

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GEMİ KAYNAKLI ATIK SULARIN DENİZDEKİ DAVRANIŞI İLE
GEMİ PARAMETRELERİ ARASINDAKİ İLİŞKİNİN
BELİRLENMESİ

Volkan ŞAHİN

DOKTORA TEZİ

Gemi İnşaatı ve Gemi Makineleri Mühendisliği Anabilim Dalı

Gemi İnşaatı ve Gemi Makineleri Mühendisliği Programı

Danışman

Prof. Dr. Nurten VARDAR

Kasım, 2020

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GEMİ KAYNAKLI ATIK SULARIN DENİZDEKİ DAVRANIŞI İLE GEMİ
PARAMETRELERİ ARASINDAKİ İLİŞKİNİN BELİRLENMESİ**

Volkan ŞAHİN tarafından hazırlanan tez çalışması 24.11.2020 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Gemi İnşaatı ve Gemi Makineleri Mühendisliği Anabilim Dalı, Gemi İnşaatı ve Gemi Makineleri Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Nurten VARDAR
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Nurten VARDAR, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Seyfettin BAYRAKTAR, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Ata BİLGİLİ, Üye
İstanbul Teknik Üniversitesi

Doç. Dr. Uğur Buğra ÇELEBİ, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Ali DOĞRUL, Üye
Milli Savunma Üniversitesi Deniz Harp Okulu

Danışmanım Prof. Dr. Nurten VARDAR sorumluluğunda tarafımca hazırlanan Gemi Kaynaklı Atık Suların Denizdeki Davranışı ile Gemi Parametreleri Arasındaki İlişkinin Belirlenmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Volkan ŞAHİN

İmza

Aileme

ve

biricik eşime

TEŞEKKÜR

Tezimin oluşmasında, lisans, yüksek lisans ve doktora dönemlerinde öğrencisi olduğum, bilgi, tecrübe ve sabrını benden hiç esirgemeyerek büyük emekler harcayan, çalışma azmini ve disiplinini kendime her alanda örnek almaya çalıştığım, danışmanım Sayın Prof. Dr. Nurten VARDAR' a sonsuz teşekkür ederim. Tez çalışmalarımda destek ve tecrübeleriyle yanımda olan Sayın Prof. Dr. Ata BİLGİLİ' ye ve Sayın Prof. Dr. Seyfettin Bayraktar' a teşekkür ederim. Tez çalışmam sırasında, her ne kadar yoğun olsa da yardımlarını hiç bir zaman esirgemeyen ve her anlamda büyük destek olan Dr. Öğr. Üyesi Levent BİLGİLİ' ye ayrıca teşekkür ederim. Fikirleriyle ve bilgi birikimiyle tezime katkısını esirgemeyen Arş. Gör. Dr. Mert EDALİ' ya teşekkürü bir borç bilirim.

Yüksek lisans ve doktora çalışmalarım boyunca, bana sürekli destek olan, zor dönemlerimde yanımda olarak bana güç veren eşim Seher ŞAHİN'e, bugünlere gelmemde en büyük emeğe sahip, kendileriyle gurur duyduğum ailem; annem Elif ŞAHİN'e, babam Doğan ŞAHİN'e ve abim Gökhan ŞAHİN'e sonsuz teşekkürlerimi sunarım.

Volkan ŞAHİN

İÇİNDEKİLER

SİMGE LİSTESİ	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	viii
TABLO LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı	5
1.3 Hipotez	6
2 SEYRELME VE YAPAY SİNİR AĞLARI	7
2.1 Seyrelme ve Seyrelme Faktörü	7
2.2 Yapay Sinir Ağı Modeli	8
2.2.1 Yapay Sinir Ağlarının Genel Yapısı ve Uygulama Alanları.....	8
2.2.2 YSA Modeli Oluşturma ve Kullanılan Fonksiyonlar	11
3 SEYRELMEİN YAPAY SİNİR AĞLARIYLA TAHMİN EDİLMESİ	19
3.1 Büyük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini	20
3.2 Küçük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini.....	33
3.3 Büyük ve Küçük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini.....	43
4 SONUÇ VE ÖNERİLER	54
KAYNAKÇA	57
A KARAR AĞACI KODU	64
TEZDEN ÜRETİLMİŞ YAYINLAR	66

SİMGE LİSTESİ

Q	Atık Su Boşaltma Debisi
CB	Blok Katsayısı
DWT	Detveyt Ton
T	Draft
SF _{EPA}	EPA Formülüyle Hesaplanan Seyrelme Faktörü
FRB	Freeboard
B	Gemi Genişliği
GT	Gros Ton
V	Hız
EP	Makine Gücü
PROP	Pervane Sayısı
SF _{YSA}	Yapay Sinir Ağlarıyla Tahmin Edilen Seyrelme Faktörü
PASS	Yolcu Sayısı

KISALTMA LİSTESİ

EPA	Environmental Protection Agency (Çevre Koruma Ajansı)
IMO	International Maritime Organization (Uluslararası Denizcilik Örgütü)
LEARNGD	Gradient Descent Weight Bias Learning Function
LEARNGDM	Gradient Descent with Momentum Weight and Bias Learning Function
LOGSIG	Log-sigmoid Aktivasyon Fonksiyonu
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MARPOL	Denizlerin Gemilerden Kirlenmesini Önleme Uluslararası Sözleşmesi
PURELIN	Doğrusal Aktivasyon Fonksiyonu
RMSE	Root Mean Square Error (Kök Ortalama Kare Hata)
TANSIG	Tan-sigmoid Aktivasyon Fonksiyonu
TRAINBFG	BFGS quasi-Newton Backpropagation
TRAINBR	Bayesian Regularization Backpropagation
TRAINCGB	Conjugate Gradient Backpropagation with Powell-Beale Restarts
TRAINCGF	Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts
TRAINCGP	Conjugate Gradient Backpropagation with Polak-Ribière Restarts
TRAINGD	Gradient Descent Backpropagation
TRAINGDA	Gradient Descent with Adaptive Learning Rate Backpropagation
TRAINGDM	Gradient Descent with Momentum Backpropagation
TRAINGDX	Gradient Descent with Momentum and Adaptive Learning Rate Backpropagation
TRAINLM	Levenberg-Marquardt Backpropagation
TRAINOSS	One-step Secant Backpropagation
TRAINR	Random Order Incremental Training with Learning Functions
TRAINSCG	Scaled Conjugate Gradient Backpropagation
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 2.1	İnsan sinir hücresinin genel yapısı.....	9
Şekil 2.2	Yapay sinir hücresinin genel yapısı.....	10
Şekil 2.3	Feed forward backpropagation ağ tipinin yapısı.....	13
Şekil 2.4	Cascade forward backpropagation ağ tipinin yapısı	14
Şekil 2.5	Log-sigmoid fonksiyonu	17
Şekil 2.6	Tan-sigmoid fonksiyonu	18
Şekil 2.7	Purelin (Linear) fonksiyonu.....	18
Şekil 3.1	Seyrelme faktörünün hesaplanması için oluşturulan YSA modeli.....	19
Şekil 3.2	Büyük yolcu gemileri için en iyi YSA yönteminin performans grafiği ..	23
Şekil 3.3	Büyük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği	24
Şekil 3.4	Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SFYSA = f(GT, DWT, PASS, FRB, EP, PROP, CB)$)	26
Şekil 3.5	Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(EP)$).....	27
Şekil 3.6	Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(GT)$).....	28
Şekil 3.7	Hesaplanan ve gros ton – makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(GT, EP)$).....	29
Şekil 3.8	Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(DWT)$).....	30
Şekil 3.9	Hesaplanan ve sadece yolcu sayısı verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(PASS)$)	30
Şekil 3.10	Hesaplanan ve sadece blok katsayısı verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(CB)$)	31
Şekil 3.11	Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(FRB)$).....	32
Şekil 3.12	Küçük yolcu gemileri için en iyi YSA yönteminin performans grafiği .	35
Şekil 3.13	Küçük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği.....	35
Şekil 3.14	Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SFYSA = f(GT, DWT, PASS, FRB, EP, PROP, CB)$).....	37
Şekil 3.15	Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(GT)$)	38

Şekil 3.16 Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(DWT)$)	38
Şekil 3.17 Hesaplanan ve gros ton – detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(GT, DWT)$).....	39
Şekil 3.18 Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(EP)$)	40
Şekil 3.19 Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(FRB)$).....	41
Şekil 3.20 Hesaplanan ve sadece blok katsayısı verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(CB)$)	41
Şekil 3.21 Büyük ve küçük yolcu gemileri için en iyi YSA yönteminin performans grafiği	44
Şekil 3.22 Büyük ve küçük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği	45
Şekil 3.23 YSA tarafından tahmin edilen ve EPA formülüyle hesaplanan seyrelme faktörü değerlerinin gemi gros tonuna göre değişimi	46
Şekil 3.24 Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SFYSA = f(GT, DWT, PASS, FRB, EP, PROP, CB)$).....	47
Şekil 3.25 Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(EP)$)	48
Şekil 3.26 Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(GT)$)	49
Şekil 3.27 Hesaplanan ve makine gücü – gros ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(EP, GT)$).....	50
Şekil 3.28 Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(DWT)$)	50
Şekil 3.29 Hesaplanan ve sadece yolcu sayısı verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(PASS)$).....	51
Şekil 3.30 Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SFYSA = f(FRB)$).....	52
Şekil 4.1 Gemi dizayn spirali	56

TABLO LİSTESİ

Tablo 2.1	YSA modellemesinde kullanılan girdiler, çıktı ve fonksiyonlar	13
Tablo 3.1	YSA'da kullanılan ağ tipleri, fonksiyonlar ve nöron sayıları	20
Tablo 3.2	Büyük yolcu gemileri için en iyi YSA modelleri	22
Tablo 3.3	En iyi YSA yönteminde gizli katmandaki ağırlık ve sapmalar	24
Tablo 3.4	En iyi YSA yönteminde çıktı katmandaki ağırlık ve sapmalar	25
Tablo 3.5	YSA' da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri	27
Tablo 3.6	YSA sonuçlarının RMSE ve MAE değerleri	33
Tablo 3.7	Küçük yolcu gemileri için en iyi YSA modelleri	34
Tablo 3.8	En iyi YSA yöntemine ait ağırlık ve sapmalar	36
Tablo 3.9	YSA' da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri	37
Tablo 3.10	YSA sonuçlarının RMSE ve MAE değerleri	42
Tablo 3.11	Büyük ve küçük yolcu gemileri için en iyi YSA modelleri	44
Tablo 3.12	En iyi YSA yöntemine ait ağırlık ve sapmalar	45
Tablo 3.13	YSA' da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri	47
Tablo 3.14	YSA sonuçlarının RMSE ve MAE değerleri	53

Gemi Kaynaklı Atık Suların Denizdeki Davranışı ile Gemi Parametreleri Arasındaki İlişkinin Belirlenmesi

Volkan ŞAHİN

Gemi İnşaatı ve Gemi Makineleri Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Prof. Dr. Nurten VARDAR

Gemi kaynaklı evsel atık sular siyah su (blackwater) ve gri su (graywater) olarak ikiye ayrılır ve blackwater terimi tuvaletlerden, graywater ise banyo, çamaşırhane ve restaurantlardan gelen pis suyu tanımlamaktadır. Her iki atık su türü de önemli çevresel kirleticiler olarak kabul edilmektedir. Boşaltımdan önce gemide arıtım yapılsa bile, atık su, su kalite standartlarını aşan önemli miktarlarda fekal koliform, ağır metaller, vb. içerir. Seyrelme, atık su denize boşaltıldıktan sonra, gemi iz bölgesinde meydana gelen türbülans dolaylı, kirletici konsantrasyonunun azalmasıdır. Çevre Koruma Ajansı'nın (EPA) tanımına göre, bu ikincil seyrelme işlemi işlemi, büyük oranda, geminin genişliğine, draftına, hızına ve atık su boşaltma debisine bağlı olan seyrelme faktörü ile ölçülür. Bu çalışmada, gemi ön tasarım aşamasındayken seyrelme faktörlerini tahmin etmek için geminin ana parametreleriyle bağlantılı bir Yapay Sinir Ağı (YSA) modeli geliştirilmiştir. Bu gemilerin muhtemel seyrelme faktörlerini tahmin etmek için 1041 büyük ve 901 küçük yolcu gemisinin gros ton, detveyt ton, yolcu sayısı, freeboard, makine gücü, pervane sayısı ve blok katsayı değerleri kullanılmıştır. En iyi YSA tahmin modeli, Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Hata (MAE) yöntemleriyle

belirlenmiştir. Sonuçlar için bir karar ağacı oluşturulmuş ve seyrelme faktörlerini etkileyen en önemli parametreler belirlenmiştir.

Geminin ana boyutları EPA'nın seyrelme faktörü formülasyonu için gereklidir, ancak bu çalışmada oluşturulan modelde seyrelmeyi tahmin etmek için sadece geminin grostonu ve / veya motor gücü yeterlidir. Ayrıca bu yeni model, geminin ana boyutları bilinmese bile seyrelme faktörlerinin tahmini için kullanılabilir ve boşaltım sonrası atık suyun MARPOL ve EPA standartlarını karşılayıp karşılamayacağı hakkında fikir verebilmektedir.

Anahtar Kelimeler: MARPOL, EPA, atık su, seyrelme, yapay sinir ağları

Determination the Relationship Between the Behaviour of Ship Waste Waters and Ship Parameters

Volkan ŞAHİN

Department of Naval Architecture and Marine Engineering

Doctor of Philosophy Thesis

Advisor: Prof. Dr. Nurten VARDAR

Wastewater formed on ships is divided into blackwater and graywater and while blackwater refers to wastewater from toilets, graywater defines wastewater from sinks, laundry and restaurants. Both types of wastewater are considered as important environmental pollutants. Even some treatment are applied onboard before discharge, wastewater contains significant amounts of faecal bacteria, heavy metals, etc. in excess of water quality standards. Dilution is the reduction of pollutant concentration due to turbulence that occurs in the ship wake after the waste water is discharged into the sea. According to the definition of Environmental Protection Agency (EPA), the natural treatment process is quantified by dilution factor, which is strongly depending on vessel width, draft, speed and wastewater discharge rate of the vessel. In this study, an Artificial Neural Network (ANN) model linked with the main parameters of the ship was developed to estimate the dilution factors while the ship is in the preliminary design stage. Gross ton, deadweight ton, passenger number, freeboard, engine power, propeller number and block coefficient values of 1041 large and 901 small cruise ships were used to estimate the likely dilution factors of these ships. The best ANN estimation model was determined by Root Mean Square Error (RMSE) and Mean Absolute Error (MAE)

methods. A decision tree was created for the results and the most important parameters affecting the dilution factors were determined.

The main dimensions of the ship are needed for the dilution factor formulation of EPA whereas in the model developed in this study only the gross tonnage and / or engine power of the ship is sufficient to estimate the dilution. Moreover this new model is also usable for the estimation of dilution factors even if the main dimensions of the ship are not known. Thus, It is possible to have an idea of whether wastewater after discharge will meet MARPOL and EPA standards.

Keywords: MARPOL, EPA, wastewater, dilution, artificial neural networks

1.1 Literatür Özeti

Dünya Doğayı Koruma Vakfı (World Wide Fund for Nature), yolcu gemilerini, çöplerin ve arıtılmamış kanalizasyonun denize dökülmesi ve gemi kaynaklı diğer kirleticilerin denize salınması yoluyla deniz kirliliğinin ana kaynakları olan dev yüzen şehirler olarak tanımlamaktadır. 3000 yolcu kapasiteli büyük bir yolcu gemisinde günde 100.000 litreden fazla insan atığı üretilmektedir. Yolcu gemilerinin gemide atık arıtma sistemlerine sahip olmaları gerekliliğine rağmen, Çevre Koruma Ajansı (EPA) birçok yolcu gemisinin, kanalizasyonunu eski teknoloji ile arıttığını ve yapılan boşaltımların genellikle önemli miktarda fekal koliform, ağır metal ve mineral besin içererek federal su kalite standartlarını aştığını belirtmektedir [1].

Gemiler, siyah su (blackwater, sewage) ve gri su (graywater) olarak adlandırılan iki ayrı kanalizasyon atığı üretmektedirler. Blackwater kanalizasyon, graywater ise genel pişirme ve temizleme atığı olarak adlandırılmaktadır. Blackwater, geminin tuvaletlerinden, hayvan yaşam mahallerinden, revirden gelen yüksek kirletici konsantrasyonuna sahip pis su olarak adlandırılırken, graywater, lavabolar, banyolar, çamaşırhaneler ve geminin restoran kısmından gelen daha düşük kirletici konsantrasyonuna sahip pis su olarak adlandırılmaktadır. Yolcu gemilerinde kullanılan çoğu arıtma sisteminde, blackwater ve graywater aynı tankta toplanarak, aynı arıtma işlemleriyle arıtılmaktadır[2]–[4].

Gemi kaynaklı atık su, deniz ortamında yüksek düzeyde kirlilik oluşturan organik madde, mineral besin, askıda katı madde ve koliform gibi kirletici konsantrasyonlarına sahiptir. Atık sudaki organik maddelerin her zaman çevre üzerinde doğrudan bir etkisi yoktur. Çoğu organik madde biyolojik olarak parçalanabilir ve bu işlemde çözünmüş oksijen kullanır. Bu durum oksijen eksikliğine yol açarak deniz ortamında istenmeyen bir durum yaratır. Organik maddeler, alıcı su ortamına bırakıldığında, mikroorganizmalar tarafından

ayrıştırılır ve karbondioksit ve suya dönüştürülür. Biyodegradasyon işlemi sırasında canlılar için hayati öneme sahip olan oksijen tüketilir. Organik maddeler yarı kapalı ve daha sıcak ortam suyuna karıştırıldığında durum daha ciddi hale gelir. Bu olay, doğal yaşama zarar verir ve aerobik koşullar nedeniyle çevrede toksik, patlayıcı gazlara ve kötü kokulara neden olur. Mineral besinler, deniz ortamında organizmaların büyümesi için gerekli olan azot ve fosfor gibi maddeleri ifade eder. Bunlar deniz ortamının hayatta kalması için gerekli olan maddelerdir. Ancak, çevrede çok fazlaysa birincil üretimi arttırmırlar. Ötrofikasyon olarak adlandırılan bu durum, yüksek akış ve su sirkülasyonu olmayan göl ve koy gibi su alanlarında daha önemli bir sorun yaratır. Mineral besin deşarjları uygun şekilde kontrol edilmezse, sudaki miktarı artmaya başlar ve kontrol edilemeyen bu organizmanın büyümesi nedeniyle su ortamı bataklık olmaya başlar. Bu ortamlarda, ötrofikasyon önlenmeli ve gemi kaynaklı atık sudaki mineral besinlerin neden olduğu bu ciddi sorunlar nedeniyle gerekli önlemler alınmalıdır [2], [3].

Koliform özellikle halk sağlığı ve deniz yaşamı için önemlidir. Deniz ortamında, koliform patojenik mikroorganizmaların bir göstergesi olarak kullanılmaktadır. Milyonlarca koliform dışkı yoluyla atılır. Bu organizmalar kendi başlarına patojenik olamazlar da, su kaynaklı hastalıkların iyi bir göstergesidir. Koliformlar yüzme için suyun kalitesi açısından özellikle önemlidir ve bu gibi alanlarda yasaklanamazsa çok dikkatli bir şekilde kontrol edilmelidir [2], [3].

Sudaki asitlik ve alkalilik pH ile gösterilmektedir. pH değeri 0 ile 14 arasında değişir ve 7, ortamın nötr olduğu anlamına gelmektedir. pH değeri 7'nin üzerinde olan sular alkali, aşağıdaki sular asidik olarak sınıflandırılmaktadır. Nötr sularda H^+ ve OH^- konsantrasyonu eşittir. Asidik sularda, H^+ ve bazik sularda OH^- oluşumları daha yüksektir. Deniz suyunun pH değerini etkileyen en önemli faktör karbondioksittir. Deniz suyunun pH değeri 7.5 ile 8.4 arasındadır. Karbondioksit konsantrasyonu düşük olduğunda, suyun pH değeri yükselir. pH değeri su canlıları için en önemli parametrelerden biridir. Yüksek ve düşük pH değerlerinin su organizmaları üzerinde olumsuz bir etkisi vardır. Sudaki bazı maddelerin toksitesi suyun pH değerlerine bağlı olarak azalır veya artar. Örneğin, pH değeri arttıkça, amonyanın toksik etkisi artar ve pH değeri düştüğünde sulfur ve siyanürün toksik etkisi artar.

Düşük veya yüksek pH değerleri balıklar üzerinde doğrudan veya dolaylı etkiye sahiptir. Kimyasal oksijen ihtiyacı, sudaki tüm maddelerin oksidasyonu için gerekli oksijen miktarını ifade etmektedir. Suda çözünen organik maddeler doğal kaynaklı olabilir veya arıtılmış, kentsel ve endüstriyel atık su ile birleştirilebilir. Ototrofik işlemlerin sonunda üretilen organik madde ile kirlilik yüküne maruz kalmayan sularda aerobik heterotrofik organizmaların tüketimi arasında doğal bir denge vardır. Biyolojik olarak bozunabilir organik maddelerin suya eklenmesi bu hassas dengeyi önemli ölçüde değiştirir. Oksijen tüketimi oksijen geri kazanımından yüksek olduğunda, sudaki biyolojik süreçler tamamen değişir [5].

Askıda katı maddeler ayrıca deniz ortamında çeşitli sorunlara neden olur. İlk olarak estetik olarak istenmeyen durumlar yaratırlar. Katı maddeler zamanla çökebilir ve derinliği azaltabilir. Bu katılar bentik organizmaları kapsarken, askıda katılar bulanıklık ve renk değişikliğine neden olur [2]. Asılı partiküller, balık yumurtalarını ve besin maddelerini oluşturan organizmaları örterek öldürebilir. Bu maddeler balığın oksijenini engeller ve büyüme hızını azaltır [5]. Stevenson ve arkadaşları 2019 yılında yaptığı çalışmada, ayrıca arıtılmamış kanalizasyonun besin döngüsüne olumsuz etkileri olduğunu belirtmiştir [6].

Deniz ekosistemi bu tür maddelerden etkilendiği için, Gemilerden Kaynaklanan Kirliliğin Önlenmesi Uluslararası Sözleşmesi (MARPOL 73/78) gibi kapsamlı uluslararası düzenlemeler kabul edilmiştir. MARPOL altı ek içerir ve bu eklerin her biri farklı kirlilik konularına odaklanır. Ek IV, gemilerden atık su boşaltımı, liman ve tesislerdeki arıtma sistemiyle ilgili gerekli koşullar hakkında belgelendirme ve araştırma gerekliliklerini düzenlemektedir.

MARPOL Ek IV'e göre gemiler, uygun atık su arıtma ve dezenfeksiyon sistemi veya atık su depolama tankı bulundurmak zorundadır. Ek IV'e göre, geminin bu arıtma sistemlerinden birine sahip olması halinde, atık su kıyıdan 3 deniz mili uzaklıkta deşarj edilebilir. Aksi takdirde, gemi herhangi bir arıtma sistemine sahip değilse, atık su kıyıdan en az 12 deniz mili uzaklıkta deşarj edilmelidir [2].

EPA standartlarına göre Alaska sularına pis su (sewage ve graywater) boşaltan seyir hızları 6 knot'tan az olan gemiler, fekal koliform standartlarını ve klor miktarı standartlarını karşılamak zorundadırlar [7]. Kıyıdan 1 deniz mili uzaklıkta ve en az

6 deniz mili hızındayken boşaltılması gereken arıtılmış atık su da EPA'nın Temiz Su Yasası (CWA) standartlarını karşılamalıdır [3], [8].

Önemli bir konu olmasına rağmen, literatürde gemilerin sıvı atıkları ile ilgili sınırlı sayıda çalışma bulunmaktadır. Westhof ve arkadaşları 2016 yılında yapmış oldukları çalışmada, gemi atık sularındaki mikro kirleticileri araştırmışlardır. Çalışma, farklı kirleticilerin türlerinin ve konsantrasyonlarının belirlenmesi üzerine odaklanmıştır [9]. Gibson ve arkadaşlarının 2019 yılında yapmış oldukları çalışmalarında, çeşitli gemi kirleticilerinin çevresel performanslarını karşılaştırmış ve ticari gemilerin denize deşarjının çevreye olan toplam zararlı etkilerin % 40-50'sine sahip olduğunu belirtmişlerdir [10]. Bien-Wilewska ve Anderberg 2018 yılında yapmış oldukları çalışmalarında Baltık Denizi'ndeki atık su yönetimi üzerinde limanların rolünü araştırmışlardır [11]. Yazarlar, Baltık Denizi'nin 2019 yılında (MARPOL Ek IV'e uygun olarak) yeni düzenlemelerle karşı karşıya kalacağını ve böylece limanların mevcut durumu ve potansiyel ölçümlerinin tartışıldığını belirtmişlerdir. Wang ve ark. (2019) kurumsal sosyal sorumluluk üzerine çalışmışlar ve sonuç olarak Carnival Şirketi'nin MARPOL IV yönetmeliği altında su kirliliğini çözmek için önemli bir etkiye sahip olduğu sonucuna ulaşmışlardır [12]. Backer 2018 yılındaki çalışmasında Baltık Denizi çevresi hakkındaki önceki çalışmaları gözden geçirmiş ve Helsinki Komisyonu'nun (HELCOM) rolünü araştırmıştır [13]. Bien-Wilewska ve arkadaşlarının 2016 yılında yapmış oldukları çalışmada, Baltık Denizi'nde faaliyet gösteren yolcu gemilerinin, gıda atıklarının ve atık sularının azot ve fosfor konsantrasyonunun karşılaştırılması üzerinde çalışmışlardır. Gıda atıklarında bulunan yıllık azot yükünün, atık sulardaki azot yükünün % 52'sine karşılık geldiği sonucuna varılmıştır. Fosfor yükünün ise gıda atıklarında, atık sularda olanın üçte biri kadar olduğu sonucuna varılmıştır [14].

Deniz suyuna deşarj, karıştırma ve dispersiyon işlemi açısından, yakın alan, uzak alan ve orta bölge bölümlerine ayrılmıştır [15]–[19]. Boşaltım noktasında, jet akış yönü ve karıştırma işlemi, deşarj momentumuna, deşarj ve atık suyun deşarj edildiği ortamın özellikleri arasındaki yoğunluklara bağlıdır. Yakın alan olarak tanımlanan bölge, zaman ve mesafe düzenindedir. Belirli bir süre veya mesafeden sonra, deşarj akış karakteristiklerinin etkisi dağılır. Atık suyun okyanus akıntılarının etkisiyle

seyreltildiği alanlar, uzak alan olarak tanımlanmaktadır. Burada mesafe ve zaman ölçeği kilometre ve saat cinsindendir. Bu iki bölge arasında ara alan adı verilen bir geçiş bölgesi vardır. Bu bölge jet akışının sonunda, yani yakın alanın sonunda başlar. Jirka 1982 yılında, Bleninger ve Jirka 2004 yılında yapmış oldukları çalışmada, bu merkezi bölgenin kötü akış koşulları altında su derinliğinden daha büyük mesafelere genişleyebildiğini göstermişlerdir. Öte yandan, güçlü çevre koşullarında (akışlarda), “orta bölge” süreci “uzak alan” sürecinden daha az önemli olabilir. Bu nedenle, orta bölgenin güçlü akış koşullarında ihmal edilebileceği sonucuna varılmıştır [20], [21].

Atık su gemilerden denize, EPA ve Uluslararası Denizcilik Örgütü (IMO) tarafından belirlenen ulusal ve uluslararası standartlar çerçevesinde tahliye edilebilir. Atık su, denize boşaltıldıktan hemen sonra, gemi izinde, gemi hareketleri ve pervanesi etkisiyle meydana gelen türbülansa, ikincil bir seyrelme işlemine maruz kalır. EPA bu konuda bazı teorik ve deneysel çalışmalar yaparak, oluşan bu seyrelmeyi tahmin edebilmek için çeşitli formüller yayınlamıştır. Yapılan çalışmalarda gemi iz bölgesinden atık sulardan numuneler alınarak, boşaltımdan önceki ve denize boşaltıldıktan sonraki kirletici konsantrasyonları karşılaştırılmıştır [3], [6], [22]–[26].

1.2 Tezin Amacı

Gemi kaynaklı atık suyun denizlere boşaltılması deniz ekosistemi için ciddi sorunlar teşkil etmektedir. Bu nedenle atık suyun denize boşaltılabilmesi için, ulusal ve uluslararası kuruluşlarca belirlenen kirletici konsantrasyonu standartlarını karşılayabilmesi gerekir. Atık su deşarj edilmeden önce her ne kadar arıtma sistemleriyle arıtılsa da bazı kirletici konsantrasyonları yönünden (fekal koliform, atık klor gibi) standartları karşılamayabilmektedir. Bu durum, gemi atık suyunu deşarj ettikten hemen sonra, gemi izinde meydana gelen seyrelme olayının önemini arttırmaktadır. Detaylı literatür araştırmasında, bugün ve gelecekte okyanuslar ve denizler için çok önemli olan, gemi kaynaklı atık suyun denizde seyrelmesinin matematiksel olarak incelenmediği ve bu alandaki çalışmaların çok fazla olmadığı görülmektedir. Bu amaçla, yolcu gemilerinin atık sularının seyreltilmesi bir YSA (yapay sinir ağı) modeli kullanılarak tahmin edilmiştir. Böylelikle gemi henüz ön

dizayn aşamasındayken, oluşturacağı seyrelmenin tahmin edilebilmesi, geminin faaliyet göstereceği sulardaki otoritelerce belirlenen atık su kirletici konsantrasyonu standartlarını karşılayıp karşılamayacağı hakkında fikir sahibi olunmasını mümkün kılacaktır.

1.3 Hipotez

Bu tez çalışmasında, atık suyun gemiden deşarj edildikten sonra denizde nasıl davrandığı ve denizde seyrelmesinin geminin hangi parametrelerine ne oranda bağlı olduğu incelenmiştir. Bu çalışmada, 1041 adet büyük ve 901 adet küçük yolcu gemisinin seyrelme faktörleri EPA formülleri ile hesaplanmıştır. Daha sonra aynı gemilerin seyrelme faktörleri, gros ton, detveyt ton, makine gücü, pervane sayısı, blok katsayısı, freeboard ve gemi yolcu sayısına bağlı olarak Yapay Sinir Ağı (YSA) modeli ile tahmin edilmiştir. Son olarak seyrelme faktörlerinin hesaplanan ve tahmin edilen değerleri birbirleriyle karşılaştırılmıştır. Hata oranı en düşük olan YSA modelinin sonuçları, bir karar ağacı oluşturularak incelenmiş ve seyrelmeye etki eden parametrelerin yüzdeleri belirlenmiştir. Gemi henüz ön dizayn aşamasındayken mümkün olduğunca az ve dizayn spiralinin en başındaki parametrelerle seyrelme miktarını hesaplayabilmek, atık su yönetimi açısından önemli olacaktır. Atık su standartlarını karşılayabilmek için, ikinci arıtım sistemi gibi davranan seyrelme faktörünün yeterli büyüklükte olup olmadığı hakkında fikir sahibi olmak, gemideki birincil arıtma sisteminin belirlenmesinde etkili olacaktır.

2.1 Seyrelme ve Seyrelme Faktörü

Seyrelme, bir ekosistemdeki bir kimyasalın daha az konsantre hale geldiği ve genellikle basitçe daha fazla çözücü (su gibi) ile karıştırılarak çözelti içindeki bir çözünmüş maddenin konsantrasyonunda bir azalma olduğu süreçtir. Seyrelme aynı zamanda bir kimyasalın (gaz, buhar, çözelti) asiditesinde veya alkaliliğinde bir azalmadır. Seyrelme, maddelerin konsantrasyonunu deşarj noktasından azaltmak için ana işlemlerden biridir. Bununla birlikte, kendi başına, seyrelme kimyasalın kütlesini azaltmaz, aksine kimyasallara potansiyel maruz kalma alanını yayar. Ek olarak, bazı kirletici maddelerin standart alan karakterizasyon ekipmanı ve teknikleri ile tespit edilemeyecek kadar seyreltilmiş seviyelerde bile tehlikeli (potasyum siyanür gibi) olduğuna inanılmaktadır [27].

Gemiden deşarj edilmeden önce gemide arıtma uygulansa bile, atık su, su kalite standartlarını aşan önemli miktarlarda fekal koliform, ağır metaller vb. içermektedir. Seyrelme, atık su denize boşaltıldıktan sonra, gemi iz bölgesinde meydana gelen türbülansın dolaylı, kirletici konsantrasyonunun azalmasıdır. Geminin boyutları, atık su deşarj akışı, pervanenin dönüşü ve geminin arkasında meydana gelen türbülansın etkilenir. Bu ikincil seyrelme işlemi, gemilerin belirlenmiş standartları karşılaması için hayati öneme sahiptir.

EPA tarafından yapılan teorik ve deneysel çalışmalar, seyrelmenin gemi genişliğinden, draftından, hızından ve atık suyun boşaltım debisinden ve aynı zamanda pervanenin ve geminin eşzamanlı hareketinden dolayı oluşan girdaptan etkilendiğini göstermektedir. EPA, teorik ve deneysel çalışmalar sonucunda bazı seyrelme faktörleri denklemleri sunmuştur [3], [28].

Yolcu sayısı 500 kişiden fazla olan büyük yolcu gemileri için ilk seyrelme faktörü denklemi aşağıdaki gibidir [3];

$$SF = (B T V)/Q \quad (2.1)$$

Burada;

SF: Seyrelme Faktörü

B: Genişlik (m)

T: Draft (m)

V: Hız (m/s)

Q: Atık su boşaltım debisi (m³/s)

olarak verilmektedir.

Bu çalışmaların ardından, farklı deneysel çalışmalarla elde edilen seyrelme faktörlerinin Denklem (2.1) tarafından hesaplanan seyrelme faktörlerinden 0.9, 4.2, 4.5, 4.7, 5.1, 5.3 ve 6.5 kat daha yüksek olduğu görülmüştür [29]. Böylece Denklem (2.1) "4" çarpan katsayısı eklenerek değiştirilmiştir [3];

$$SF = 4 (B T V)/Q \quad (2.2)$$

Yolcu kapasiteleri 500'den az olan gemiler küçük yolcu gemileri olarak sınıflandırılmaktadır. Yapılan çalışmalar, Denklem (2.1)'in büyük ve küçük gemilerin benzer hidrodinamik özellikleri nedeniyle küçük yolcu gemileri için "3" katsayısı ile çarpılarak kullanılabileceğini göstermiştir [30]. Küçük yolcu gemileri için seyrelme faktörü aşağıdaki gibidir.


$$SF = 3 (B T V)/Q \quad (2.3)$$

2.2 Yapay Sinir Ağı Modeli

2.2.1 Yapay Sinir Ağlarının Genel Yapısı ve Uygulama Alanları

Yapay sinir ağları, insan beyninin ana özelliklerinden olan öğrenme yoluyla yeni bilgiler türetebilme ve anlayabilme gibi yetenekleri otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Bu sistemler insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, dış ortamdan gelen girdilere karşı nasıl çıktılar üretebileceğini saptayan yapılardır. Yapay sinir ağlarının yapısı insan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme,


ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi alanlarda başarılı bir şekilde uygulanmaktadırlar. Dış ortamlardan aldıkları bilgiler ile kendi deneyimlerini oluşturarak benzer konularda benzer kararları verirler. Yapay sinir ağları bilgileri toplama, değerlendirme ve çıktı üretme konusunda biyolojik sinir hücrelerine benzer yapıda çalışmaktadırlar [31]. Biyolojik bir sinir hücresi dendrit, hücre gövdesi, çekirdek, akson ve sinapslardan oluşmaktadır. Dendritler, hücreye gelen bilgileri aksonlara iletirler. Aksonlar ise bu bilgileri diğer sinir hücrelerine ulaştıran yapılardır. Bilgileri ağırlıklandırıp, devamındaki sinir hücresinin dendritlerine ileten yapılar sinapslardır. Bu yapılarla meydana gelen sistem, sinir hücresi (nöron) olarak adlandırılmaktadır. Nöronların birbirleriyle sağlıklı iletişim içinde olması, öğrenmenin hızını ve kalitesini doğrudan etkiler. Sinir hücreleri, dış ortamdan gelen verileri birbirlerine aktararak öğrenme sürecini gerçekleştirirler. Bu verileri girdi olarak kullanıp, çıktı olarak da öğrenme işlemini gerçekleştirirler [32]. Şekil 2.1, insan sinir hücresinin yapısını göstermektedir.



Şekil 2.1 İnsan sinir hücresinin genel yapısı [33]

Biyolojik sinir ağlarındaki sinir hücrelerine benzer şekilde yapay sinir ağlarında da sinir hücreleri bulunmaktadır. Her yapay sinir hücresinin 5 temel elemanı bulunmaktadır. Bu elemanlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olarak adlandırılmaktadır. Girdiler, dış dünyadan gelen ağın öğrenmesi istenen örnekler tarafından belirlenen bilgilerdir. Ağırlıklar, yapay sinir hücresine gelen girdinin önemini ve hücre üzerindeki etkisini gösterir. Toplama fonksiyonu hücreye gelen net girdiyi hesaplar. Bu işlem için değişik fonksiyonlar kullanılsa da en yaygın olanı ağırlıklı toplamı hesaplamaktır. Her gelen girdi değeri kendi ağırlığıyla çarpılarak toplanır ve ağa gelen net girdi hesaplanmış olur. Aktivasyon fonksiyonu (transfer fonksiyonu) hücreye gelen net girdiyi işleyerek, bu

girdiye karşılık üretilecek çıktıyı hesaplar. Bu işlem için de, toplama fonksiyonunun da olduğu gibi çeşitli fonksiyonlar kullanılmaktadır. Çıktı ise aktivasyon fonksiyonu tarafından hesaplanan çıktı değeridir. Hesaplanan bu çıktı değeri dış dünyaya veya başka bir hücreye gönderilir [31], [34]. Biyolojik sinir sistemindeki, sinir sistemi, sinir, sinaps, dendrit, hücre gövdesi ve akson, yapay sinir ağlarında sırasıyla sinirsel hesaplama sistemi, düğüm, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve sinir çıkışına denk gelmektedir. Yapay sinir ağının genel yapısı Şekil 2.2’de gösterilmektedir.



Şekil 2.2 Yapay sinir hücresinin genel yapısı [33]

Yapay sinir hücreleri girdi katmanı, ara katmanlar (gizli katmanlar) ve çıktı katmanı şeklinde bir araya gelerek yapay sinir ağlarını oluştururlar. Girdi katmanından gelen bilgiler ara katmanda işlendikten sonra çıktı katmanına gönderilir. Bir ağda birden fazla ara katman bulunabilir. Çıktı katmanında ise ara katmandan gelen bilgiler işlenir ve çıktı üretilir[31], [35], [36].

Yapay sinir ağlarının çevre kirliliği ve mühendislik konularında birçok uygulama alanı mevcuttur. Jumaat ve arkadaşları 2018 yılındaki çalışmalarında, YSA kullanarak fotovoltaiik (PV) panel sisteminden güç çıkışını tahmin etmişlerdir. Çalışmada elde edilen çıktıların Kök Ortalama Kare Hatası (RMSE) değerleri YSA yönteminin uygunluğunu göstermiştir [37]. Ahmed 2017 yılındaki çalışmasında, Surma Nehri'ndeki biyokimyasal oksijen ihtiyacı (BOİ) ve kimyasal oksijen ihtiyacı

(KOİ) değerlerinden çözünmüş oksijeni tahmin etmek için YSA yöntemini kullanmıştır. YSA modelinin performansının her üç hata performansı yönteminde de kabul edilebilir olduğu bulunmuştur [38]. Singh ve arkadaşları 2009 yılındaki çalışmalarında, Gomti Nehri'ndeki biyokimyasal oksijen ihtiyacını ve çözünmüş oksijen seviyelerini YSA kullanarak tahmin etmiş ve sonuçların performansını RMSE ve R^2 yöntemleriyle değerlendirmiştir [39]. Hanbay ve arkadaşları 2008 yılındaki çalışmalarında, atık su arıtma tesisi performansını tahmin etmek için YSA'yı kullanmışlardır [40]. Keiner ve Yan 1998 yılında, Panda ve arkadaşlarının 2004 yılında yapmış oldukları çalışmalarda YSA tekniğini kullanarak, su kalitesi modellemesi üzerine çalışmışlardır [41], [42].

Abyaneh 2014 yılındaki çalışmasında, atık su arıtma tesisinde atık suyun biyokimyasal oksijen ihtiyacı ve kimyasal oksijen ihtiyacı değerlerinin belirlenmesinde çok değişkenli doğrusal regresyon (MLR) ve YSA yöntemlerinin performansını değerlendirmiştir. Her iki yöntemin performansı da korelasyon katsayısı (R) ve RMSE yöntemi ile değerlendirilmiş ve YSA modelinin MLR yönteminden daha iyi performans gösterdiği tespit edilmiştir [43]. Elhatip ve Kömür 2008 yılındaki çalışmasında, baraj suyunun elektriksel iletkenlik ve çözünmüş oksijen değerlerindeki değişiklikleri değerlendirmek için YSA yöntemini kullanarak sonuçların ölçülen değerlere yakın olduğunu bulmuşlardır [44]. Ranković ve arkadaşları 2010 yılında yapmış oldukları çalışmada, Sırbistan'da Gruža Rezervuarı'nda çözünmüş oksijen değerlerini tahmin etmek için bir YSA modeli geliştirmiştir. Sonuçların deneysel verilerle tutarlı olduğunu göstermişlerdir [45]. Saber ve arkadaşları 2019 yılında yapmış oldukları çalışmada, YSA'nın performans değerlendirmesinde, R^2 , RMSE ve bağıl hata hesaplama yöntemlerini kullanarak, su kalitesi parametrelerini tahmin etmede YSA'nın başarılı olduğunu bildirmişlerdir [46]. Çalışmalarında çözünmüş oksijenin tahmininde YSA yöntemini kullanan Sarkar ve Pandey, 2015 yılındaki çalışmalarında, YSA'nın su kalitesi modellemesinde etkili olduğunu belirtmişlerdir [47].

2.2.2 YSA Modeli Oluşturma ve Kullanılan Fonksiyonlar

Bu tez çalışmasında Mathworks®MATLAB Neural Network Toolbox paket programındaki yapay sinir ağları aracı kullanılmıştır. İlk olarak, 1041 tane büyük ve

901 tane küçük yolcu gemisinin seyrelme faktörleri sırasıyla Denklem 2.2 ve 2.3 ile hesaplanmıştır. Bu denklemlerle hesaplanan seyrelme faktörlerinin gerçek değerler olduğu varsayılmıştır. Daha sonra bu gemilerin gros ton, detveyt ton, yolcu sayıları, freeboard, makine gücü, pervane sayıları ve blok katsayıları değerleri yapay sinir ağına girdi değerleri olarak tanıtılmıştır. Denklemlerle elde edilen seyrelme faktörü değerleri ise yapay sinir ağına çıktı olarak verilmiştir.

Bütün data setinin %70'i yapay sinir ağlarına ağın kendini eğitebilmesi için eğitim seti olarak tanıtılmıştır. Daha sonra büyük yolcu gemileri için Denklem 2.2 ve küçük yolcu gemileri için Denklem 2.3' den elde edilen seyrelme faktörleri değeri ağa çıktı olarak tanıtılarak, sistemin kendini bu çıktılara göre eğitmesi istenmiştir. Eğitim sürecinden sonra, data setinin kalan % 30'u modele verilerek ve seyrelme faktörü değerleri YSA ile elde edilmiştir. Elde edilen sonuçlar denklemlerden elde edilen sonuçlarla kıyaslanarak en iyi YSA modeli belirlenmiştir. Hesaplamalar için MATLAB Neural Network Toolbox içinde hazır halde bulunan TRAINBFG, TRAINBR, TRAINCGB, TRAINCGF, TRAINCGP, TRAINGD, TRAINGDM, TRAINGDA, TRAINGDX, TRAINLM, TRAINOSS, TRAINR, TRAINRP ve TRAINSCG eğitim fonksiyonları; LEARNGD ve LEARNGDM öğrenme fonksiyonları; ortalama karesel hata (MSE) ve kareleri alınmış hatalar toplamı (SSE) performans ve hata fonksiyonları olarak, 8, 10, 12 nöron sayılarıyla cascade-forward backpropagation (CFB) ve feed-forward backpropagation (FFB) ağ tiplerinde girdi katmanında log-sigmoid (LOGSIG) ve tan-sigmoid veya hiperbolik tanjant (TANSIG); gizli katmanda ise LOGSIG, TANSIG ve doğrusal (PURELIN) aktivasyon fonksiyonları kullanılmıştır. Kullanılan girdiler, çıktılar ve fonksiyonlar Tablo 2.1'de verilmiştir.


2.2.2.1 YSA'da Kullanılan Ağ Tipleri

FFB ağ tipi bir dizi katmandan oluşur. İlk katmanın ağ girişinden olmak üzere, sonraki her katmanın bir önceki katmanla bağlantısı vardır. Son katman ağın çıktısını üretir. Bu sistemde, bulunan hatalar geriye doğru işletilerek, mümkün olduğunca doğru bir öğrenme algoritması oluşturmaya çalışılır. FFB algoritmaları ileri doğrultuda seyreden, gizli nöronlar arasında dönüşümlü bir ilişkisi olmayan yapılardır. FFB algoritmaları, karmaşık ve nonlinear ağ bağlantılarını öğrenmekte kullanılabilir [48], [49].

Tablo 2.1 YSA modellemesinde kullanılan girdiler, çıktı ve fonksiyonlar


Girdiler	-Gros Ton -Detveyt Ton -Yolcu Sayısı -Freeboard -Makine gücü -Pervane Sayısı -Blok Katsayısı	
Ağ Tipleri	-Feed-forward backpropagation -Cascade-forward backpropagation	
Eğitim Fonksiyonları	-TRAINBFG -TRAINBR -TRAINCGB -TRAINCGF -TRAINCGP -TRAINGD -TRAINGDM	-TRAINGDA -TRAINGDX -TRAINLM -TRAINOSS -TRAINR -TRAINRP -TRAINSCG
Öğrenme Fonksiyonları	-LEARNGD -LEARNGDM	
Performans ve Hata Fonksiyonları	-MSE -SSE	
Nöron Sayıları	-8 -10 -12	
Aktivasyon Fonksiyonları	-LOGSIG -TANSIG -PURELIN	
Çıktı	-Seyrelme Miktarı	

Şekil 2.3'te FFB ağ tipinin yapısı görülmektedir [49].



Şekil 2.3 Feed forward backpropagation ağ tipinin yapısı

CFB ağ tipi, FFB ağlara benzer yapıdadır. Ancak girişten ve önceki her katmandan sonraki katmanlara bir bağlantı içerir. Yani her katmandaki nöronlar bir önceki katmandaki nöronlarla bağlantı göstermektedir. Şekil 3.3'te CFB ağ tipinin yapısı görülmektedir [50].



Şekil 2.4 Cascade forward backpropagation ağ tipinin yapısı

2.2.2.2 YSA'da Kullanılan Öğrenme Fonksiyonları

Bu tez çalışmasında MATLAB Neural Network Toolbox paket programı içerisindeki LEARNGD ve LEARNGDM öğrenme fonksiyonları kullanılmıştır. LEARNGD öğrenme fonksiyonunda;

$$dW = lr \times gW \quad (2.4)$$

formülü kullanılmaktadır. Burada; dW , nörondaki değişimi, lr öğrenme hızını ve gW gradyan inişi temsil etmektedir [32], [51]. LEARNGDM öğrenme fonksiyonunda;

$$dW = mc \times dW_{prev} + (1 - mc) \times lr \times gW \quad (2.5)$$

formülü kullanılmaktadır. LEARNGD öğrenme fonksiyonundan farklı olarak bu formülde 'mc' momentum sabiti kullanılmaktadır [52].

2.2.2.3 YSA'da Kullanılan Eğitim Fonksiyonları

Bu tez çalışmasında MATLAB Neural Network Toolbox paket programı içerisindeki, aşağıda detayları açıklanan eğitim fonksiyonları kullanılmıştır. Eğitim fonksiyonları, sisteme girilen data'ları belirli algoritmalarla göre kullanarak sistemi eğittikten sonra çıktı'lara ulaşmak için kullanılır.

TRAINBFG fonksiyonu, ağırlık ve sapma değerlerini BFGS quasi-Newton yöntemine göre düzenleyen bir ağ eğitim fonksiyonudur. TRAINBFG fonksiyonu,

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (2.6)$$

formülüyle ifade edilmektedir. Burada Hessian Matrisi, A_k^{-1} olarak belirtilmiştir. Hessian Matrisi, skaler değerli bir alanın ya da fonksiyonun ikinci dereceden kısmi türevlerinden oluşan kare matristir. Quasi-Newton olarak isimlendirilen yöntemlerde, ikinci türevleri hesaplanmadan da ileri beslemeli yapay sinir ağı yapısı oluşturulabilir [53].

TRAINBR fonksiyonu, ağırlık ve sapma değerlerini Levenberg-Marquardt optimizasyonuna göre düzenleyen bir ağı eğitim fonksiyonudur. Hata ve ağırlıkların kombinasyonunu en aza indirerek, ardından en iyi ağı üretmek için doğru kombinasyonu belirler. Bu sürece Bayes düzenlenmesi denilmektedir [54].

TRAINCGB fonksiyonu, ağırlık ve sapma değerlerini Powell-Beale fonksiyonunun, geri yayılımına (back propagation) göre düzenleyen bir ağı eğitim fonksiyonudur [55]. TRAINCGF eğitim fonksiyonu, ağırlık ve sapma değerlerini Fletcher-Reeves eşlenik gradyan algoritmasına göre düzenleyen bir ağı fonksiyonudur. Tüm eşlenik gradyan algoritmaları, ilk yinelemede en dik iniş yönünde (gradyanın negatifi) arama yaparak başlar.

$$p_0 = -g_0 \quad (2.7)$$

Ardından, geçerli arama yönü boyunca hareket etmek için en uygun mesafeyi belirlemek üzere bir satır araması yapılır;

$$(x_{k+1} = x_k + \alpha_k p_k) \quad (2.8)$$

Daha sonra bir sonraki arama yönü, önceki arama yönlerine eşlenecek şekilde belirlenir. Yeni arama yönünü belirlemek için genel prosedür, en dik iniş yönünü önceki arama yönüyle birleştirmektir;

$$(p_k = -g_k + \beta_k p_{k-1}) \quad (2.9)$$

Eşlenik gradyan algoritmasının çeşitli versiyonları, sabit β_k değerinin hesaplanma şekli ile ayırt edilir. Fletcher-Reeves düzenlemesi için;

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{g_{k-1}^T g_{k-1}} \quad (2.10)$$

formülü kullanılır. Bu, geçerli gradyanın karesi alınmış normunun, bir önceki gradyanın karesi olan norma oranıdır [56]. TRAINCGP eğitim fonksiyonunda da denklem 2.9 ve 2.10 kullanılmaktadır [57]. TRAINGD fonksiyonu ağırlık ve sapma değerlerini gradyan inişine göre güncelleyen bir ağ eğitim fonksiyonudur. Ağın ağırlıkları, girdileri ve aktivasyon fonksiyonlarının türevlenebilir fonksiyonlar olması durumunda bütün ağlar eğitilebilir. Performans türevleri herhangi bir değişkenin ağırlık ve sapmalarına bağlı olarak, geri yayılım yöntemiyle (backpropagation) hesaplanır [58]. TRAINGDM eğitim fonksiyonu TRAINGD fonksiyonuna benzer yapıda çalışır. Ek olarak hesaplamalarda gradyan inişin momentumu hesaba katılır [59]. TRAINGDA eğitim fonksiyonunda da mevcut iterasyonun ağırlık ve sapma değerleri kullanılarak yeni iterasyonların ağırlık ve sapma değerleri hesaplanır [60]. TRAINGDX eğitim fonksiyonunda, TRAINGD fonksiyonundan farklı olarak uyarlanabilir öğrenme oranı da kullanılır [61]. TRAINLM eğitim fonksiyonunda ağırlık ve sapma değerleri Levenberg-Marquardt optimizasyon yöntemine göre düzenlenir. Bu eğitim fonksiyonunda da Hessian Matrisi kullanılır. Hessian Matrisi ve gradyan sırasıyla;

$$H = J^T J \quad (2.11)$$

$$g = J^T e \quad (2.12)$$

şeklinde hesaplanır. J, ağırlık ve sapma değerleri açısından ağ hatalarının birinci türevlerini kapsayan Jacobian matrisidir ve e, ağ hatalarının vektörünü temsil etmektedir. Jacobian matrisi, Hessian matrisini hesaplamaktan daha az karmaşık olan standart bir geri yayılım tekniği ile hesaplanabilir. Levenberg-Marquardt algoritması, bu yaklaşımı Hessian matrisine aşağıdaki Newton benzeri güncellemede kullanır [62].

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (2.13)$$

TRAIPOSS eğitim fonksiyonu tek aşamalı sekant yöntemine göre ağırlık ve sapma değerlerini güncelleyen bir ağ eğitim fonksiyonudur. BFGS algoritması, her yinelemede eşlenik gradyan algoritmalarından daha fazla depolama ve hesaplama gerektirdiğinden, daha küçük depolama ve hesaplama gereksinimlerine sahip sekant yaklaşımına ihtiyaç vardır. Bir aşamalı sekant yöntemi, eşlenik gradyan

algoritmaları ile Quasi-Newton algoritmaları arasındaki boşluğu doldurmaktadır [63]. TRAINR eğitim fonksiyonunda, her iterasyon için, tüm eğitim vektörlerinin (veya sekanslarının) her biri farklı rastgele bir sırayla verilerek, ağırlık ve sapma değerleri buna göre güncellenir [64]. TRAINRP eğitim fonksiyonu, esnek geri yayılım algoritmasına göre ağırlık ve sapma değerlerini güncelleyen bir ağ eğitim fonksiyonudur [65]. TRAINSCG eğitim fonksiyonu, ağırlık ve sapma değerlerini ölçeklendirilmiş eşlenik gradyan yöntemine göre güncelleyen bir ağ eğitim fonksiyonudur. Bu eğitim algoritmasında ağırlıkları, net girdileri ve aktivasyon fonksiyonları türevlenebilir fonksiyonlara sahip bütün ağlar eğitilebilir [66].

2.2.2.4 YSA'da Kullanılan Performans ve Hata Fonksiyonları

Bu tez çalışmasında MATLAB Neural Network Toolbox paket programı içerisindeki MSE (Mean squared normalized error) ve SSE (Sum squared error) performans ve hata fonksiyonları kullanılmıştır. MSE, ağın performansını, hataların karelerinin ortalamasına göre ölçer [67]. SSE ise ağın performansını hataların karelerinin toplamına göre ölçmektedir [68].


2.2.2.5 YSA'da Kullanılan Aktivasyon (transfer) Fonksiyonları

Aktivasyon fonksiyonları sisteme gelen net girdiyi işler ve hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. MATLAB Neural Network Toolbox paket programında LOGSIG (log-sigmoid), TANSIG (tan-sigmoid veya hiperbolik tanjant) ve PURELIN (lineer) olmak üzere üç tane aktivasyon fonksiyonu bulunmaktadır. LOGSIG fonksiyonunun dinamik aralığı [0 1] aralığındayken, TANSIG ve PURELIN fonksiyonlarının dinamik aralıkları [-1 1] arasındadır [69]–[71].

LOGSIG fonksiyonunun ait formülasyon;

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.14)$$

şeklinde gösterilir. LOGSIG fonksiyonuna ait grafik Şekil 2.5' te gösterilmiştir [72].




Şekil 2.5 Log-sigmoid fonksiyonu

TANSIG fonksiyonuna ait formülasyon;

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2.15)$$

şeklinde gösterilir. TANSIG fonksiyonuna ait grafik Şekil 2.6' da gösterilmiştir [73].




Şekil 2.6 Tan-sigmoid fonksiyonu

PURELIN fonksiyonuna ait formülasyon

$$f(x) = x \quad (2.16)$$

şeklinde dir. PURELIN fonksiyonuna ait grafik Şekil 2.7' de gösterilmiştir [74].



Şekil 2.7 Purelin (Lineer) fonksiyonu


Bu tez çalışmasında LOGSIG ve TANSIG fonksiyonları gizli katmanda kullanılırken, çıktı katmanında PURELIN ve TANSIG fonksiyonları kullanılmıştır. Bu fonksiyonların kullanılabilmesi için yapay sinir ağlarına tanıtılan tüm verilerin LOGSIG fonksiyonu için denklem 2.17 ve TANSIG fonksiyonu içinse denklem 2.18' e göre normalize edilmesi gerekmektedir [69], [70], [75].

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.17)$$

$$x_{norm} = 2 \times \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) - 1 \quad (2.18)$$

SEYRELMEİN YAPAY SİNİR AĞLARIYLA TAHMİN EDİLMESİ

Bu kısımda 1041 adet büyük ve 901 tane küçük yolcu gemisinin verileri Şekil 3.1’ de gösterildiği gibi yapay sinir ağlarına girdi olarak verilerek, çıktı olarak seyrelme faktörü elde edilmiştir.



Şekil 3.1 Seyrelme faktörünün hesaplanması için oluşturulan YSA modeli

Şekil 3.1’ de, girdilerin farklı sayıda nöron içeren gizli bir katman yardımıyla çıkış katmanına aktarıldığı görülebilir. Bu çalışmada 8, 10 ve 12 nöron kullanılmıştır [76]. Oluşturulan YSA modelinde kullanılan ağ tipleri, eğitim, öğrenme, performans ve hata fonksiyonları Tablo 3.1’ de gösterildiği gibidir. Oluşturulan her bir YSA modelinde LOGSIG ve TANSIG fonksiyonlarından bir tanesi gizli katmanda, TANSIG ve PURELIN fonksiyonlarından bir tanesi de çıktı katmanında kullanılmıştır.

Tablo 3.1 YSA’da kullanılan ağ tipleri, fonksiyonlar ve nöron sayıları

Ağ Tipi	Eğitim Fonksiyonu	Öğrenme Fonksiyonu	Aktivasyon Fonksiyonu		Performans ve Hata Fonksiyonu	Nöron Sayısı
FFB/CFB	TRAINBFG	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINBR	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINCGB	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINCGF	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINCGP	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINGD	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINGDM	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINGDA	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINGDx	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINLM	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINOSS	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINR	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINRP	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12
FFB/CFB	TRAINSxG	LEARNGD/LEARNGDM	LOGSIG/TANSIG	TANSIG/PURELIN	MSE/SSE	8/10/12

Her bir YSA modelinde, 14 farklı eğitim fonksiyonu, 2 farklı öğrenme fonksiyonu, gizli ve çıktı katmanlarında 2’şer farklı aktivasyon fonksiyonu, 2 farklı performans fonksiyonu 3 farklı nöron sayısında denenerek, 2 farklı ağ tipinde hesaplamalar yapılmıştır. Sonuç olarak; büyük yolcu gemileri, küçük yolcu gemileri, büyük ve küçük yolcu gemileri veri grubu oluşturularak, bu herbir grup için toplamda 1344 farklı model oluşturulmuştur.

3.1 Büyük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini

1041 tane büyük yolcu gemisinin gros ton, dedveyt ton, yolcu sayısı, freeboard, makine gücü, pervane sayısı, blok katsayısı değerlerinden oluşan data seti yapay sinir ağlarında 1041 x 7 matris oluşturularak kullanılmıştır. Veriler, tümü Tablo 3.1’de tanımlanan ağ tipleri, aktivasyon fonksiyonları, eğitim fonksiyonları, öğrenme fonksiyonları, performans ve hata fonksiyonları ve 3 farklı nöron numarasını içeren farklı YSA modelleri tarafından çalıştırılmıştır.

1041 geminin, 729 tanesinin (% 70) verileri YSA modelini eğitmek için eğitim verisi olarak tanımlanmıştır. Sistemin eğitim performansını test etmek için kalan 312 geminin verileri (% 30) sisteme test verisi olarak tanımlanmıştır. Eğitim verisi olarak tanımlanan gemilerin seyrelme faktörleri EPA' nın seyrelme faktörü denklemine (denklem 2.2) göre hesaplanarak, eğitim verilerinin çıktısı olarak tanımlanmıştır. Öğrenme işlemi tamamlandıktan sonra, test için ayrılan gemilerin verileri, YSA tarafından işlenerek bu gemilerin seyrelme faktörlerinin, EPA seyrelme faktörü formülasyonu tarafından hesaplanan seyrelme faktörü değerine ne kadar yaklaştığı hesaplanmıştır. Daha sonra, oluşturulan YSA modelinin sonuçlarını test etmek ve en iyi YSA modeline ulaşmak için tüm sonuçlara RMSE (Root Mean Square Error) ve MAE (Mean Absolute Error) yöntemleri uygulanarak hatalar hesaplanmıştır. RMSE ve MAE, YSA modellerinin doğruluğunu belirlemek için yaygın olarak kullanılan ve iki sürekli değişken, yani tahmin edilen ve elde edilen sonuçlar arasındaki farka dayanan hata hesaplama yöntemleridir. RMSE yönteminde gerçek ve elde edilen değerler farkının karesinin toplam değer sayısına bölümünün karekökü alınarak bir hata analizi gerçekleştirilir. MAE yöntemindeyse gerçek ve elde edilen değerler farkının mutlak değerlerinin toplamının değer sayısına bölünmesiyle hata analizi yapılmaktadır. RMSE ve MAE formülleri sırasıyla aşağıdaki gibidir [77].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3.1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.2)$$

$$e = SF_{EPA} - SF_{YSA} \quad (3.3)$$

$$SF_{EPA} = f(B, T, V, Q) \quad (3.4)$$

$$SF_{YSA} = f(GT, DWT, PASS, FRB, EP, PROP, CB) \quad (3.5)$$

Burada;

- SF_{EPA} : EPA formülasyonuna göre hesaplanan seyrelme faktörü
- SF_{YSA} : YSA tarafından tahmin edilen seyrelme faktörü
- GT : Gros ton (m^3)

DWT : Detveyt ton (ton)
 PASS : Yolcu Sayısı
 FRB : Freeboard (m)
 EP : Makine gücü (kW)
 PROP : Pervane Sayısı
 CB : Blok katsayısı
 n : Gemi Sayısı

olarak tanımlanmıştır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.05290 \quad (3.6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0393 \quad (3.7)$$

Tablo 3.2'de RMSE ve MAE yöntemlerine göre, büyük yolcu gemileri için en iyi 10 YSA sonucu sunulmuştur. RMSE ve MAE sonuçları, Denklem 3.1 ve 3.2'nin YSA modeli ile elde edilen tüm sonuçlara (312 test gemisinin sonuçları) uygulanmasıyla hesaplanmıştır. RMSE ve MAE yöntemlerinde sonuçların sıfıra yaklaşması, sistemin daha iyi çalıştığını göstermektedir.


Tablo 3.2 Büyük yolcu gemileri için en iyi YSA modelleri

Ağ Tipi	Aktivasyon Fonksiyonu	Eğitim Fonksiyonu	Öğrenme Fonksiyonu	Performans ve Hata Fonksiyonu	Nöron Sayısı	RMSE	MAE
CFB	LOGSIG-PURELIN	TRAINCGB	LEARNGD	MSE	12	0.05290	0.0393
CFB	LOGSIG-PURELIN	TRAINLM	LEARNGD	MSE	8	0.05496	0.0397
FFB	LOGSIG-PURELIN	TRAINCGB	LEARNGD	MSE	8	0.05614	0.0428
FFB	LOGSIG-PURELIN	TRAINCGF	LEARNGDM	SSE	12	0.05732	0.0429
FFB	LOGSIG-PURELIN	TRAINCGB	LEARNGD	MSE	10	0.05747	0.0404
CFB	LOGSIG-PURELIN	TRAINRP	LEARNGDM	MSE	12	0.05946	0.0451
CFB	LOGSIG-PURELIN	TRAINCGB	LEARNGD	SSE	12	0.06009	0.0423
FFB	LOGSIG-TANSIG	TRAINGDM	LEARNGD	SSE	8	0.06026	0.0470
CFB	LOGSIG-PURELIN	TRAINCGB	LEARNGDM	MSE	8	0.06059	0.0436
CFB	LOGSIG-PURELIN	TRAINSGB	LEARNGD	SSE	12	0.06064	0.0452

Büyük yolcu gemilerinin seyrelme faktörünün tahmin edilmesi için oluşturulan YSA modelinde en iyi RMSE ve MAE değerleri, CFB ağ tipi, LOGSIG-PURELIN (gizli katmandaki LOGSIG, çıkış katmanındaki PURELIN işlevi) aktivasyon fonksiyonu,


TRAINCGB eğitim fonksiyonu, LEARNGD öğrenme fonksiyonu, MSE performans ve hata fonksiyonu ve 12 nöronla eğitilen YSA modelinden sırasıyla 0.05290 ve 0.0393 olarak elde edilmiştir.

Şekil 3.2 ve Şekil 3.3, en iyi YSA modeli için performans ve regresyon grafiklerini göstermektedir. Şekil 3.2, YSA modelinin toplam 27 iterasyon yaptığını ve 21. iterasyonda en iyi sonucu elde ettiğini göstermektedir. 21. iterasyondan sonra, model en iyi sonuca ulaştığında durmaya karar vermiştir. Bu, modelin 21. iterasyondan sonra kararlı hale geldiği anlamına gelmektedir.



Şekil 3.2 Büyük yolcu gemileri için en iyi YSA yönteminin performans grafiği

Mathworks® MATLAB Neural Network Toolbox, YSA sistemine verilen eğitim verilerini (mevcut tüm verilerin% 70'i) %70' i eğitim, %15' i validasyon ve %15' i test olacak şekilde kendi içinde bölerek öğrenme sürecini gerçekleştirmektedir. Şekil 3.3'e göre, eğitim, validasyon ve test süreçlerinde modelin ortalama başarı oranı 0.93216'dır. R değeri 1.0'a yaklaştıkça, modelin başarılı bir sonuç elde ettiği söylenebilir [78]. Şekil 3.3' te sistemin eğitim kısmının R değerinin 0.93801, validasyon kısmında R değerinin 0.9187 olduğu ve test kısmında R değerinin 0.9272 olduğu görülmektedir.



Şekil 3.3 Büyük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği

Tablo 3.3 ve 3.4' te oluşturulan YSA modelinin ağırlık ve sapma değerleri verilmiştir.

Tablo 3. 3 En iyi YSA yönteminde gizli katmandaki ağırlık ve sapmalar

Nöron (i)	GT	DWT	PASS	FRB	EP	PROP	CB	l_w	b_i
1	1.688	2.353	0.966	1.012	1.137	1.325	1.670	-0.9586	-3.945
2	2.405	-0.092	1.526	-1.084	1.515	-1.450	-1.514	-0.3060	-3.261
3	-1.617	1.630	1.226	2.234	-0.829	0.055	2.057	0.6825	2.379
4	2.239	-1.648	-0.495	-2.284	1.160	0.944	-0.651	0.7073	-1.880
5	0.915	-0.709	1.056	-0.459	1.056	2.716	-2.067	-0.4331	-0.930
6	-1.863	1.662	-1.517	-0.637	-1.558	1.923	-1.045	0.5922	0.532
7	-1.429	1.797	1.248	1.642	-2.430	0.328	0.667	-0.2533	-0.358
8	0.166	2.214	-2.270	1.447	-0.147	-1.703	-0.335	-0.2904	1.074
9	2.127	0.705	-1.017	-1.491	2.154	-1.610	-0.655	0.4977	1.865
10	2.071	-1.999	-1.964	-0.007	-0.695	-1.101	1.480	-0.7390	2.504
11	-1.805	1.941	-2.157	-0.267	0.615	1.875	0.448	0.5579	-3.271
12	2.296	2.135	1.590	0.729	-1.370	-1.136	0.146	0.0056	3.920

Tablo 3. 4 En iyi YSA yönteminde çıktı katmandaki ağırlık ve sapmalar

GT	DWT	PASS	FRB	EP	PROP	CB	b ₂
0.67191	0.16502	0.059104	0.30242	0.18465	-0.15789	-0.21583	0.0640

Tablo 3.3 ve Tablo 3.4' te sunulan değerler, her bir nöronun her girdi üzerindeki etkilerini gösterir. b_i, karşılık gelen nörondaki her bir girişin değerlerinin sapmasını temsil eder.

Ağırlıkların ve sapmaların matematiksel ifadesi aşağıdaki gibidir [76];

$$u_i = \sum_{j=1} W_{ij}X_j + b_i \quad (3.8)$$

Burada;

i : Nöron sayısı

j : Gemi parametresi

u_i : i. nörondaki aktivite

W_{ij} : i. nörondaki j. ağırlık

X_j : j. katmandaki çıktı değeri

b_i : 1. katmandaki i. nöronun sapma değeri

göstermektedir. Gizli katmandaki çıktı değerleri, denklem 2.14' te gösterildiği gibi aşağıdaki formülasyonla hesaplanır.

$$\text{Log sig}(u_i) = \frac{1}{1 + e^{-u_i}} \quad (3.9)$$

1041 tane büyük yolcu gemisinin $SF_{YSA_{\text{logsig}}}$, $SF_{YSA_{\text{purelin}}}$ ve SF_{YSA} değerleri kullanılan YSA modeliyle hesaplanmıştır. YSA modeline göre değiştirilmiş denklemler aşağıdaki gibidir.

$$SF_{YSA_{\text{logsig}}} = \sum_{i=1}^{12} \text{logsig}(u_i)lw_i \quad (3.10)$$

Çıktı katmanındaki çıktı değerleri, denklem 2.16'da gösterildiği gibi aşağıdaki formülasyonlarla hesaplanır.

$$\text{Purelin}(u_i) = u_i \quad (3.11)$$

$$SF_{YSA_{purelin}} = (\sum_{i=1}^7 W_{ij} X_j) + b_2 \quad (3.12)$$

Burada;

lw_i : Katmandaki ağırlık


b_2 : 2. katmandaki sapma

olarak gösterilmektedir. Eğitilmiş YSA modelinin ağırlık ve sapma değerleri kullanılarak, seyrelme faktörünün normalize edilmiş değeri aşağıdaki gibi verilebilir.

$$SF_{YSA} = (\sum_{i=1}^{12} \logsig(u_i) lw_i) + (\sum_{i=1}^7 W_{ij} X_j) + b_2 \quad (3.13)$$

Burada, SF_{YSA} denklem 2.17' ye göre normalize edilmiş seyrelme faktörü değeridir.

Yapay sinir ağlarına 7 tane girdi (GT, DWT, makine gücü, yolcu sayısı, pervane sayısı, blok katsayısı, freeboard) girilerek karşılığında çıktı olarak seyrelme faktörü elde edilmiştir. Şekil 3.4, tüm girdi değerleri için YSA tarafından tahmin edilen ve hesaplanan seyrelme faktörleri arasındaki ilişkiyi göstermektedir. R^2 değerinin 1.0'a yaklaşması, tahmin edilen ve hesaplanan seyrelme faktörlerinin birbirine yaklaştığı ve hata oranının azaldığı anlamına gelmektedir [79].




Şekil 3.4 Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT, DWT, PASS, FRB, EP, PROP, CB)$)

YSA tarafından elde edilen sonuca hangi girdinin ne kadar etki ettiğini hesaplayabilmek ve nihayetinde gemi henüz ön dizayn aşamasındayken tek parametreye bağlı olarak geminin oluşturabileceği seyrelme faktörünü hesaplayabilmek için R dilinde CART algoritması kullanılarak, RPART kütüphanesi [80] kaynaklı bir kod yazılarak bir karar ağacı (decision tree) oluşturulmuştur [81]–[83]. Yazılan bu kod ek A' da gösterilmiştir. Yapay sinir ağlarına girdi olarak verilen değişkenlerin seyrelme faktörleri üzerindeki etki oranları Tablo 3.5' de gösterilmektedir. Tablo 3.5' de görüldüğü gibi makine gücü ve gros ton girdi değerleri seyrelme faktörlerini sırasıyla %37 ve %29 etkilemiştir.

Tablo 3.5 YSA' da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri

EP	GT	DWT	PASS	CB	FRB	PROP
%37	%29	%13	%12	%5	%3	%1

Makine gücü ve gros ton dataları YSA sistemine ayrı ayrı ve beraber girilerek çıktı olarak seyrelme faktörü elde edilmiştir. Şekil 3.5, YSA' nın sadece makine gücü veri setiyle eğitildikten sonraki seyrelme faktörü tahminleriyle EPA formülasyonu (denklem 2.2) hesaplanan seyrelme faktörü değerlerinin karşılaştırılmasını göstermektedir.



Şekil 3.5 Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(EP)$)


Makine gücü verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(EP) \quad (3.14)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0702 \quad (3.15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0475 \quad (3.16)$$

Şekil 3.6, YSA' nın sadece gros ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.6 Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT)$)


Gros ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(GT) \quad (3.17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0713 \quad (3.18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0491 \quad (3.19)$$

Şekil 3.7, YSA' nın makine gücü ve gros ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.7 Hesaplanan ve gros ton – makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT, EP)$)

Gros ton ve makine gücü verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(GT, EP) \quad (3.17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0518 \quad (3.18)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0373 \quad (3.19)$$


Detveyt ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(DWT) \quad (3.20)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1099 \quad (3.21)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0785 \quad (3.22)$$

Şekil 3.8, YSA' nın sadece detveyt ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.8 Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(DWT)$)

Şekil 3.9, YSA' nın sadece yolcu sayısı veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.9 Hesaplanan ve sadece yolcu sayısı verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(PASS)$)


Yolcu sayısı verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(PASS) \quad (3.23)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1118 \quad (3.24)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0900 \quad (3.25)$$

Şekil 3.10, YSA' nın sadece blok katsayısı veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.10 Hesaplanan ve sadece blok katsayısı verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(C_B)$)


Blok katsayısı verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(C_B) \quad (3.26)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1501 \quad (3.27)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.1178 \quad (3.28)$$

Şekil 3.11, YSA' nın sadece freeboard veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.11 Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(FRB)$)

Freeboard verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(FRB) \quad (3.29)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1332 \quad (3.30)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.1007 \quad (3.31)$$

Yukarıda verilen grafiklerden de görüldüğü gibi, seyrelme faktörünü hesaplamak için YSA'ya tanıtılan girdilerin, karar ağacından elde edilen seyrelme faktörlerine etki oranı azaldıkça, R^2 değerleri azalmış ve RMSE ve MAE değerleri de artmıştır. Bu durum da hata oranlarının arttığını göstermektedir. Bu sonuç karar ağacının doğru çalıştığını ve büyük yolcu gemilerinin seyrelme faktörüne etki eden en önemli parametrelerin makine gücü ve/veya gros ton değerlerinin olduğunu desteklemektedir.

Tablo 3.6, YSA sonuçlarının RMSE ve MAE değerlerini göstermektedir. Tablo 3.6'da verilen sonuçlar, YSA'nın, gemi henüz ön dizayn aşamasındayken bir geminin seyrelme faktörünü gemi gros tonu ve/veya makine gücü verisiyle kabul edilebilir bir hata ile tahmin etmek için yeterli olduğunu göstermektedir.

Tablo 3.6 YSA sonuçlarının RMSE ve MAE değerleri

	RMSE	MAE
Bütün Veri Seti Kullanıldığında	0.0529	0.0393
Sadece Makine Gücü Veri Seti Kullanıldığında	0.0702	0.0475
Sadece Gros Ton Veri Seti Kullanıldığında	0.0713	0.0491
Makine Gücü ve Gros Ton Veri Seti Birlikte Kullanıldığında	0.0518	0.0373
Sadece Detveyt Ton Veri Seti Kullanıldığında	0.1099	0.0785
Sadece Yolcu Sayısı Veri Seti Kullanıldığında	0.1118	0.09
Sadece Blok Katsayısı Veri Seti Kullanıldığında	0.1501	0.1178
Sadece Freeboard Veri Seti Kullanıldığında	0.1332	0.1007

3.2 Küçük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini

901 tane küçük yolcu gemisinin gros ton, dedveyt ton, yolcu sayısı, freeboard, makine gücü, pervane sayısı, blok katsayısı değerlerinden oluşan data seti yapay sinir ağlarında 901 x 7 matris oluşturularak kullanılmıştır. Veriler, büyük yolcu gemilerinin seyrelme faktörlerini hesaplanmasında olduğu gibi, tümü Tablo 3.1'de tanımlanan ağ tipleri, aktivasyon fonksiyonları, eğitim fonksiyonları, öğrenme fonksiyonları, performans ve hata fonksiyonları ve 3 farklı nöron numarasını içeren farklı YSA modelleri tarafından çalıştırılmıştır.

901 geminin, 631 tanesinin (% 70) verileri YSA modelini eğitmek için eğitim verisi olarak tanımlanmıştır. Sistemin eğitim performansını test etmek için kalan 270 geminin verileri (% 30) sisteme test verisi olarak tanımlanmıştır. Eğitim verisi olarak tanımlanan gemilerin seyrelme faktörleri EPA' nın seyrelme faktörü denkleminde (denklem 2.3) göre hesaplanarak, eğitim verilerinin çıktısı olarak tanımlanmıştır. Öğrenme işlemi tamamlandıktan sonra, test için ayrılan gemilerin verileri, YSA tarafından işlenerek bu gemilerin seyrelme faktörlerinin, EPA seyrelme faktörü formülasyonu tarafından hesaplanan seyrelme faktörü değerine ne kadar yaklaştığı hesaplanmıştır. Daha sonra, oluşturulan YSA modelinin sonuçlarını test etmek ve en iyi YSA modeline ulaşmak için tüm sonuçlara RMSE (Root Mean Square

Error) ve MAE (Mean Absolute Error) yöntemleri uygulanarak hatalar hesaplanmıştır.


Tablo 3.7'de RMSE ve MAE yöntemlerine göre, küçük yolcu gemileri için en iyi 10 YSA sonucu sunulmuştur. RMSE ve MAE sonuçları, Denklem 3.1 ve 3.2' nin YSA modeli ile elde edilen tüm sonuçlara (270 test gemisinin sonuçları) uygulanmasıyla hesaplanmıştır.

Tablo 3.7 Küçük yolcu gemileri için en iyi YSA modelleri

Ağ Tipi	Aktivasyon Fonksiyonu	Eğitim Fonksiyonu	Öğrenme Fonksiyonu	Performans ve Hata Fonksiyonu	Nöron Sayısı	RMSE	MAE
FFB	LOGSIG-PURELIN	TRAINLM	LEARNGDM	MSE	12	0.04761	0.030945
CFB	LOGSIG-PURELIN	TRAINR	LEARNGDM	MSE	12	0.04999	0.036024
CFB	LOGSIG-TANSIG	TRAINBR	LEARNGD	SSE	10	0.05016	0.032717
CFB	LOGSIG-PURELIN	TRAINR	LEARNGD	MSE	8	0.05112	0.034006
FFB	LOGSIG-TANSIG	TRAINLM	LEARNGDM	MSE	12	0.05248	0.034917
FFB	LOGSIG-TANSIG	TRAINR	LEARNGDM	MSE	8	0.05429	0.037409
CFB	LOGSIG-PURELIN	TRAINR	LEARNGD	SSE	10	0.05458	0.037489
FFB	LOGSIG-PURELIN	TRAINR	LEARNGDM	SSE	12	0.05503	0.036908
CFB	LOGSIG-TANSIG	TRAINGDA	LEARNGD	MSE	12	0.05630	0.039349
CFB	LOGSIG-TANSIG	TRAINCGB	LEARNGD	SSE	10	0.05659	0.037293


Küçük yolcu gemilerinin seyrelme faktörü tahmini için en iyi RMSE ve MAE değerleri, FFB ağ tipi, LOGSIG-PURELIN (gizli katmandaki LOGSIG, çıkış katmanındaki PURELIN işlevi) aktivasyon fonksiyonu, TRAINLM eğitim fonksiyonu, LEARNGDM öğrenme fonksiyonu, MSE performans ve hata fonksiyonu ve 12 nöronla eğitilen YSA modelinden sırasıyla 0.04761 ve 0.030945 olarak elde edilmiştir.

Şekil 3.12 ve Şekil 3.13, en iyi YSA modeli için performans ve regresyon grafiklerini göstermektedir. Şekil 3.2, YSA modelinin toplam 9 iterasyon yaptığını ve 3. iterasyonda en iyi sonucu elde ettiğini göstermektedir. 3. iterasyondan sonra, model en iyi sonuca ulaştığında durmaya karar vermiştir. Bu, modelin 3. iterasyondan sonra kararlı hale geldiği anlamına gelmektedir.



Şekil 3.12 Küçük yolcu gemileri için en iyi YSA yönteminin performans grafiği

Şekil 3.13'e göre, eğitim, validasyon ve test süreçlerinde modelin ortalama başarı oranı 0.84581'dir. Şekil 3.13' te sistemin eğitim kısmının R değerinin 0.90696, validasyon kısmında R değerinin 0.78193 olduğu ve test kısmında R değerinin 0.62074 olduğu görülmektedir.



Şekil 3.13 Küçük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği

Tablo 3.8' de oluşturulan YSA modelinin ağırlık ve sapma değerleri verilmiştir.


Tablo 3.8 En iyi YSA yöntemine ait ağırlık ve sapmalar

Nöron (i)	GT	DWT	PASS	FRB	EP	PROP	CB	lw	b _i	b ₂
1	1.6543	2.423	0.91131	0.99262	1.0685	1.3022	1.6539	0.87736	-3.9583	-0.54059
2	2.4524	0.011304	1.5152	-0.96871	1.3936	-1.5686	-1.4261	-0.0127	-3.3884	
3	-1.2592	1.9023	1.4218	2.4176	-1.1605	0.17954	1.6585	0.79712	2.3704	
4	2.6349	-1.2118	-0.12627	-2.0835	0.80656	0.71501	-0.74158	1.0831	-2.265	
5	0.79269	-0.68831	1.0139	-0.5876	0.98537	2.9037	-2.1617	-0.07691	-0.95541	
6	-1.7902	1.7845	-1.4435	-0.56039	-1.5181	1.9074	-1.109	0.3633	0.39618	
7	-1.7389	1.6342	1.326	0.55982	-2.4704	-0.26403	0.9276;	-0.79762	-0.95089	
8	0.1319	2.2533	-2.4317	0.99315	0.18225	-1.7882	-0.13672	-0.14763	0.84996	
9	2.4723	0.87941	-0.64967	-1.1602	1.9031	-1.3375	-0.52571	0.75386	2.0183	
10	2.0099	-2.0073	-2.0377	0.083164	-0.67359	-1.1445	1.5247	-1.0668	2.5145	
11	-1.4134	2.4688	-1.9624	-0.15506	0.32734	1.3743	0.62127	0.19242	-3.4705	
12	2.0294	1.9082	1.4224	0.3465	-1.5777	-1.3466	0.2685	0.41485	4.1038	

Bölüm 3.1'de büyük yolcu gemilerinin seyrelme faktörünü hesaplariken kullanılan denklemlerde olduğu gibi, eğitilmiş YSA modelinin ağırlık ve sapma değerleri kullanılarak, seyrelme faktörünün normalize edilmiş değeri denklem 3.32' deki gibi [76] verilebilir. Burada yapılan işlem denklem 3.13' ten farklı olarak, Bölüm 2.2' de anlatıldığı üzere, FFB ağ tipinde girdi katmanından direkt çıktı katmanına bağlantı olmadığı için, girdi katmanında kullanılan 7 tane verinin tekrar ağırlıklarının hesaplanmamasıdır. Bu yüzden YSA tarafından tahmin edilen seyrelme faktörü aşağıdaki şekilde hesaplanır.

$$SF_{YSA} = (\sum_{i=1}^{12} \text{logsig}(u_i)lw_i) + b_2 \quad (3.32)$$

Burada, SF_{YSA} denklem 2.17' ye göre normalize edilmiş seyrelme faktörü değeridir. Yapay sinir ağlarına 7 tane girdi (GT, DWT, makine gücü, yolcu sayısı, pervane sayısı, blok katsayısı, freeboard) girilerek karşılığında çıktı olarak seyrelme faktörü elde edilmiştir. Şekil 3.14, tüm girdi değerleri için YSA tarafından tahmin edilen ve hesaplanan seyrelme faktörleri arasındaki ilişkiyi göstermektedir.



Şekil 3.14 Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT, DWT, PASS, FRB, EP, PROP, CB)$)

Yapay sinir ağlarına girdi olarak verilen değişkenlerin seyrelme faktörleri üzerindeki etki oranları Bölüm 3.1’de anlatıldığı gibi bir karar ağacı oluşturularak hesaplanmıştır. Tablo 3.9’ da görüldüğü gibi gros ton ve detveyt ton girdi değerleri seyrelme faktörlerini sırasıyla %56 ve %18 oranında etkilemiştir.

Tablo 3.9 YSA’ da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri

GT	DWT	EP	FRB	CB	PROP	PASS
%56	%18	%16	%5	%3	%1	%1


Gros ton ve detveyt ton dataları YSA sistemine ayrı ayrı ve beraber girilerek çıktı olarak seyrelme faktörü elde edilmiştir. Sadece gros ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(GT) \quad (3.33)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0778 \quad (3.34)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0450 \quad (3.35)$$

Şekil 3.15, YSA' nın sadece gros ton veri setiyle eğitildikten sonraki seyrelme faktörü tahminleriyle EPA formülasyonu (denklem 2.3) hesaplanan seyrelme faktörü değerlerinin karşılaştırılmasını göstermektedir.



Şekil 3.15 Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT)$)

Şekil 3.16, YSA' nın sadece detveyt ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.16 Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(DWT)$)


Sadece detveyt ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(DWT) \quad (3.36)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0929 \quad (3.37)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0512 \quad (3.38)$$

Şekil 3.17, YSA' nın detveyt ton ve gros ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.17 Hesaplanan ve gros ton – detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT, DWT)$)


Gros ton ve detveyt ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(GT, DWT) \quad (3.39)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0924 \quad (3.40)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0485 \quad (3.41)$$

Şekil 3.18, YSA' nın sadece makine gücü veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.18 Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(EP)$)

Sadece makine gücü verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(EP) \quad (3.39)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0681 \quad (3.40)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0483 \quad (3.41)$$


Sadece freeboard verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(FRB) \quad (3.42)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1038 \quad (3.43)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0655 \quad (3.44)$$

Şekil 3.19, YSA'nın sadece freeboard veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.19 Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(FRB)$)

Şekil 3.20, YSA'nın sadece blok katsayısı veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3. 20 Hesaplanan ve sadece blok katsayısı verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(CB)$)

Sadece blok katsayısı verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(CB) \quad (3.42)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1125 \quad (3.43)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0654 \quad (3.44)$$

Yukarıdaki grafiklerden ve karar ağacının sonuçlarından da (Tablo 3.9) görüleceği üzere küçük yolcu gemilerinin seyrelme faktörlerine en çok etki eden parametreler gros ton, detveyt ton ve makine gücüdür. Makine gücü dışındaki verilerin, karar ağacı sonuçlarında görülen etki oranları düştükçe RMSE ve MAE değerleri artmış ve R^2 değerleri ise azalmıştır. Tablo 3.7, küçük yolcu gemileri için YSA sonuçlarının RMSE ve MAE değerlerini göstermektedir. Tablo 3.6 ile kıyaslandığında küçük yolcu gemilerinin seyrelme faktörünün tahmin edilmesinde kullanılan YSA modelinin büyük yolcu gemilerinin seyrelme faktörünün tahmin edilmesinde kullanılan YSA modeli kadar başarılı olmadığı görülmektedir. Bu durum büyük ve küçük yolcu gemilerinin seyrelme faktörü hesabında kullanılan denklemlerdeki (denklem 2.2 ve denklem 2.3) katsayıların farklılığından ve büyük yolcu gemilerinin YSA modelinde kullanılan veri setinin (1041 gemi), küçük yolcu gemilerinin YSA modelinde kullanılan veri setinden (901 gemi) daha büyük olmasından kaynaklanmaktadır.

Tablo 3.10 YSA sonuçlarının RMSE ve MAE değerleri

	RMSE	MAE
Bütün Veri Seti Kullanıldığında	0.0476	0.0309
Sadece Gros Ton Veri Seti Kullanıldığında	0.0778	0.0450
Sadece Detveyt Ton Veri Seti Kullanıldığında	0.0929	0.0512
Gros Ton ve Detveyt Ton Veri Seti Birlikte Kullanıldığında	0.0924	0.0485
Sadece Makine Gücü Veri Seti Kullanıldığında	0.0681	0.0483
Sadece Freeboard Veri Seti Kullanıldığında	0.1038	0.0655
Sadece Blok Katsayısı Veri Seti Kullanıldığında	0.1125	0.0654

3.3 Büyük ve Küçük Yolcu Gemilerinin Seyrelme Faktörlerinin Tahmini

1041 tane büyük ve 901 tane küçük yolcu gemisinin gros ton, dedveyt ton, yolcu sayısı, freeboard, makine gücü, pervane sayısı, blok katsayısı değerlerinden oluşan data seti yapay sinir ağlarında 1942 x 7 matris oluşturularak kullanılmıştır. Veriler, büyük yolcu gemilerinin seyrelme faktörlerini hesaplanmasında olduğu gibi, tümü Tablo 3.1'de tanımlanan ağ tipleri, aktivasyon fonksiyonları, eğitim fonksiyonları, öğrenme fonksiyonları, performans ve hata fonksiyonları ve 3 farklı nöron numarasını içeren farklı YSA modelleri tarafından çalıştırılmıştır.

1942 geminin, 1360 tanesinin (% 70) verileri YSA modelini eğitmek için eğitim verisi olarak tanımlanmıştır. Sistemin eğitim performansını test etmek için kalan 582 geminin verileri (% 30) sisteme test verisi olarak tanımlanmıştır. Eğitim verisi olarak tanımlanan gemilerin seyrelme faktörleri EPA' nın seyrelme faktörü denklemine (denklem 2.2 ve 2.3) göre hesaplanarak, eğitim verilerinin çıktısı olarak tanımlanmıştır. Öğrenme işlemi tamamlandıktan sonra, test için ayrılan gemilerin verileri, YSA tarafından işlenerek bu gemilerin seyrelme faktörlerinin, EPA seyrelme faktörü formülasyonu tarafından hesaplanan seyrelme faktörü değerine ne kadar yaklaştığı hesaplanmıştır. Daha sonra, oluşturulan YSA modelinin sonuçlarını test etmek ve en iyi YSA modeline ulaşmak için tüm sonuçlara RMSE (Root Mean Square Error) ve MAE (Mean Absolute Error) yöntemleri uygulanarak hatalar hesaplanmıştır.

Tablo 3.11'de RMSE ve MAE yöntemlerine göre, büyük ve küçük yolcu gemileri için en iyi 10 YSA sonucu sunulmuştur. RMSE ve MAE sonuçları, Denklem 3.1 ve 3.2' nin YSA modeli ile elde edilen tüm sonuçlara (582 test gemisinin sonuçları) uygulanmasıyla hesaplanmıştır.


Büyük ve küçük yolcu gemilerinin seyrelme faktörleri tahmini için en iyi RMSE ve MAE değerleri, FFB ağ tipi, LOGSIG-PURELIN (gizli katmandaki LOGSIG, çıkış katmanındaki PURELIN fonksiyonu) aktivasyon fonksiyonu, TRAINBFG eğitim fonksiyonu, LEARNGD öğrenme fonksiyonu, SSE performans ve hata fonksiyonu ve

8 nöronla eğitilen YSA modelinden sırasıyla 0.03943 ve 0.02402 olarak elde edilmiştir.

Tablo 3.11 Büyük ve küçük yolcu gemileri için en iyi YSA modelleri


Ağ Tipi	Aktivasyon Fonksiyonu	Eğitim Fonksiyonu	Öğrenme Fonksiyonu	Performans ve Hata Fonksiyonu	Nöron Sayısı	RMSE	MAE
FFB	LOGSIG-PURELIN	TRAINBFG	LEARNGD	SSE	8	0.03943	0.02402
CFB	LOGSIG-PURELIN	TRAINLM	LEARNGDM	SSE	12	0.03971	0.023908
FFB	LOGSIG-TANSIG	TRAINBFG	LEARNGDM	SSE	12	0.04049	0.025368
FFB	LOGSIG-TANSIG	TRAINCGF	LEARNGD	SSE	10	0.04056	0.025813
CFB	LOGSIG-PURELIN	TRAINLM	LEARNGD	SSE	12	0.04153	0.02565
CFB	LOGSIG-PURELIN	TRAINBFG	LEARNGDM	MSE	10	0.04186	0.027004
FFB	LOGSIG-PURELIN	TRAINCGF	LEARNGD	SSE	12	0.04290	0.026436
FFB	LOGSIG-PURELIN	TRAINBFG	LEARNGD	MSE	8	0.04312	0.027416
FFB	LOGSIG-TANSIG	TRAINBFG	LEARNGD	MSE	10	0.04363	0.029772
FFB	LOGSIG-PURELIN	TRAINLM	LEARNGD	MSE	10	0.04411	0.025112

Şekil 3.21 ve Şekil 3.22, en iyi YSA modeli için performans ve regresyon grafiklerini göstermektedir. Şekil 3.21, YSA modelinin toplam 37 iterasyon yaptığını ve 31. iterasyonda en iyi sonucu elde ettiğini göstermektedir. 31. iterasyondan sonra, model en iyi sonuca ulaştığında durmaya karar vermiştir. Bu, modelin 31. iterasyondan sonra kararlı hale geldiği anlamına gelmektedir. Büyük ve küçük yolcu gemileri için ayrı ayrı yapılan performans grafikleriyle karşılaştırıldığında, veri sayısı arttıkça, öğrenme için yapılan iterasyon sayısı da artmıştır.



Şekil 3.21 Büyük ve küçük yolcu gemileri için en iyi YSA yönteminin performans grafiği

Şekil 3.22'ye göre, eğitim, validasyon ve test süreçlerinde modelin ortalama başarı oranı 0.97962'dir. Şekil 3.22' de sistemin eğitim kısmının R değerinin 0.96672, validasyon kısmında R değerinin 0.97962 olduğu ve test kısmında R değerinin 0.9845 olduğu görülmektedir.



Şekil 3.22 Büyük ve küçük yolcu gemileri için en iyi YSA yönteminin regresyon grafiği

Tablo 3.12' de oluşturulan YSA modelinin ağırlık ve sapma değerleri verilmiştir.


Tablo 3.12 En iyi YSA yöntemine ait ağırlık ve sapmalar

Nöron (i)	GT	DWT	PASS	FRB	EP	PROP	CB	b_i	b_2
1	1.9099	1.5106	-0.78458	1.3037	-1.1158	-0.15389	1.0021	-3.7116	-0.89399
2	1.395	1.5219	1.604	1.3353	-2.1471	-0.28647	0.79193	-3.3973	
3	3.5925	-0.43642	2.278	-1.4342	3.0235	-0.45652	-1.5075	0.44855	
4	-0.40711	5.2999	-0.21439	2.7338	-0.97562	2.1875	-1.9895	-5.4064	
5	4.4688	3.0997	0.36832	-0.02139	1.9676	-0.00653	0.045175	9.2257	
6	0.4997	2.5708	-0.19884	2.0679	0.38383	-0.97283	0.66856	-6.4516	
7	-0.36131	0.58016	1.4704	1.5167	2.2949	0.35765	-1.7642	-2.6798	
8	-0.10367	-1.9643	1.6572	-0.64429	-1.7538	0.55976	-0.00647	4.2217	

Bölüm 3.2’de küyük yolcu gemilerinin seyrelme faktörünü hesaplamak için kullanılan denklemlerde olduğu gibi, eğitilmiş YSA modelinin ağırlık ve sapma değerleri kullanılarak, seyrelme faktörünün normalize edilmiş değeri denklem 3.45’ teki gibi verilebilir [76].


$$SF_{YSA} = (\sum_{i=1}^8 \text{logsig}(u_i)lw_i) + b_2 \quad (3.45)$$

Burada, SF_{YSA} denklem 2.17’ ye göre normalize edilmiş seyrelme faktörü değeridir. Yapay sinir ağlarına 7 tane girdi (GT, DWT, makine gücü, yolcu sayısı, pervane sayısı, blok katsayısı, freeboard) girilerek karşılığında çıktı olarak seyrelme faktörü elde edilmiştir. Şekil 3.23, YSA tarafından tahmin edilen ve EPA tarafından hesaplanan seyrelme faktörü değerlerini, gemilerin gros ton büyüklüklerinin değişimine göre ayrı ayrı göstermektedir.



Şekil 3. 23 YSA tarafından tahmin edilen ve EPA formülüyle hesaplanan seyrelme faktörü değerlerinin gemi gros tonuna göre değişimi

Şekil 3.24, tüm girdi değerleri için YSA tarafından tahmin edilen ve hesaplanan seyrelme faktörleri arasındaki ilişkiyi göstermektedir.



Şekil 3.24 Bütün girdi değerleri için hesaplanan ve tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT, DWT, PASS, FRB, EP, PROP, CB)$)

Yapay sinir ağlarına girdi olarak verilen değişkenlerin büyük ve küçük yolcu gemilerinin seyrelme faktörleri üzerindeki etki oranları Bölüm 3.1 ve 3.2’de anlatıldığı gibi bir karar ağacı oluşturularak hesaplanmıştır. Tablo 3.13’ te görüldüğü gibi makine gücü ve gros ton girdi değerleri seyrelme faktörlerini sırasıyla %28 ve %27 oranında etki eden en önemli iki parametre olarak bulunmuştur.

Tablo 3.13 YSA’ da kullanılan girdilerin seyrelme faktörü üzerindeki etkileri

EP	GT	DWT	PASS	FRB	CB	PROP
%28	%27	%19	%14	%11	%1	%1


Makine gücü ve gros ton dataları YSA sistemine ayrı ayrı ve beraber girilerek çıktı olarak seyrelme faktörü elde edilmiştir. Sadece makine gücü verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(EP) \quad (3.46)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0566 \quad (3.47)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0334 \quad (3.48)$$

Şekil 3.25, YSA' nın sadece makine gücü veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.25 Hesaplanan ve sadece makine gücü verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(EP)$)


Sadece gros ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(GT) \quad (3.49)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0544 \quad (3.50)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0333 \quad (3.51)$$

Şekil 3.26, YSA' nın sadece gros ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.26 Hesaplanan ve sadece gros ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(GT)$)


Makine gücü ve gros ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(EP, GT) \quad (3.52)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0457 \quad (3.53)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0290 \quad (3.54)$$

Şekil 3.27, YSA' nın makine gücü ve gros ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.27 Hesaplanan ve makine gücü – gros ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(EP, GT)$)

Şekil 3.28, YSA' nın sadece dedveyt ton veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.28 Hesaplanan ve sadece detveyt ton verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(DWT)$)


Sadece dedveyt ton verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(DWT) \quad (3.55)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0844 \quad (3.56)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0518 \quad (3.57)$$

Şekil 3.29, YSA' nın sadece yolcu sayısı veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.29 Hesaplanan ve sadece yolcu sayısı verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(PASS)$)


Sadece yolcu sayısı verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(PASS) \quad (3.55)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.0972 \quad (3.56)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0704 \quad (3.57)$$

Şekil 3.30, YSA' nın sadece freeboard veri serileri ile eğitildiği seyrelme faktörleri ile EPA formülü tarafından hesaplanan seyrelme faktörü arasındaki ilişkiyi göstermektedir.



Şekil 3.30 Hesaplanan ve sadece freeboard verileriyle tahmin edilen seyrelme faktörleri ($SF_{YSA} = f(FRB)$)

Sadece freeboard verilerine bağlı olarak seyrelme faktörünün tahmininin hata analizi denklem 3.1 ve 3.2 kullanılarak aşağıdaki gibi hesaplanmıştır.

$$SF_{YSA} = f(FRB) \quad (3.58)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SF_{EPA_i} - SF_{YSA_i})^2}{n}} = 0.1248 \quad (3.59)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |SF_{EPA_i} - SF_{YSA_i}| = 0.0925 \quad (3.60)$$

Yukarıda verilen grafiklerden de görüldüğü gibi, seyrelme faktörünü hesaplamak için YSA'ya tanıtılan girdilerin, karar ağacından elde edilen seyrelme faktörlerine etki oranı azaldıkça R^2 , değerleri azalmış ve RMSE ve MAE değerleri de artmıştır. Bu durum da hata oranlarının arttığını göstermektedir. Bu sonuç karar ağacının doğru çalıştığını ve büyük ve küçük yolcu gemilerinin seyrelme faktörüne etki eden en önemli parametrelerin makine gücü ve/veya gros ton değerlerinin olduğunu desteklemektedir.

Tablo 3.14 YSA sonuçlarının RMSE ve MAE değerlerini göstermektedir. Tablo 3.6'da verilen sonuçlar, YSA'nın, gemi henüz ön dizayn aşamasındayken bir geminin seyrelme faktörünü gemi gros tonu ve/veya makine gücü verisiyle kabul edilebilir bir hata ile tahmin etmek için yeterli olduğunu göstermektedir. Tablo 3.6, 3.10 ve 3.14' teki RMSE ve MAE sonuçları incelendiğinde büyük yolcu gemileri ve küçük

yolcu gemilerinin seyrelme faktörlerinin tahmini YSA'da ayrı ayrı yapıldığında, büyük ve küçük yolcu gemilerinin veri setlerinin birarada YSA'da model oluşturulup tahmin edilmesi kadar başarılı olmadığı görülmektedir. Bunun en önemli sebebi, veri setleri birarada kullanıldığında toplam 1942 tane geminin veri setinin ayrı ayrı model oluşturulduğundaki veri setinden daha fazla olmasıdır. Böylelikle YSA daha iyi bir öğrenme gerçekleştirerek, hesaplanan seyrelme faktörleri (Denklem 2.2 ve Denklem 2.3) değerlerine daha çok yaklaşabilmiş ve hata oranı daha az olmuştur.

Tablo 3.14 YSA sonuçlarının RMSE ve MAE değerleri

	RMSE	MAE
Bütün Veri Seti Kullanıldığında	0.0394	0.0240
Sadece Makine Gücü Veri Seti Kullanıldığında	0.0566	0.0334
Sadece Gros Ton Veri Seti Kullanıldığında	0.0544	0.0333
Makine Gücü ve Gros Ton Veri Seti Birlikte Kullanıldığında	0.0457	0.0290
Sadece Detveyt Ton Veri Seti Kullanıldığında	0.0844	0.0518
Sadece Yolcu Sayısı Veri Seti Kullanıldığında	0.0972	0.0704
Sadece Freeboard Veri Seti Kullanıldığında	0.1248	0.0925

Yolcu gemileri denizlerdeki başlıca atık su üreticisidir. Özellikle daha büyük kapasiteye sahip gemilerin deniz çevresi üzerinde ciddi olumsuz etkileri vardır. Gemi kaynaklı atık su, deniz ortamında yüksek düzeyde kirlilik oluşturan organik madde, besinler, askıda katı maddeler ve koliformlar gibi kirlletici konsantrasyonlarına sahiptir. Kirlilik seviyesinin zamanla artması deniz ve okyanus ekolojisi için tehdit oluşturmaktadır. Gemi kaynaklı atık su ile ilgili literatürde çok fazla çalışma bulunmamaktadır. Okyanus ve denizlerin geleceği için daha ileri çalışmalar çok önemlidir.

Bu tez çalışması 1041 tane büyük ve 901 tane küçük yolcu gemisinin verileri kullanılarak yapılmıştır. Bu gemiler şu anda dünyada aktif olan yolcu gemilerinin önemli bir kısmıdır. Bu çalışmanın başlangıcında gemilerin seyrelme faktörleri EPA formülasyonu kullanılarak hesaplanmıştır. Bu hesaplama yönteminde, kullanılan parametreler gemilerin genişliği (m), draftı (m), hızı (m/s) ve atık suyun boşaltım debisi (m^3/s) 'dir. EPA formülasyonu ile hesaplanan bu seyrelme faktörleri gerçek değerler olarak kabul edilmiştir. Daha sonra makine güçleri, gros ton, detveyt ton, freeboard değerleri, pervane sayıları, blok katsayıları ve yolcu sayıları YSA modeline girdi olarak verilmiştir.


Büyük yolcu gemileri için 1041 tane geminin 729 tanesinin (% 70), küçük yolcu gemileri için 901 tane geminin 631 tanesinin (%70), büyük ve küçük yolcu gemileri için 1942 tane geminin 1360 tanesinin (%70) verileri YSA modelini eğitmek için eğitim verisi olarak tanımlanmıştır. Sistemin eğitim performansını test etmek için büyük yolcu gemileri için 312 geminin (%30), küçük yolcu gemileri için 270 geminin (%30), büyük ve küçük yolcu gemileri için 582 geminin (% 30) verileri sisteme test verisi olarak tanımlanmıştır. Seyrelme faktörleri YSA yöntemi ile bu yeni parametrelere göre çıktılar olarak hesaplanmıştır. Elde edilen bu değerler EPA'nın formülüne göre hesaplanan seyrelme faktörü değerleriyle karşılaştırılarak en iyi YSA modeli belirlenmiştir. Bu modelden alınan sonuçlar R dilinde CART algoritması

kullanılarak, RPART kütüphanesi kaynaklı bir kod yazılarak oluşturulan karar ağacında incelenmiş ve seyrelme faktörüne etki eden en önemli parametreler büyük yolcu gemileri, küçük yolcu gemileri, büyük ve küçük yolcu gemileri için ayrı ayrı belirlenmiştir. RMSE ve MAE performans analizlerinin sonuçları YSA'nın kabul edilebilir bir hatayla gemilerin seyrelme faktörlerini tahmin etmek için yeterli olduğunu göstermektedir.

Çalışma sonucunda büyük yolcu gemileri için makine gücü (%37) ve gros ton (%29), küçük yolcu gemileri için gros ton (%56) ve dedveyt ton (%18), büyük ve küçük yolcu gemileri için makine gücü (%28) ve gros ton (%27) seyrelme faktörünü etkileyen en önemli iki parametre olarak bulunmuştur. RMSE ve MAE sonuçları incelendiğinde büyük yolcu gemileri ve küçük yolcu gemilerinin seyrelme faktörlerinin tahmini YSA'da ayrı ayrı yapıldığında, büyük ve küçük yolcu gemilerinin veri setlerinin birarada oluşturularak YSA'da model oluşturulup tahmin edilmesi kadar başarılı olmadığı görülmektedir. Aynı durum büyük yolcu gemilerinin seyrelme faktörlerinin tahmin edilmesi için oluşturulan YSA modeli ile küçük yolcu gemilerinin seyrelme faktörlerinin tahmin edilmesi için oluşturulan YSA modeli arasında da görülmüştür. Bunun en önemli sebebi, veri setleri birarada kullanıldığında toplam 1942 tane geminin veri setinin ayrı ayrı model oluşturulduğundaki veri setinden daha fazla olmasıdır. Böylelikle YSA daha iyi bir öğrenme gerçekleştirerek, hesaplanan seyrelme faktörleri değerlerine daha çok yaklaşabilmiş ve hata oranı daha az olmuştur. Bu tez çalışmasında elde edilen sonuçlara göre, büyük ve küçük yolcu gemileri için FFB ağ tipi, LOGSIG-PURELIN (gizli katmandaki LOGSIG, çıkış katmanındaki PURELIN işlevi) aktivasyon fonksiyonu, TRAINBFG eğitim fonksiyonu, LEARNGD öğrenme fonksiyonu, SSE performans ve hata fonksiyonu ve 8 nöronla oluşturulan YSA modeli kullanılarak, büyük ve/veya küçük yolcu gemilerinin seyrelme faktörleri küçük bir hata oranıyla tespit edilebilmektedir.

RMSE ve MAE performans analizlerinin sonuçları, sadece makine gücü, sadece gros ton ve makine gücü – gros ton değerleriyle oluşturulan YSA modelinin, seyrelme faktörünü kabul edilebilir bir hatayla tahmin etmek için yeterli olduğunu göstermektedir.

Büyük ve küçük yolcu gemileri için yolcu sayısının seyrelme faktörü değeri üzerindeki etkisi %12 olarak saptanmıştır. Bu sonuca göre yolcu sayısı arttıkça her ne kadar atık su miktarı artsa da sonuç olarak seyrelme miktarı büyük oranda değişmeyecektir. Yolcu sayıları eşit olan iki gemiden, makine gücü ve gros ton değeri fazla olan gemi daha büyük seyrelme faktörüne sahip olacaktır. Gemi freeboard, blok katsayısı ve pervane sayısının büyük ve küçük yolcu gemilerinin seyrelme faktörüne etkisi sırasıyla %11, %1 ve %1 olarak belirlenmiştir. Bu değerlerin seyrelme faktörüne etkilerinin az olması, normalizasyon değerlerindeki değişim aralıklarının az olmasından kaynaklandığı düşünülmektedir. Makine gücü ve gros ton değerlerinin tek başlarına ya da her ikisinin seyrelme miktarını tahmin etmede başarılı olduğu görülmektedir.



Şekil 4.1 Gemi dizayn spirali

Bu çalışmanın sonuçlarına göre, gemi ön dizayn aşamasındayken, Şekil 4.1'deki [84] gemi dizayn spiralinin en başında yer alan, geminin tonaj değerleri biliniyorsa, gemi tarafından yapılacak atıksuyun seyreltilmesi belirli bir hata ile tahmin edilebilmektedir. EPA'nın seyrelme faktörü formülasyonu için geminin ana boyutları gereklidir, ancak bu çalışmada oluşturulan modelde seyrelmeyi tahmin etmek için sadece geminin grostonu ve / veya motor gücü yeterlidir. Ayrıca bu yeni model, geminin ana boyutları bilinmese bile seyrelme faktörlerinin tahmini için de kullanılabilir. Böylece, deşarj sonrası atıksuyun MARPOL ve EPA standartlarını karşılayıp karşılamayacağı hakkında bir fikre sahip olmak mümkündür.

-
- [1] H. Jennings, K. Ulrik, ve P. Bishop, "Tourism Concern Research Briefing Cruise Tourism – what's below the surface?," 2016.
- [2] MARPOL Annex IV, "Regulations for the Prevention of Pollution by Sewage from Ships" <http://www.imo.org/en/OurWork/Environment/PollutionPrevention/Sewage/Pages/Default.aspx>. [Erişim tarihi: 03.02.2020]
- [3] U.S. Environmental Protection Agency, "Cruise Ship Discharge Assessment Report," 2008.
- [4] US Environmental Protection Agency, "Generic Sampling and Analysis Plan for Large Cruise Ships in Alaska Waters," 2004.
- [5] H. A. Keskin, "Gemilerden Kaynaklanan Atıkların Kontrolü Kapsamında Liman Atık Kabul Tesisi ve Ambarlı Limanı Örneği," İstanbul Teknik Üniversitesi, 2006.
- [6] T. C. Stevenson, J. Davies, H. P. Huntington, ve W. Sheard, "An examination of trans-Arctic vessel routing in the Central Arctic Ocean," *Marine Policy*, c. 100, ss. 83–89, 2019, doi: 10.1016/j.marpol.2018.11.031.
- [7] V. Şahin, "Yolcu Gemisi Kaynaklı Kanalizasyon Atıklarının Gemi Formu ve Sistemlerine Bağlı Olarak Tahmini," Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, 2015.
- [8] V. Şahin ve N. Vardar, "Sewage Treatment Systems of Cruise Ships and The Parameters Affect on Dilution of Effluent at Sea," *Journal of Maritime and Marine Sciences*, c. 1, ss. 25–31, 2015.
- [9] L. Westhof, S. Köster, ve M. Reich, "Occurrence of micropollutants in the wastewater streams of cruise ships," *Emerging Contaminants*, c. 2, sy. 4, ss. 178–184, 2016, doi: 10.1016/j.emcon.2016.10.001.
- [10] M. Gibson, A. J. Murphy, ve K. Pazouki, "Evaluation of environmental performance indices for ships," *Transportation Research Part D: Transport and Environment*, c. 73, ss. 152–161, 2019, doi: 10.1016/j.trd.2019.07.002.
- [11] M. Wilewska-Bien ve S. Anderberg, "Reception of sewage in the Baltic Sea – The port's role in the sustainable management of ship wastes," *Marine Policy*, c. 93, ss. 207–213, Nis. 2018, doi: 10.1016/j.marpol.2018.04.012.
- [12] G. Wang, K. X. Li, ve Y. Xiao, "Measuring marine environmental efficiency of a cruise shipping company considering corporate social responsibility," *Marine Policy*, c. 99, ss. 140–147, Oca. 2019, doi: 10.1016/j.marpol.2018.10.028.
- [13] H. Backer, "Regional work on prevention of pollution from ships in the Baltic Sea – A Paradox Or A Global Forerunner?," *Marine Policy*, c. 98, ss. 255–263,

- Ara. 2018, doi: 10.1016/j.marpol.2018.09.022.
- [14] M. Wilewska-Bien, L. Granhag, ve K. Andersson, "The nutrient load from food waste generated onboard ships in the Baltic Sea," *Marine Pollution Bulletin*, c. 105, sy. 1, ss. 359–366, 2016, doi: 10.1016/j.marpolbul.2016.03.002.
 - [15] G. H. Jirka, "Integral Model for Turbulent Buoyant Jets in Unbounded Stratified Flows Part 2: Plane Jet Dynamics Resulting from Multiport Diffuser Jets," *Environmental Fluid Mechanics*, c. 6, ss. 43–100, 2006, doi: 10.1007/s10652-005-4656-0.
 - [16] L. Zhao, Z. Chen, ve K. Lee, "Modelling the dispersion of wastewater discharges from offshore outfalls: A review," *Environmental Reviews*, c. 19, sy. 1, ss. 107–120, 2011, doi: 10.1139/A10-025.
 - [17] J. L. Martin, S. C. McCutcheon, ve R. W. Schottman, *Hydrodynamics and Transport for Water Quality Modeling*. CRC Press, 2018.
 - [18] L. R. Davis, "Fundamentals of Environmental Discharge Modeling," CRC Press, Boca Raton, 1999, doi: 10.1201/9780203755310.
 - [19] M. Mestres Ridge, "Three-dimensional simulation of pollutant dispersion in coastal waters," Departament d'Enginyeria Hidràulica ,Universitat Politècnica de Catalunya, 2002.
 - [20] G. H. Jirka, "Multiport Diffusers For Heat Disposal - A Summary," *Journal of the Boston Society of Civil Engineers Section, American Society of Civil Engineers*, c. 68, sy. 1, 1982.
 - [21] T. Bleninger ve G. Jirka, "Near- and far-field model coupling methodology for wastewater discharges," *Environmental Hydraulics and Sustainable Water Management*, ss. 447–453, Ara. 2004, doi: 10.1201/b16814-73.
 - [22] Science Advisory Panel and Alaska Department of Environmental Conservation, "The impact of cruise ship wastewater discharge on Alaska Waters," 2002.
 - [23] Alaska Department of Environmental Conservation, "Assessment of the Stationary Cruise Ship Plume Dilution Study," 2009.
 - [24] United States Environmental Protection Agency, "Cruise Ship Plume Tracking Survey Report," 2002.
 - [25] U.S. Environmental Protection Agency, "Sampling Episode Report Cruise Ship Plume Dilution Study," Skagway, Alaska.
 - [26] Alaska Department of Environmental Conservation, "Assessment of cruise ship and ferry wastewater impacts in Alaska," 2004.
 - [27] J. G. Speight, *Reaction Mechanisms in Environmental Engineering: Analysis and Prediction*, 2018.
 - [28] E. Heinen, K. Potts, L. Snow, W. Trulli, ve D. Redford, "Dilution of Wastewater Discharges from Moving Cruise Ships," ss. 386–389, 2003.
 - [29] L. C. Loehr, M. Atkinson, ve K. George, "Using a Simple Dilution Model to Estimate Wastewater Contaminant Concentrations Behind Moving Passenger

- Vessels," *Oceans*, c. 1, ss. 390–393, 2003.
- [30] L. C. Loehr, C. Beegle-krause, K. George, C. D. Mcgee, A. J. Mearns, ve M. J. Atkinson, "The Significance of Dilution in Evaluating Possible Impacts of Wastewater Discharges From Large Cruise Ships," c. 52, ss. 681–688, 2006, doi: 10.1016/j.marpolbul.2005.10.021.
- [31] E. Öztemel, *Yapay Sinir Ağları*. İstanbul,Türkiye: Papatya Yayıncılık, 2003.
- [32] L. Bilgili, "Gemilerin Değişken Deniz ve Operasyon Koşullarında Gaz Emisyonlarının Farklı Makine Öğrenmesi Yöntemleriyle Tahmini ve Yaşam Döngüsü İçinde Değerlendirilmesi," Doktora Tezi, Yıldız Teknik Üniversitesi, 2018.
- [33] A. C. Yazıcı, E. Ögüş, S. Ankaralı, S. Canan, H. Ankaralı, ve Z. Akkuş, "Yapay Sinir Ağlarına Genel Bakış," *Türkiye Klinikleri Tıp Bilimleri Dergisi*, c. 27, sy. 1, ss. 65–71, 2007.
- [34] S. A. Kalogirou, "Applications of artificial neural-networks for energy systems," *Applied Energy*, c. 67, sy. 1–2, ss. 17–35, 2000, doi: 10.1016/S0306-2619(00)00005-2.
- [35] S. Venkatramanan, S. Y. Chung, S. Selvam, J. H. Son, ve Y. J. Kim, "Interrelationship between geochemical elements of sediment and groundwater at Samrak Park Delta of Nakdong River Basin in Korea: multivariate statistical analyses and artificial neural network approaches," *Environmental Earth Sciences*, c. 76, sy. 13, ss. 1–12, 2017, doi: 10.1007/s12665-017-6795-2.
- [36] J. Mubiru, "Using Artificial Neural Networks to Predict Direct Solar Irradiation," *Advances in Artificial Neural Systems*, ss. 1–6, 2011, doi: 10.1155/2011/142054.
- [37] S. Amely Jumaat, F. Crocker, M. Helmy Abd Wahab, N. Hanis Mohammad Radzi, ve M. Fakri Othman, "Prediction of Photovoltaic (PV) Output Using Artificial Neural Network (ANN) Based on Ambient Factors," *Journal of Physics: Conference Series*, c. 1049, sy. 1, 2018, doi: 10.1088/1742-6596/1049/1/012088.
- [38] A. A. M. Ahmed, "Prediction of dissolved oxygen in Surma River by biochemical oxygen demand and chemical oxygen demand using the artificial neural networks (ANNs)," *Journal of King Saud University - Engineering Sciences*, 2017, doi: 10.1016/j.jksues.2014.05.001.
- [39] K. P. Singh, A. Basant, A. Malik, ve G. Jain, "Artificial neural network modeling of the river water quality-A case study," *Ecological Modelling*, c. 220, sy. 6, ss. 888–895, 2009, doi: 10.1016/j.ecolmodel.2009.01.004.
- [40] D. Hanbay, I. Turkoglu, ve Y. Demir, "Prediction of wastewater treatment plant performance based on wavelet packet decomposition and neural networks," *Expert Systems with Applications*, c. 34, sy. 2, ss. 1038–1043, 2008, doi: 10.1016/j.eswa.2006.10.030.
- [41] L. E. Keiner ve X. H. Yan, "A neural network model for estimating sea surface

- chlorophyll and sediments from thematic mapper imagery," *Remote Sensing of Environment*, c. 66, sy. 2, ss. 153–165, 1998, doi: 10.1016/S0034-4257(98)00054-6.
- [42] Panda, S.S., Garg, V., ve Chaubey I., "Artificial Neural Networks Application in Lake Water Quality Estimation Using Satellite Imagery," *Journal of Environmental Informatics*, c. 4, sy. 2, ss. 65–74, 2004, doi: 10.3808/jei.200400038.
- [43] H. Z. Abyaneh, "Evaluation of multivariate linear regression and artificial neural networks in prediction of water quality parameters," *Journal of Environmental Health Science and Engineering*, c. 12, sy. 1, ss. 6–13, 2014, doi: 10.1186/2052-336X-12-40.
- [44] H. Elhatip ve M. A. Kömür, "Evaluation of water quality parameters for the Mamasin dam in Aksaray City in the central Anatolian part of Turkey by means of artificial neural networks," *Environmental Geology*, c. 53, sy. 6, ss. 1157–1164, 2008, doi: 10.1007/s00254-007-0705-y.
- [45] V. Ranković, J. Radulović, I. Radojević, A. Ostojić, ve L. Čomić, "Neural network modeling of dissolved oxygen in the Gruža reservoir, Serbia," *Ecological Modelling*, c. 221, sy. 8, ss. 1239–1244, 2010, doi: 10.1016/j.ecolmodel.2009.12.023.
- [46] A. Saber, D. E. James, ve D. F. Hayes, "Estimation of water quality profiles in deep lakes based on easily measurable constituents at the water surface using artificial neural networks coupled with stationary wavelet transform," *Science of the Total Environment*, c. 694, Ara. 2019, doi: 10.1016/j.scitotenv.2019.133690.
- [47] A. Sarkar ve P. Pandey, "River Water Quality Modelling Using Artificial Neural Network Technique," *Aquatic Procedia*, c. 4, ss. 1070–1077, 2015, doi: 10.1016/j.aqpro.2015.02.135.
- [48] S. Goyal ve G. K. Goyal, "Cascade and Feedforward Backpropagation Artificial Neural Network Models For Prediction of Sensory Quality of Instant Coffee Flavoured Sterilized Drink," *Canadian Journal on Artificial Intelligence Machine Learning and Pattern Recognition*, c. 2, sy. 6, ss. 78–82, 2011.
- [49] "Feedforward neural network - MATLAB feedforwardnet." <https://www.mathworks.com/help/deeplearning/ref/feedforwardnet.html>. [Erişim tarihi: 07.02.2020].
- [50] "Cascade-forward neural network - MATLAB cascadeforwardnet." <https://www.mathworks.com/help/deeplearning/ref/cascadeforwardnet.html>. [Erişim tarihi: 07.02.2020].
- [51] "Gradient descent weight and bias learning function - MATLAB learnngd." https://www.mathworks.com/help/deeplearning/ref/learnngd.html?s_tid=doc_ta. [Erişim tarihi: 07.02.2020].
- [52] "Gradient descent with momentum weight and bias learning function - MATLAB learnngdm." https://www.mathworks.com/help/deeplearning/ref/learnngdm.html?s_tid

- =doc_ta. [Erişim tarihi: 07.02.2020].
- [53] "BFGS quasi-Newton backpropagation - MATLAB trainbfg." <https://www.mathworks.com/help/deeplearning/ref/trainbfg.html>. [Erişim tarihi: 07.02.2020].
- [54] "Bayesian regularization backpropagation - MATLAB trainbr." https://www.mathworks.com/help/deeplearning/ref/trainbr.html?s_tid=doc_ta. [Erişim tarihi: 07.02.2020].
- [55] "Conjugate gradient backpropagation with Powell-Beale restarts - MATLAB traincgb." https://www.mathworks.com/help/deeplearning/ref/traincgb.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [56] "Conjugate gradient backpropagation with Fletcher-Reeves updates - MATLAB traincgf." https://www.mathworks.com/help/deeplearning/ref/traincgf.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [57] "Conjugate gradient backpropagation with Polak-Ribière updates - MATLAB traincgp." https://www.mathworks.com/help/deeplearning/ref/traincgp.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [58] "Gradient descent backpropagation - MATLAB traingd." https://www.mathworks.com/help/deeplearning/ref/traingd.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [59] "Gradient descent with momentum backpropagation - MATLAB traingdm." https://www.mathworks.com/help/deeplearning/ref/traingdm.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [60] "Gradient descent with adaptive learning rate backpropagation - MATLAB traingda." https://www.mathworks.com/help/deeplearning/ref/traingda.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [61] "Gradient descent with momentum and adaptive learning rate backpropagation - MATLAB traingdx." https://www.mathworks.com/help/deeplearning/ref/traingdx.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [62] "Levenberg-Marquardt backpropagation - MATLAB trainlm." https://www.mathworks.com/help/deeplearning/ref/trainlm.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [63] "One-step secant backpropagation - MATLAB trainoss." https://www.mathworks.com/help/deeplearning/ref/trainoss.html?s_tid=doc_ta. [Erişim tarihi: 08.02.2020].
- [64] "Random order incremental training with learning functions - MATLAB trainr." https://www.mathworks.com/help/deeplearning/ref/trainr.html?s_tid=doc

- _ta. [Eriřim tarihi: 08.02.2020].
- [65] “Resilient backpropagation - MATLAB trainrp.” https://www.mathworks.com/help/deeplearning/ref/trainrp.html?s_tid=doc_ta. [Eriřim tarihi: 08.02.2020].
- [66] “Scaled conjugate gradient backpropagation - MATLAB trainscg.” https://www.mathworks.com/help/deeplearning/ref/trainscg.html?s_tid=doc_ta. [Eriřim tarihi: 08.02.2020].
- [67] “Mean squared normalized error performance function - MATLAB mse.” https://www.mathworks.com/help/deeplearning/ref/mse.html?s_tid=doc_ta. [Eriřim tarihi: 09.02.2020].
- [68] “Sum squared error performance function - MATLAB sse.” https://www.mathworks.com/help/deeplearning/ref/sse.html?s_tid=doc_ta. [Eriřim tarihi: 09.02.2020].
- [69] M. Tahani, M. Vakili, ve S. Khosrojerdi, “Experimental evaluation and ANN modeling of thermal conductivity of graphene oxide nanoplatelets/deionized water nanofluid,” *International Communications in Heat and Mass Transfer*, c. 76, ss. 358–365, 2016, doi: 10.1016/j.icheatmasstransfer.2016.06.003.
- [70] K. Chiteka ve C. C. Enweremadu, “Prediction of global horizontal solar irradiance in Zimbabwe using artificial neural networks,” *Journal of Cleaner Production*, c. 135, ss. 701–711, 2016, doi: 10.1016/j.jclepro.2016.06.128.
- [71] P. Jain ve M. C. Deo, “Neural networks in ocean engineering,” *Ships and Offshore Structures*, c. 1, sy. 1, ss. 25–35, 2006, doi: 10.1533/saos.2004.0005.
- [72] “Log-sigmoid transfer function - MATLAB logsig.” https://www.mathworks.com/help/deeplearning/ref/logsig.html?s_tid=doc_ta. [Eriřim tarihi: 09.02.2020].
- [73] “Hyperbolic tangent sigmoid transfer function - MATLAB tansig.” https://www.mathworks.com/help/deeplearning/ref/tansig.html?s_tid=doc_ta. [Eriřim tarihi: 09.02.2020].
- [74] “Linear transfer function - MATLAB purelin.” https://www.mathworks.com/help/deeplearning/ref/purelin.html?s_tid=doc_ta. [Eriřim tarihi: 09.02.2020].
- [75] R. C. Deo, X. Wen, ve F. Qi, “A wavelet-coupled support vector machine model for forecasting global incident solar radiation using limited meteorological dataset,” *Applied Energy*, vol. 168, pp. 568–593, 2016, doi: 10.1016/j.apenergy.2016.01.130.
- [76] E. Bal Beřikçi, O. Arslan, O. Turan, ve A. I. Ölçer, “An artificial neural network based decision support system for energy efficient ship operations,” *Computers and Operations Research*, c. 66, ss. 393–401, 2016, doi: 10.1016/j.cor.2015.04.004.
- [77] T. Chai ve R. R. Draxler, “Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature,” *Geoscientific Model Development*, c. 7, sy. 3, ss. 1247–1250, 2014, doi:

10.5194/gmd-7-1247-2014.

- [78] M. Udovičić, K. Baždarić, L. Bilić-Zulle, ve M. Petrovečki, "What we need to know when calculating the coefficient of correlation?," *Biochemia Medica*, c. 17, sy. 1, ss. 10–15, 2007.
- [79] N. J. D. Nagelkerke, "A Note on a General Definition of the Coefficient of Determination," 1991.
- [80] R Development Core Team 3.0.1., "A Language and Environment for Statistical Computing," 2019.
- [81] E. J. Atkinson ve T. M. Therneau, "An Introduction to Recursive Partitioning Using the RPART Routines," *Mayo Clinic Section Biostatistics Technical Report*, Nis. 2019.
- [82] M. Edali ve G. Yücel, "Automated analysis of regularities between model parameters and output using support vector regression in conjunction with decision trees," *Jasss*, c. 21, sy. 4, 2018, doi: 10.18564/jasss.3786.
- [83] W. Y. Loh, "Classification and regression trees," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, c. 1, sy. 1, ss. 14–23, 2011, doi: 10.1002/widm.8.
- [84] C. Aksu, "Gemi Dizaynında Optimizasyon ve Uygulama Örneği," Yüksek Lisans Tezi, Balıkesir Üniversitesi, 2013.

```
install.packages("rpart")
install.packages("rpart.plot")
install.packages("rattle")
library(rpart)
library(rpart.plot)
library(rattle)

read.excel <- function(header=TRUE,...)
{read.table("clipboard",sep="\t",header=header,...)}

tr = read.excel()

***

tree = rpart(YSASF ~ GT + DWT + PASS + FRB + EP + PROP + CB, data = tr)
summary(tree)
prp(tree)
leaves = as.numeric(row.names(tree$frame)[tree$where])
forplot = NULL
for (i in unique(leaves)){
  print(i)
  out = tr[which(leaves == i), "SF"]
  forplot = rbind(forplot, cbind(rep(i, length(out)), out))}

forplot = as.data.frame(forplot)
```

```
colnames(forplot) = c("ID", "Value")
```

```
x11()
```

```
boxplot(forplot$Value ~ forplot$ID, xlab = "Decision Rule Number", ylab =  
"Output")
```

```
asRules(tree)
```

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgisi: volkansahin0902@gmail.com

Konferans Bildirileri

1. V. Şahin, L. Bilgili, ve N. Vardar, “Yolcu Gemilerinin Atıksularının Denizdeki Seyrelmelerinin Yapay Sinir Ağları ile İncelenmesi,” 5. Ulusal Deniz Turizmi Sempozyumu “Dijital Dönüşüm,” ss. 341–360, 2020 doi: 10.18872/0.2020.45.

Makaleler

1. V. Şahin ve N. Vardar, “Determination of Wastewater Behavior of Large Passenger Ships Based on Their Main Parameters in the Pre-Design Stage,” Journal of Marine Science and Engineering, c. 8, sy. 8, ss. 546-563, Tem. 2020, doi: 10.3390/jmse8080546