000	0.48604E+009	0.47130E+009
33685	0.0000	-0.31410E+008	-0.49778E+009	0.49778E+009	0.48284E+009
33685	0.48222E+009	0.29881E+008	0.0000	0.48222E+009	0.46800E+009
33686	0.0000	-0.30141E+008	-0.49347E+009	0.49347E+009	0.47912E+009
33686	0.47849E+009	0.28827E+008	0.0000	0.47849E+009	0.46475E+009
33687	0.0000	-0.28987E+008	-0.48926E+009	0.48926E+009	0.47543E+009
33687	0.47484E+009	0.27849E+008	0.0000	0.47484E+009	0.46154E+009
33688	0.0000	-0.27930E+008	-0.48513E+009	0.48513E+009	0.47179E+009

Şekil 6.10 : Ansys programında gerilme sonuçlarının listelenmesi.

NODE	X	Y	Z
32361	2.80638810811	2.65781927269	1.05097892037
32362	2.80638810811	2.67234287527	1.05097892037
32363	2.80638810811	2.68686647785	1.05097892037
32364	2.80638810811	2.70139008044	1.05097892037
32365	2.82091956757	0.145236025830E-001	1.05097892037
32366	2.82091956757	0.290472051660E-001	1.05097892037
32367	2.82091956757	0.435708077490E-001	1.05097892037
32368	2.82091956757	0.580944103320E-001	1.05097892037
32369	2.82091956757	0.726180129150E-001	1.05097892037
32370	2.82091956757	0.871416154980E-001	1.05097892037
32371	2.82091956757	0.101665218081	1.05097892037
32372	2.82091956757	0.116188820664	1.05097892037
32373	2.82091956757	0.130712423247	1.05097892037
32374	2.82091956757	0.145236025830	1.05097892037
32375	2.82091956757	0.159759628413	1.05097892037
32376	2.82091956757	0.174283230996	1.05097892037
32377	2.82091956757	0.188806833579	1.05097892037
32378	2.82091956757	0.203330436162	1.05097892037
32379	2.82091956757	0.217854038745	1.05097892037
32380	2.82091956757	0.232377641328	1.05097892037
NODE	X	Y	Z
32381	2.82091956757	0.246901243911	1.05097892037
32382	2.82091956757	0.261424846494	1.05097892037
32383	2.82091956757	0.275948449077	1.05097892037
32384	2.82091956757	0.290472051660	1.05097892037
32385	2.82091956757	0.304995654243	1.05097892037
32386	2.82091956757	0.319519256826	1.05097892037
32387	2.82091956757	0.334042859409	1.05097892037
32388	2.82091956757	0.348566461992	1.05097892037
32389	2.82091956757	0.363090064575	1.05097892037
32390	2.82091956757	0.377613667158	1.05097892037
32391	2.82091956757	0.392137269741	1.05097892037
32392	2.82091956757	0.406660872324	1.05097892037
32393	2.82091956757	0.421184474907	1.05097892037
32394	2.82091956757	0.435708077490	1.05097892037
32395	2.82091956757	0.450231680073	1.05097892037
32396	2.82091956757	0.464755282656	1.05097892037
32397	2.82091956757	0.479278885239	1.05097892037
32398	2.82091956757	0.493802487822	1.05097892037
32399	2.82091956757	0.508326090405	1.05097892037
32400	2.82091956757	0.522849692988	1.05097892037

Şekil 6.11 : Ansys programında düğüm noktalarının koordinatlarının listelenmesi.

6.2 Verilerin İşlenmesi

Makine öğrenmesinde kullanmak üzere seçilen problem ve sonrasında takip edilen adımlar şu şekildedir;

- Problem tanımı, seçilen problemi bir makine öğrenme problemine dönüştürmeyi içerir.
- Hipotez üretimi, model için olası bir iş hipotezi ve potansiyel özellikler yaratma sürecidir.
- Veri Toplama, hipotezi test etmek ve modeli oluşturmak için veri toplamasını gerektirir.
- Veri keşfetme ve temizleme, aykırı değerleri, eksik değerleri kaldırmaya ve verileri gerekli biçime dönüştürmeye yardımcı olur.
- Modelleme, aslında makine öğrenme modellerini oluşturduğunuz yerdir. Model oluşturulduktan sonra uygulaması yapılır.

Veri toplama adımından sonra gelen veri keşfetme ve temizleme adımında Ansys programı ile simülasyonu tamamlanıp çıktı değerleri elde edilen modelin verilerinin

işlenmesi Python programı yardımıyla yapılacaktır. Her bir veri seti için kaydedilen gerilme değerleri ve düğüm konumları üzerinden bir filtreleme işlemi yapılacaktır.

Filtreleme, maksimum Von Mises gerilmesinin olduğu düğüm noktası üzerinden yapılmıştır. Bu düğüm noktasının koordinatları referans değeri olarak belirlenmiştir. Referans noktasına olan uzaklık L2 normuna göre meta parametre olan r yarıçapı uzaklığındaki noktalar seçilerek filtrelenmiştir (Şekil 6.12). Buradaki amaç belirli bir yarıçap uzunluğundaki alandaki değerleri seçerek makul noktalar ile işlem yapmaktır, ayrıca ikinci bir yarıçap ekleyerek çeşitlilik sağlanmıştır. Böylece referans noktasına uzak ve yakın noktaların seçiminin hataya etkisi gözlemlenmiştir.

Gerilme yığılmasının meydana geldiği noktanın alan etkisini gözlemek üzere seçilen parametreler r_1 ve r_2 değerleri, alt plaka kısa kenarının yüzde oranları olacak şekilde formülize edilmiştir. İki yarıçap kullanıldığında daha mantıklı sonuçlar elde edilmiştir, bu yarıçaplardan r_1 değeri x_1 uzunluğunun %20'si kadar alana yayılan noktaların gerilme değerlerini içerirken, r_2 değeri ise x_1 uzunluğunun %40'ı kadar uzağına yayılan noktalarındaki gerilme (r_1 alanının içindeki noktaların çıkarıldığı) değerleridir. İkinci yarıçap belirlenen uzak nokta ile iç yarıçap arasında kalan orta bölgenin gerilmelerini içerir. Şekil 6.12'de görülen kod içinde filtData ve filtData2 isimli denklemler (25. ve 26. Satırlar) bu ifadenin temsildir. Tek bir yarıçap kullanıldığında hata oranı yaklaşık olarak %10-20 arasında artmıştır. Denemeler sonucunda iki yarıçapın kullanılmasına karar verilmiştir.

```
1 # -*- coding: utf-8 -*-  
2 """  
3 Created on Sun Apr  5 16:10:29 2020  
4  
5 @author: Burcün  
6 """  
7 import numpy as np  
8  
9 def dist(p1, p2):  
10     # L2 norm, p1 ve p2 arası mesafe  
11     delta = p1 - p2  
12     return np.linalg.norm(delta)  
13  
14 for filename in range(1,201):  
15     data = np.loadtxt(str(filename)+".dat", unpack=False)  
16     resultindexarray = np.argmax(data, axis=0) # her sütunun maksimum değerinin kaçınıcı satırda olduğu belirten ifade.  
17     maxrow = resultindexarray[9] # max.vonmises değeri.  
18     ref = data[maxrow, :] # max.vonmises değerinin bulunduğu satırdaki tüm değerler.  
19  
20     data2 = np.loadtxt("roughprmt.dat") # başlangıçtaki parametre dosyası  
21     x1 = data2[(filename-1),3]  
22     r1 = x1*0.2 # referans noktası ile filtrelenecek mesafe parametresinin x1'e bağlı ifadesi.  
23     r2 = x1*0.4  
24  
25     filtData = [i for i in data if dist(i[0:3],ref[0:3]) < r1] # referans satırıma uzaklığı r1 kadar olan satırların filtrelenmesi.  
26     filtData2 = [i for i in data if dist(i[0:3],ref[0:3]) > r1 and dist(i[0:3],ref[0:3]) < r2 ] # referans satırıma uzaklığı r2 kadar olan  
    satırların filtrelenmesi.  
27  
28     prmtRow = [data2[(filename-1), :]]*(len(filtData)) # her id numarasına göre parametre değerlerinin olduğu satır  
29     prmtRow2 = [data2[(filename-1), :]]*(len(filtData2))  
30  
31     #outdata = np.concatenate((prmtRow, filtData, filtData2), axis=None)  
32     out = np.savetxt(str(filename)+"filter.dat", np.hstack([prmtRow, filtData]))  
33     out = np.savetxt(str(filename)+"filter2.dat", np.hstack([prmtRow2, filtData2]))
```

Şekil 6.12 : Verilerin filtrelenmesi için kullanılan kod.

Filtrelenmiş çıktılarından makine öğrenmesi girdi verileri olacak parametreler elde edilir. Bunlar; Von Mises gerilmesinin maksimum değeri, standart sapması, ortalaması ve ağ boyutudur.

Makine öğrenmesi için çıktı olarak kullanılacak değer ince ağ yapılı durumdan alınan gerilme değerleridir. Bu gerilme değerleri süreksizliğin başladığı iki köşeden klas kurallarına uygun sıcak nokta analizinde kullanılan ekstrapole edilmiş gerilme değerleridir. Kullanılacak girdiler ise kaba ağ yapılı sonuçlardan elde edilen;

- Ortalama Von Mises gerilme değeri,
- Standart sapma Von Mises gerilme değeri,
- Maksimum Von Mises gerilme değeri,
- Ağ boyutu
- Süreksizliğin başladığı iki köşeden klas kurallarına uygun olarak ekstrapole edilmiş gerilme değerleridir.

Şekil 6.13’de ekran görüntüsü verilen kod ile girdi ve çıktı değerlerin toplanması ve ‘mldata.csv’ isimli dosyaya yazdırılması paylaşılmıştır. Bu dosya 7 sütun her biri yukarıda ifade edilen girdi değerleri ve parametre seti kadar (200 veya 2000) satıra sahiptir.

```
1 # -*- coding: utf-8 -*-
2 """
3 Created on Tue Apr 21 16:47:13 2020
4
5 @author: Burcin
6 """
7
8 import numpy as np
9
10 a = 201
11
12 mldata = np.zeros((a, 7))
13
14 for filename in range(1,a):
15     data = np.loadtxt(str(filename)+".dat", ndmin =2)
16     #data1,data2 rough mesh filtrelenmiş sonuçları içerecek dosyalar.
17     data1 = np.loadtxt(str(filename)+"filter.dat", ndmin =2)
18     data2 = np.loadtxt(str(filename)+"filter2.dat", ndmin =2)
19     #data3 fine mesh sonuçlarını içerecek dosyalar.
20     data3 = np.loadtxt('C:/Users/Burcin/Documents/YüksekLisansTez/Uygulama/finemesh/'+str(filename)+'.dat', ndmin =2)
21
22     mldata[(filename-1), 0] = data1[0,6] #machine learning için her parametre setinin mesh boyutu.
23     mldata[(filename-1), 1] = np.std(data1[:,19]) #r1 filtrelenmiş vonmiseses standart sapması.
24     mldata[(filename-1), 2] = np.mean(data1[:,19]) #r1 parametresi için roughdan gelen vonmiseses ortalaması.
25     mldata[(filename-1), 3] = np.std(data2[:,19]) # r2 parametresine göre değişen von mises standart sapması.
26     mldata[(filename-1), 4] = np.mean(data2[:,19]) # r2 parametresine göre değişen von mises gerilme ortalaması.
27     mldata[(filename-1), 5] = np.max(data[:,10]) #rough meshten gelen ekstreple gerilme değeri.
28     mldata[(filename-1), 6] = np.max(data3[:,10]) #fine meshten gelen ekstreple gerilme değeri.
29
30 output = np.savetxt("mldata.csv", mldata, delimiter=",")
31
32
```

Şekil 6.13 : Makine öğrenmesi için kullanılacak verilerin hazırlandığı kod.

6.3 Algoritma Kullanımı

Yapılan işlemleri adım adım özetleyecek olursak;

1. Aşama : Her bir parametre seti için belirlenen sayıda kaba ve ince ağ yapılı gerilme analizlerini yapmak
2. Aşama : Ansys programından her düğüm noktası için gerilme ve konum bilgileri almak
3. Aşama : Düğüm nokta sonuçlarını meta parametre olan r yarıçaplarına göre filtrelemek
4. Aşama : Filtrelenen sonuçtan makine öğrenmesinde kullanılmak üzere uygun input ve output değerlerini çekmek
5. Aşama : Verileri transformasyonla kullanılabilir hale çevirdikten sonra regresyon analizi yapmak

Algoritma, Python programında Scikit-learn, Numpy, Pandas kütüphaneleri kullanılarak uygulanmıştır. Veriler;

- x değerleri 6 girdi değeri olan;
 - ağ boyutu,
 - $r1$ parametresine göre filtrelenen gerilmelerin standart sapması,
 - $r1$ parametresine göre filtrelenen gerilmelerin ortalaması,
 - $r2$ parametresine göre filtrelenen değerlerin standart sapması,
 - $r2$ parametresine göre filtrelenen değerlerin ortalaması,
 - kaba ağ yapılı model sonuçlarından elde edilen ekstrapole edilmiş gerilme değeri
- y değeri 1 çıktı değeri olarak;
 - ince ağ yapılı model sonuçlarından elde edilen ekstrapole edilmiş gerilme değeri olarak ayrılmıştır.

Makine öğrenmesi tekniklerinden denetimli öğrenme genellenecek olursa bağımsız değişkenlerin (x değerleri) girdi olarak kullanılıp bağımlı değişkenlerin (y değerleri) tahmin edilmesi denebilir. Bu tahmin sürecinde seçilen makine öğrenmesi uygulamasına bağlı olmakla birlikte ne kadar düzgün veri setiyle işlem yapılırsa o kadar uygun sonuçlar elde edilir. Uygulanan problemde her ne kadar birçok olasılığı değerlendirmek için rastgeleliğin korunması istense de girdi oluşturabilecek değerler arasında eleme yapılarak sonuçlara etkisi olan değerler seçilmiştir.

Ayrılan değerleri daha sonra aşağıdaki denklemde görüldüğü gibi %20'si test edilecek değerler olmak üzere sınıflandırılmıştır. Bu değerlerin çok fazla olmaması makinenin öğrenmesi açısından daha sağlıklıdır.

$$x_{train}, x_{test}, y_{train}, y_{test} = \text{train_test_split}(x, y, \text{test_size} = 0.2, \text{random_state} = 0) \quad (6.1)$$

Veriler eğitim ve test verileri olarak ayrıldıktan sonra seçilen kernel fonksiyonu tanımlanmıştır. Kernel fonksiyonları kişinin seçimine bağlıdır ve bu problemde Gauss süreci regresyon uygulanacağı için radyal bazlı kernel (RBF) fonksiyonu tercih edilmiştir. Diğer kernel fonksiyonları da denenmiş olup çoklu kernel yerine tek bir çekirdek kullanmak tercih edilmiştir.

$$\text{kernel} = \text{gp.kernels.RBF}(10.0, (1e - 3, 1e + 3)) \quad (6.2)$$

Bu denklemde kullanılan, fonksiyonların düzgünlüğünü kodlayan, uzaydaki girdilerin benzerliğinin çıktılarının benzerliğine karşılık geldiği radyal bazlı işlev (RBF) çekirdeğidir. Bu çekirdeğin iki parametresi sırasıyla, uzunluk ölçeği (l) ve bu ölçekte alt ve üst sınır. Bu sınırlar sabit olarak ayarlanırsa hiper parametre ayarı sırasında uzunluk ölçeği değiştirilemez. Eğer veri tipi float ise izotropik kernel, array ise anizotropik kernel kullanılır.

Kernel işlevi seçildikten sonra, Scikit-learn ile Gauss süreci regresyon modelini atanır;

$$\text{model} = \text{gp.GaussianProcessRegressor}(\text{kernel} = \text{kernel}, n_{\text{restart_optimizer}} = 10, \alpha = 0.9, \text{normalize_y} = \text{True}) \quad (6.3)$$

alpha : Aynı şekilde dağıtılmış (i.i.d) Gauss gürültüsünün varyansı,

n_restarts_optimizer : Log-marjinal olasılığını en üst düzeye çıkaran çekirdeğin parametrelerini bulmak için optimize edicinin yeniden başlatma sayısı,

normalize_y : Sabit ortalama fonksiyonunu belirler (Doğru eğitim verilerini sembolize eder).

Veri kümesinde x değerleri ve y değerleri farklı şekilde ölçeklendirilmiştir. Girdi (input) değerlerine standart skaler dönüşümü, çıktı (output) değerine ise güç dönüşümü uygulanmıştır;

$$scaler = preprocessing.StandardScaler().fit(x_train) \quad (6.4)$$

$$x_train = scaler.transform(x_train) \quad (6.5)$$

$$x_test = scaler.transform(x_test) \quad (6.6)$$

$$pt = PowerTransformer(method = 'yeo - johnson') \quad (6.7)$$

$$y_train2 = pt.fit_transform(y_train.reshape(-1,1)) \quad (6.8)$$

Güç dönüşümlerinden Yeo-Johnson yöntemi diğer yöntemlere kıyasla daha uyumlu veriler ürettiği için seçilmiştir. Modelin oluşturulması şu denklem ile ifade edilir;

$$model.fit(x_train, y_train2) \quad (6.9)$$

Model uyumu sağlandıktan sonra test verilerinde x değerlerine göre y değerleri tahmin edilmiştir. Transformasyon ile dönüştürülen değerler, ters transformasyon ile gerçek boyutuna çekilmiştir.

$$y_pred, std = model.predict(x_test, return_std = True) \quad (6.10)$$

$$y_pred2 = pt.inverse_transform(y_pred.reshape(-1,1)) \quad (6.11)$$

Tahmin değeri y_pred2 verileri ile y_test verileri arasında hata oranına bakılarak modelin uygunluğu yorumlanır.

Tahminlerin kalitesini ölçmek için yine Scikit-learn kütüphanesinde bulunan metrik sistemler modülü baz alınmıştır ve birden fazla yöntem uygulanmıştır (Çizelge 6.4). Bazı metrik sistemler gürültülü veriler nedeniyle yanıltıcı olabiliyor. Birden fazla metrik sistem ile incelenen problemde hatayı değerlendirmek daha kapsamlı hale geliyor.

Çizelge 6.4 : Metrik sistemler.

Metrik İşlev Adı	Formülü
Ortalama kare hata (MSE)	$MSE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2$
Kök ortalama kare hata (RMSE)	$RMSE(y, \hat{y}) = \sqrt{MSE(y, \hat{y})}$
Ortalama kare logaritmik hata (MSELog)	$MSLE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} (\log_e(1 + y_i) - \log_e(1 + \hat{y}_i))^2$
Ortalama mutlak hata (MAE)	$MAE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} y_i - \hat{y}_i $
Medyan mutlak hata (MedAE)	$MedAE(y, \hat{y}) = median(y_1 - \hat{y}_1 , \dots, y_n - \hat{y}_n)$
Maksimum hata (MaxEr)	$MaxEr(y, \hat{y}) = max(y_i - \hat{y}_i)$
Bağımlı varyans değeri (EVS)	$EVS(y, \hat{y}) = 1 - \frac{Var\{y - \hat{y}\}}{Var\{y\}}$
R^2 Skoru	$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n-1} (y_i - \bar{y})^2}$

EVS için mümkün olan en iyi değer 1.0'dır ve düşük değerler daha kötüdür.

Maksium hata, tahmin edilen değer ile gerçek değer arasındaki en kötü durum hatasını yakalayan bir metrik olarak hesaplar. En iyi değer 0'dır.

R^2 hata oranı modeldeki bağımsız değişkenler tarafından açıklanan y'nin varyans oranını temsil eder ve en iyi değer 1.0'dır.

MedAE ise, hedef ve tahmin arasındaki tüm mutlak farklılıkların medyanı alınarak hesaplanır. MAE aynı farklılıkların ortalamasıdır.

MSE kare logaritmik (karesel) hata veya kaybın beklenen değerine karşılık gelen bir risk ölçüsü olan ortalama kare hatasını hesaplar.

7. SONUÇLAR VE TARTIŞMA

Uygulama sonucu elde edilen hata oranları aşağıdaki tabloda ifade edilmiştir. 200 data için yapılan analizlerde yarıçap değiştiğinde hata oranı etkilenmiştir. Minimum hatanın genel olarak görüldüğü yarıçaplar ise $r_1=0.2$ ve $r_2=0.4$ değerleridir (Çizelge 7.1). Bu demek oluyor ki elimizdeki veri setinde maksimum gerilmenin meydana geldiği noktadan bağlı olduğu kenarın uzunluğunun yüzde yirmisi kadar uzaklıkta olan gerilme değerleri ve buna ek olarak aynı uzunluğun yüzde kırkı olan uzak noktalardan alınan değerler en iyi sonucu vermiştir. Hem problem içinde parametrisasyon hem de makine öğrenmesinde farklı araçlar ve parametreler kullanılarak hata sonuçları elde edilmiştir.

Çizelge 7.1 : Değişen yarıçapa göre hata oranları.

RMSE	MSE	MAE	EVS	MaxEr	MSE Log	Med AbEr	r2 Score	Değişen yarıçap
1.45E +08	2.09E +16	8.93E +07	8.82 E-01	4.93E +08	1.10E -01	4.13E +07	0.881 71	$r_1=0.2 /$ $r_2=0.4$
1.49E +08	2.22E +16	9.28E +07	8.75 E-01	4.96E +08	1.16E -01	4.67E +07	0.874 676	$r_1=0.1/r_2$ $=0.3$
1.46E +08	2.12E +16	9.01E +07	8.80 E-01	4.92E +08	1.10E -01	4.23E +07	0.880 028	$r_1=0.2/r_2$ $=0.5$
1.53E +08	2.34E +16	9.50E +07	8.68 E-01	4.95E +08	1.18E -01	4.67E +07	0.867 868	$r_1=0.1/r_2$ $=0.4$
1.61E +08	2.60E +16	9.66E +07	8.54 E-01	4.92E +08	1.10E -01	4.35E +07	0.853 244	$r = 0.2$
1.63E +08	2.66E +16	9.70E +07	8.50 E-01	4.92E +08	1.11E -01	4.26E +07	0.849 732	$r = 0.3$
1.76E +08	3.10E +16	1.05E +08	8.26 E-01	5.33E +08	1.17E -01	4.50E +07	0.824 795	$r = 0.1$


En iyi değerleri veren yarıçaplarla 2000 veri modeli çalıştırılırsa elde edilen sonuçlar Çizelge 7.2’de verilmiştir. Bu çalışma ile seçilen parametrelerin tahminde etkili olduğu gözlenmektedir. Örneğin ağ boyutunu makine öğrenmesi inputlarından çıkarıldığında

kök ortalama kare hata dikkate alınırsa 2 kat artmaktadır, veya her iki model için ekstrapole edilmiş gerilme değerleri yerine maksimum gerilme değerlerine göre hata hesaplandığında yine 1,7 kat artış gözlemlenmektedir. Hesaplanan hata oranları makine öğrenmesi yöntemlerinden Gauss süreci regresyon analizi sonucunda elde edilen değerlerdir. Sonuç olarak, bir regresyon analizi yapılarak hassas ağ modelinin gerilme sonuçları tahmin edilmekte ve böylece büyük ölçekli yapıların tasarımında zaman ve bilgi tasarrufu sağlanmaktadır.

Çizelge 7.2 : Veri sayısı 2000 olan modelin hata sonuçları.


RMSE	MSE	MAE	EVS	MaxE r	MSELo g	MedAbE r	R ²	Kullanılan Yöntem
1.29E+08	1.66E+16	6.42E+07	8.40E-01	1.11E+09	9.02E-01	3.52E+07	0.94	Gauss Süreci Reg.
1.84E+08	3.38E+16	8.51E+07	8.85E-01	1.54E+09	7.91E-01	2.67E+07	0.88	Gradyan Arttırıcı R.
2.07E+08	4.27E+16	9.69E+07	8.53E-01	1.81E+09	7.77E-01	2.92E+07	0.85	Karar Ağacı Reg.
1.94E+08	3.77E+16	1.04E+08	8.68E-01	1.33E+09	8.36E-01	4.01E+07	0.87	Rastgele Orman Reg
4.01E+09	1.61E+19	5.75E+08	5.52E+01	6.80E+10	1.23E+00	6.16E+07	0.65	Ridge Reg.

Farklı regresyon yöntemleri kullanılarak elde edilen hata değerleri 2000 veri seti için Çizelge 7.2’de gösterilmektedir. Kullanılan yöntemlerin R² değerine bakacak olunursa, 1’e en yakın değer Gauss süreci regresyonu ile elde edilmiştir (0.94). Şekil 7.1’de regresyon sonrası hata oranı resmedilmiştir. Mavi noktalar gerçek değeri, sarı noktalar ise tahmin edilen değeri göstermektedir ve tabloya göre uygunluk oranı sağlanmıştır ancak sapmalar da mevcuttur, bunların giderilmesi gerekmektedir. Tahmin edilen değer ve gerçek değerlerin bir referans çizgisi etrafındaki dağılımları ve aynı zamanda her bir parametrenin dağılımı da gösterilmektedir (Şekil 7.6, Şekil 7.7). Tahmin değerleri 150 ve 250 Mpa arasında daha düzgün yayılım gösterirken buralarda gerçek değerler nispeten seyrek. Şekil 7.6’da girdi sırasına göre dizilmiş parametrelerden ağ boyutu beklenildiği üzere düzgün dağılımlı rastgele iken, gerilme değerleri benzer yayılımlar göstermiştir.




Şekil 7.1 : Gauss süreci regresyonu çizimi.

Gauss süreci regresyonu daha sonra her bir parametrenin etkisini ölçmek için tekrar parametreler birer birer çıkarılarak denenmiştir. Bu parametrelerin eklenip çıkarmasıyla kök kare hata değeri (RMSE), ortalama mutlak değer (MAE) ve R^2 hata değerlerinde meydana gelen değişimler Şekil 7.2 ve Şekil 7.3'te gösterilmiştir. Şekillerden edinilecek bilgi; tüm parametrelerin katkı sağladığı regresyon en iyi sonucu verirken, kaba ağ yapısı gerilmelerinin standart sapması RMSE ve MAE hata değerlerini pek etkilememiştir. Bunun yanı sıra kaba ağ yapısının gerilme sonuçları çıkarıldığında tahminde önemli bir düşüş yaşanmaktadır. R^2 hata değeri tablosunda da standart sapmaların çıkarılmasına rağmen aynı değer elde edilmiştir ve onları takiben ilginç bir biçimde ağ boyutunun etkisi de R^2 hata değerinde diğer parametrelere oranla daha azdır. Kullanılan parametreler genel olarak sonuçları iyileştirmiş olup, probleme özgü farklı parametreler de eklenebilir.




Şekil 7.2 : Değişen parametrelere bağlı hata değerleri.




Şekil 7.3 : Değişen parametrelere göre R2 hata değeri.

Parametre setine uygun olarak sonuçların gözlenebileceği oranda veri sayısı belirlendiğinde modelin performansı o sayının artmasıyla her zaman doğru orantılı olmaz. Ancak bu modelde 2000 veri ile daha düşük RMSE değeri elde edilmiştir (Şekil 7.4). Ortalama kare hata değerlerinin yüksek gözükmesinin nedeni kullanılan verilerin boyutunun Mpa cinsinden olmasıdır. Tablodan da anlaşılacağı üzere mantıklı kararların verilmesi için RMSE, MAE ve R^2 hata değerleri dikkate alınacaktır.




Şekil 7.4 : Hata oranları arasındaki fark.



Şekil 7.5 : Ridge regresyonu değişen alfa parametre değeri.


Ridge regresyonu L2 düzenlemesini gerçekleştiren en küçük doğrusal kare yöntemidir. Bu model, kayıp fonksiyonunun doğrusal en küçük kareler fonksiyonu olduğu ve regülasyonun L2 normu tarafından verildiği bir regresyon modelini çözer, objektif fonksiyonunu en aza indirir. Yapılan Ridge regresyonu farklı alfa parametreleri için tekrarlanmıştır. Parametre değerindeki değişim veri sayısının 2000 olduğu set için pek fark yaratmamıştır (Şekil 7.5). Ancak 200 veri içeren sette ise alfa değerini arttırmak modelin tahmin oranını da arttırmıştır. Bu regresyonlar R^2 değeri ile ölçülür, önceki bölümlerde bahsedildiği gibi R^2 değeri 1'e ne kadar yakınsa analiz o kadar iyi

sonuç vermiş demektir. Yapılan örneklerden de görüldüğü üzere Ridge regresyonu bu problem için iyi bir tahmin aracı olmamıştır. Aynı şekilde Gradyan Arttırıcı, Rastgele Orman ve Karar Ağacı regresyon tipleri de Gauss süreci regresyon kadar başarı sağlayamamıştır.




Şekil 7.6 : Parametrelerin dağılım grafikleri.

Parametrelerin dağılımları ortalama ve standart sapma değerleri için benzer olmakla birlikte beklenildiği üzere en düzgün dağılım ağ boyutu rastgele dağıtımında gözlemlenmektedir (Şekil 7.6). Gerçek değerler ve tahmin değerleri arasındaki dağılımda aralıklar fark göstermekte ancak dağılımın şekli benzerlik içermektedir (Şekil 7.7). Modelin tahmin dağılımının gerçeğe yakın olması iyi bir sonuçtur.




Şekil 7.7 : Tahmin ve gerçek gerilme değerlerinin dağılım grafikleri.



Şekil 7.8 : Makine öğrenmesi verilerinin korelasyonu.

Makine öğrenmesinde kullanılan tüm parametrelerin ve y değerinin korelasyonunun görüldüğü şekilde bazı parametreler birbiriyle pozitif korelasyon içindeyken bazıları arasında ilişki bulunmamaktadır (Şekil 7.8). Çıkan sonuçlardan ortalama mutlak hata değerleri de Gauss süreci için daha iyi sonuçlar vermiştir. Şekil 7.9'te histogram dağılımı gösterilen ortalama mutlak hata değerinin farklı regresyon sonuçları belirtilmiştir. Görüldüğü üzere Gauss süreci regresyonu en az değeri vermektedir.



Şekil 7.9 : Farklı regresyon modellerinde ortalama mutlak hata değişimi.

Gerilme yığılması tahmini zor bir problem olup hesaplama ile ilgili model seçimi, model parametreleri ayarı, transformasyon gibi mevcut standart yaklaşımlar denenmiştir. İncelenen problemin nasıl hesaplanması ve alternatifler ile değerlendirilmesi gerektiği gösterilmiştir. Bu çalışmanın devamında, oluşturulan model geliştirecek ve hata oranı azaltılacaktır. Yine Ansys programı yardımıyla iki boyutlu analiz ve üç boyutlu analiz arasında bir geçiş uygulaması hedeflenmektedir.

Bu çalışma İstanbul Teknik Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimince Desteklenmiştir. Proje Numarası: 42166.

KAYNAKLAR


- [1] **S. T. More and R. S. Bindu**, (2015). "Effect of Mesh Size on Finite Element Analysis of Plate Structure," *Int. J. Eng. Sci. Innov. Technol.*, vol. 4, no. 3, pp. 181–185.
- [2] **Y. Li, T. Wierzbicki, M. A. Sutton, J. Yan, and X. Deng**, (2011). "Mixed mode stable tearing of thin sheet Al 6061-T6 specimens: Experimental measurements and finite element simulations using a modified Mohr-Coulomb fracture criterion," *Int. J. Fract.*, vol. 168, no. 1, pp. 53–71.
- [3] **L. Y. Weibing Liu, Mamtimin Geni**, (2011). "Effect of Mesh Size of Finite Element Analysis in Model Analysis for Periodic Symmetric Struts SupportNo Title," *Key Eng. Mater.*, vol. Vols. 462-, no. pp 1008-1012, pp. 462–463.
- [4] **P. Raut**, (2012). "Impact of mesh quality parameters on elements such as beam, shell and 3D solid in structural analysis," *Int. J. Eng. Res. Appl.*, vol. 2, no. 6, pp. 99–103.
- [5] **Y. Liu**, (2013). "Choose the Best Element Size to Yield Accurate FEA Results While Reduce FE Models's Complexity," *Br. J. Eng. Technol.*, vol. Vols. 1 No, pp. 13–28.
- [6] **S. Jamshed**, (2012). *HPC Benchmarks for CFD*.
- [7] **J. S. Millán, I. Armendáriz, J. García-Martínez, and R. González**, (2016). "Strategies for static failure analysis on aerospace structures," *Handb. Mater. Fail. Anal. with Case Stud. from Aerosp. Automot. Ind.*, pp. 3–28.
- [8] **A. Dutt**, (2015). "Effect of Mesh Size on Finite Element Analysis of Beam," *Int. J. Mech. Eng.*, vol. 2, no. 12, pp. 8–10.
- [9] **K.-H. Chang**, (2015). "Structural Analysis," *E-Design*,., K.-H. Chang, Ed., pp. 325–390.
- [10] **S. Nagendra, J. B. Staubach, A. J. Suydam, S. J. Ghunakikar, and V. R. Akula**, (2005). "Optimal rapid multidisciplinary response networks: RAPIDDISK," *Struct. Multidiscip. Optim.*, vol. 29, no. 3, pp. 213–231.
- [11] **B. Wijerathna, T. Vidal-Calleja, S. Kodagoda, Q. Zhang, and J. Valls Miro**, (2013). "Multiple defect interpretation based on Gaussian processes for MFL technology," *Nondestruct. Charact. Compos. Mater. Aerosp. Eng. Civ. Infrastructure, Homel. Secur. 2013*, vol. 8694, no. February 2017, p. 86941Z.
- [12] **K. Kumar, P. K. Biswas, and N. Dhang**, (2019). "Damage diagnosis of steel truss bridges under varying environmental and loading conditions," *Int. J. Acoust. Vib.*, vol. 24, no. 1, pp. 56–67.
- [13] **S. Zajam, T. Joshi, and B. Bhattacharya**, (2019). "Application of wavelet analysis and machine learning on vibration data from gas pipelines for structural health monitoring," *Procedia Struct. Integr.*, vol. 14, pp. 712–719.

- [14] **M. M., Iman & Safa, Maryam & Ibrahim, Zainah & Kisi, Ozgur & Tahir, Mahmood & Baharom, Shahrizan & Azimi,** (2016). "Strength prediction of rotary brace damper using MLR and MARS," pp. 471–488.
- [15] **Z. M. Yaseen et al.,** (2018). "Predicting compressive strength of lightweight foamed concrete using extreme learning machine model," *Adv. Eng. Softw.*, vol. 115, no. April 2017, pp. 112–125.
- [16] **N. T. Trung et al.,** (2019). "Moment-rotation prediction of precast beam-to-column connections using extreme learning machine," *Struct. Eng. Mech.*, vol. 70, no. 5, pp. 639–647.
- [17] **D. K. Choi,** (2019). "Data-Driven Materials Modeling with XGBoost Algorithm and Statistical Inference Analysis for Prediction of Fatigue Strength of Steels," *Int. J. Precis. Eng. Manuf.*, vol. 20, no. 1, pp. 129–138.
- [18] **A. Thirumalaiselvi, M. Verma, N. Anandavalli, and J. Rajasankar,** (2018). "Response prediction of laced steel-concrete composite beams using machine learning algorithms," *Struct. Eng. Mech.*, vol. 66, no. 3, pp. 399–409.
- [19] **M. Manngård, J. Kronqvist, and J. M. Böling,** (2018). "Structural learning in artificial neural networks using sparse optimization," *Neurocomputing*, vol. 272, pp. 660–667.
- [20] **H. Cui, O. Turan, and P. Sayer,** (2012). "Learning-based ship design optimization approach," *CAD Comput. Aided Des.*, vol. 44, no. 3, pp. 186–195.
- [21] **X. Liu, Q. Wang, R. Huang, S. Wang, and X. Liu,** (2019). "A prediction method for deck-motion based on online least square support vector machine and genetic algorithm," *J. Mar. Sci. Technol.*, vol. 24, no. 2, pp. 382–397.
- [22] **DNV-GL,** (2014). "Fatigue Analysis of Offshore Steel Structure."
- [23] **N. Kyokai,** (2000). "Rules for the survey and construction of steel ships chapter 1," vol. 1, no. 1, pp. 1–39.
- [24] **Bureau Veritas,** (2016). "Rules for the Classification of Offshore Units PART A - Classification and Surveys (NR 455.A1 DT R05 E)," vol. 33, no. 445.
- [25] **H. Sönerlind,** (2015). "Singularities in Finite Element Models: Dealing with Red Spots," [Online]. Available: <https://www.comsol.com/blogs/singularities-in-finite-element-models-dealing-with-red-spots/>.
- [26] **R. G. Tarihi and R. G. Say,** (2014). "Resmi Gazete Tarihi: 13.04.2013 Resmi Gazete Sayısı: 28617," no. 1.
- [27] **DNVGL,** (2015). "DNVGL-CG-0129: Fatigue Assessment of Ship Structures," no. October, pp. 1–129.
- [28] **N. Stojkovic, D. Stojic, S. Zivkovic, and G. Toplicic-Curcic,** (2018). "Algorithm for determination of S-N curves of the structural elements subjected to cyclic loading," *Facta Univ. - Ser. Archit. Civ. Eng.*, vol. 16, no. 1, pp. 81–91.
- [29] **W. D. Pilkey and D. F. Pilkey,** (2008). *Shoulder Fillets*.
- [30] **BUREAU VERITAS - NR 515 DTM R00 E,** (2004). "Fatigue of longitudinal connections under shear mode," vol. 33, no. 515.

- [31] **T. Ltd**, (2001). "HOT-SPOT STRESS S-N CURVES FOR FPSO FATIGUE ASSESSMENT." [Online]. Available: <https://www.twi-global.com/technical-knowledge/published-papers/recommended-hot-spot-stress-design-s-n-curves-for-fatigue-assessment-of-fpsos-june-2001>.
- [32] **N. K. Kyokai**, (1999). "Technical Guide Regarding the Strength Evaluation of Hull Structures," no. December.
- [33] **DNVGL**, (2016). "DNVGL-CG-0128 Buckling," no. October 2015, pp. 1–131.
- [34] **DNVGL**, (2015). "DNVGL-CG-0127 Finite element analysis," no. October, p. 93.
- [35] **F. & Associates**, "Finite Element Analysis (FEA)." [Online]. Available: <https://www.fernandes.net.au/services/finite-element-analysis-fea/>.
- [36] **BV**, (2016). "Guidelines for Fatigue Assessment of Steel Ships and Offshore Units Guidance Note," vol. 33, no. September, pp. 1–172.
- [37] **Bureau Veritas Marine & Offshore Division**, (2014). "Rules for the Classification of Steel Ships. Part B - Hull and Stability. Chapters 5-6-7," vol. 33, no. 469, pp. 1–138.
- [38] **DNVGL**, (2015). "OFFSHORE STANDARD DNVGL-OS-C102-Edition July 2015, Structural design of offshore ships," no. July.
- [39] **DNVGL**, (2018). "Rules for Classification of Ships, Part 3 - Hull, Chapter 7 - Finite element analysis," no. July.
- [40] **J. Yang, K. Y. Li, and S. P. Zhang**, (2006). "The non-invasive 3-D temperature image reconstruction of organism by ANSYS," *Proc. 2006 Int. Conf. Mach. Learn. Cybern.*, vol. 2006, no. August, pp. 4268–4272.
- [41] **A. Tools**, (2008). "Parametric Design Analysis for Evaluating a Range of Variables Geometric Parameters: A Key to.", By Pierre Thieffry, Product Manager, ANSYS, Inc.
- [42] **S. L. Brunton, B. R. Noack, and P. Koumoutsakos**, (2020). "Machine Learning for Fluid Mechanics," *Annu. Rev. Fluid Mech.*, vol. 52, no. 1, pp. 477–508.
- [43] **E. Alpaydin**, (2010). *Introduction to Machine Learning*, 2nd ed. MIT Press, 2010.
- [44] **E. Mohammed, Mohssen & Khan, Muhammad & Bashier**, (2016). *Machine Learning: Algorithms and Applications*.
- [45] **J. Hastie, T.; Tibshirani, R. & Friedman**, (2001). *The Elements of Statistical Learning*. New York, USA.
- [46] **D. Soni**, (2018). "Supervised vs. Unsupervised Learning," [Online]. Available: <https://towardsdatascience.com/supervised-vs-unsupervised-learning-14f68e32ea8d>.
- [47] **P. Grohs, D. Perekrestenko, D. Elbrächter, and H. Bölcskei**, (2019). "Deep Neural Network Approximation Theory".
- [48] **C. E. Rasmussen and C. K. I. Williams**, (2006). *Gaussian processes for machine learning*. 2006, vol. 38, no. 2.
- [49] **A. G. Richard, S. Sutton and Barto**, (2006). *Reinforcement Learning: An Introduction*, Second ed. Massachusetts, London, England: The MIT Press Cambridge, 2006.

- [50] **S. Ray**, (2015). "7 Regression Techniques you should know," [Online]. Available: <https://www.analyticsvidhya.com/blog/2015/08/comprehensive-guide-regression/>.
- [51] **A. W. Services**, "Amazon Machine Learning - Developer Guide."
- [52] **C. Campbell and Y. Ying**, (2011). *Learning with support vector machines*, v.10.
- [53] **Cartwheel Technologies**, "Support Vector Machine - Regression (SVR)." https://www.saedsayad.com/support_vector_machine_reg.htm.
- [54] **Cartwheel Technologies**, "Decision Tree Regression." [Online]. Available: https://saedsayad.com/decision_tree_reg.htm.
- [55] **Scikit-learn**, "Decision Tree Regression." [Online]. Available: https://scikit-learn.org/stable/auto_examples/tree/plot_tree_regression.html.
- [56] **Scikit-learn**, "RandomForestRegressor." [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>.
- [57] **Carnegie Mellon School of Computer Science**, "Bayesian Linear Regression."
- [58] **S. Theodoridis**, (2015). *Machine learning: a Bayesian and optimization perspective*, 1st ed. Academic Press.
- [59] **D. Barber**, (2012). *Gaussian processes. In Bayesian Reasoning and Machine Learning*. Cambridge University Press.
- [60] **S. Vempati, A. Vedaldi, A. Zisserman, and C. V. Jawahar**, (2010). "Generalized RBF feature maps for Efficient Detection," *Br. Mach. Vis. Conf. BMVC 2010 - Proc.*
- [61] **M. Ge, T. & Smoller, Jordan & Sabuncu**, (2016). "Kernel machine regression in neuroimaging genetics".
- [62] **T. Hofmann, B. Schölkopf, and A. J. Smola**, (2008). "Kernel methods in machine learning," *Ann. Stat.*, vol. 36, no. 3, pp. 1171–1220.
- [63] **Scikit-learn**, "Dataset Transformations." [Online]. Available: https://scikit-learn.org/0.21/data_transforms.html.
- [64] **A. T. Beck and K. R. M. dos Santos**, (2014). "A benchmark study on intelligent sampling techniques in Monte Carlo simulation," *Lat. Am. J. Solids Struct.*, p. 25.

ÖZGEÇMİŞ



Ad-Soyad : Burçin ATEŞ

Doğum Tarihi ve Yeri :

E-posta

ÖĞRENİM DURUMU:

- **Lisans** : 2017, İstanbul Teknik Üniversitesi, Gemi İnşaatı ve Deniz Bilimleri Fakültesi, Gemi ve Deniz Teknolojisi Mühendisliği
- **Yükseklisans** : 2020, İstanbul Teknik Üniversitesi, Gemi ve Deniz Teknolojisi Mühendisliği Anabilim Dalı, Gemi ve Deniz Teknolojisi Mühendisliği Programı

MESLEKİ DENEYİM:

- 2017, SEFT Ship Design, Gemi İnşaatı Mühendisi.

YAYINLAR, SUNUMLAR VE PATENTLER:

Burcin Ates, Serdar Aytekin Koroglu (2021). Estimation of Stress Concentrations in Ship Structures by Using Coarse Mesh and Machine Learning. The 34th Asian-Pacific Technical Exchange and Advisory Meeting on Marine Structures .