

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ARAÇLARDA KÜTLE TAHMİN YÖNTEMLERİNİN
KARŞILAŞTIRILMASI

Adem ORUZ

YÜKSEK LİSANS TEZİ
Makine Mühendisliği Anabilim Dalı
Otomotiv Mühendisliği Programı

Danışman
Doç. Dr. Alp Tekin ERGENÇ

Haziran, 2023

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ARAÇLARDA KÜTLE TAHMİN YÖNTEMLERİNİN
KARŞILAŞTIRILMASI

Adem ORUZ tarafından hazırlanan tez çalışması 23.06.2023 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı Otomotiv Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Alp Tekin ERGENÇ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Alp Tekin ERGENÇ, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Orkun ÖZENER, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Özgen AKALIN, Üye
İstanbul Teknik Üniversitesi

Danışmanım Doç. Dr. Alp Tekin ERGENÇ sorumluluğunda tarafımca hazırlanan Araçlarda Kütle Tahmin Yöntemlerinin Karşılaştırılması 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.

Adem ORUZ

İmza

Bu çalışmayı gösterdiğim sabır ve metanet için kendime, bana her daim yardımcı olan arkadaşım Alican Kılınç'a ve eşim Merve'ye atfediyorum.



TEŞEKKÜR

Çalışmamda benden desteğini esirgemeyen danışman hocam Doç. Dr. Alp Tekin Ergenç'e teşekkür ederim.

Adem ORUZ



İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	x
ÖZET	xi
ABSTRACT	xii
1 GİRİŞ	1
1.1 Literatür Araştırması	1
1.2 Tezin Amacı	2
2 ALGORİTMA TASARIMI	3
2.1 Kütle Tahmin Algoritmalarına Giriş	3
2.2 Yazılım Mimarisi	4
2.2.1 Araç Modeli ve Sinyal İşleme	4
2.2.2 Aktivasyon Koşulları	6
2.2.3 EKF Yöntemi	7
2.2.4 RLS Yöntemi	9
3 KALİBRASYON	11
3.1 Kalibrasyon Yaklaşımlarına Giriş	11
3.2 Sinyal İşleme ve Araç Modeli Kalibrasyonu	11
3.3 Aktivasyon Koşullarının Kalibrasyonu	14
3.4 EKF Kalibrasyonu	15
3.5 RLS Kalibrasyonu	15
4 YÖNTEMLERİN KARŞILAŞTIRILMASI	17
4.1 Test Şartları	17
4.2 Performans Metriklerinin Belirlenmesi	21

4.2.1	Tahmin Doğruluğu	22
4.2.2	Tahmin Hızı	23
4.2.3	Kalibrasyon Eforu	25
4.2.4	İşletim Süresi	25
4.2.5	Hassasiyet Analizi	27
5	SONUÇ VE ÖNERİLER	30
	KAYNAKÇA	31
	TEZDEN ÜRETİLMİŞ YAYINLAR	33



SİMGE LİSTESİ

A	Aracın ön yüzey alanı
ω	Araç hızı
C_d	Aerodinamik sürüklenme katsayısı
J	Atalet kuvvetleri
ρ	Hava yoğunluğu
F	Kuvvet
ω	Motor devir artışı
r	Toplam aktarma oranı
T	Tork
λ	Unutma faktörü
α	Yol eğimi
μ	Yuvarlanma direnci
η	Verim

KISALTMA LİSTESİ

EKF	Extended Kalman Filter (Genişletilmiş Kalman Filtresi)
RLS	Recursive Least Square (Ardışık En Küçük Kareler)
WCET	Worst-Case Execution Time
GPS	Global Positioning System
LVDT	Linear Variable Differential Transducerx
FFNN	Feed Forward Neural Network

ŞEKİL LİSTESİ

Şekil 2.1	Yazılım mimarisinin şematik gösterimi	4
Şekil 2.2	Araca etki eden kuvvetlerin şematik gösterimi	5
Şekil 2.3	EKF operasyonunun şematik olarak gösterimi	8
Şekil 3.1	WLTP çevrimi	12
Şekil 3.2	WLTP çevriminde tekerlek kuvvetinin validasyonu	13
Şekil 4.1	%60 yüklü durum için araç hızı histogramı.	18
Şekil 4.2	%60 yüklü durum için araç ivmesi histogramı.	18
Şekil 4.3	%60 yüklü durum için yol eğimi histogramı.	19
Şekil 4.4	%100 yüklü durum için araç hızı histogramı.	19
Şekil 4.5	%100 yüklü durum için araç ivmesi histogramı.	20
Şekil 4.6	%100 yüklü durum için yol eğimi histogramı.	20
Şekil 4.7	%100 yüklü durum için tahmin hızlarının karşılaştırılması.	24

TABLO LİSTESİ

Tablo 3.1	Lambdanın tahmin sonuçlarına etkisi.	16
Tablo 4.1	%60 yüklü araç için toplanan dataların özeti.	17
Tablo 4.2	%100 yüklü araç için toplanan dataların özeti.	21
Tablo 4.3	%60 yüklü durumda EKF ve RLS yöntemlerinin sonuçları.	22
Tablo 4.4	%100 yüklü durumda EKF ve RLS yöntemlerinin sonuçları.	23
Tablo 4.5	Her 2 yük durumu için yöntemlerin mutlak değerce ortalama hataları.	23
Tablo 4.6	EKF parametreleri ve kalibrasyon eforu.	25
Tablo 4.7	RLS parametreleri ve kalibrasyon eforu.	25
Tablo 4.8	Analizde kullanılan bilgisayarın özellikleri.	26
Tablo 4.9	İşletim süresi analiz sonuçları.	27
Tablo 4.10	Yuvarlanma direnci olan hassasiyet.	27
Tablo 4.11	Aerodinamik sürüklenme katsayısına olan hassasiyet.	28
Tablo 4.12	Tekerlek yarıçapının değişimine olan hassasiyet.	28
Tablo 4.13	Eğim değişimine gösterilen hassasiyet.	29

Araçlarda Kütle Tahmin Yöntemlerinin Karşılaştırılması

Adem ORUZ

Makine Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Alp Tekin ERGENÇ

Günümüz araçlarında araç kütlesi vites değiştirme algoritmaları, kalkış, frenleme, otonom sürüş fonksiyonları gibi farklı fonksiyonlarda girdi olarak kullanılmaktadır. Bu yüzden araçların kontrol ünitelerinde tüm sürüş ve yol şartlarında çalışabilen bir kütle tahmin algoritması bulunması oldukça önemlidir.

Hafif ve ağır ticari araçlarda, binek araçlara kıyasla, araç kütlesini bilmek ve kontrol algoritmalarında girdi olarak kullanmak daha önemlidir. Bunun sebebi bu araçlardaki kütle değişiminin binek araca kıyasla oldukça büyük bir skalada değişiyor olmasıdır. Literatürde kütle hesaplayabilmek için birçok farklı metod önerilmiştir.

Bu çalışmada literatürde model tabanlı kütle tahmin yöntemlerinden en fazla çalışılan 2 yöntem olan Kalman Filtresi (KF) ve RLS yöntemleri karşılaştırılmalı olarak incelenmiştir. İlk adımda Matlab/Simulink ortamında algoritmalar geliştirilmiştir ve ilk kalibrasyon işlemi AVL VSM datasıyla yapılmıştır. Daha sonra gerçek araç datasıyla kalibrasyon güncellenmiş ve farklı rotalarda 2 farklı ağırlıkta araç datası alınmıştır. Daha sonra bu datalar kullanılarak belirlenen performans metriklerine göre method karşılaştırması yapılmıştır.

Anahtar Kelimeler: kütle tahmini, RLS ve EKF karşılaştırması, hafif ticari araç, AVL VSM

Mass Estimation Methods Comparison For Vehicles

Adem ORUZ

Department of Mechanical Engineering

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Alp Tekin ERGENÇ

In today's vehicles, vehicle mass is used as input in different functions such as gear shifting algorithms, launch, braking, autonomous driving functions. Therefore, it is very important to have a mass estimation algorithm that can work in all driving and road conditions in the control units of the vehicles.

In light and heavy commercial vehicles, it is more important to know the vehicle mass and to use it as an input in control algorithms compared to passenger vehicles. The reason for this is that the mass change in these vehicles varies on a rather large scale compared to the passenger car. Many different methods have been proposed in the literature to calculate the mass.

In this study, Kalman Filter (KF) and RLS methods, which are the two most studied methods of model-based mass estimation methods in the literature, were examined comparatively. In the first step, algorithms were developed in Matlab/Simulink environment and the first calibration was done with AVL VSM data. Afterwards, the calibration was updated with real vehicle data and data of 2 different weights of vehicles were taken on different routes. Then, a method comparison was made by using these data according to the determined performance metrics.

Keywords: mass estimation, RLS and EKF comparison, light duty vehicles, AVL VSM

1.1 Literatür Araştırması

Hem ticari hem de binek araçlar için araç kullanımı sırasında kütle ve yol eğiminin değişmesi nedeniyle kütle ve yol doğru şekilde tahmini için birçok araştırma yapılmıştır [1]. Araç performansını etkileyen parametreler arasında kütle ve yol eğimi araç performansı üzerinde önemli etkilere sahip olanlardır. Özellikle bir ağır ticari araç için kütle değişimi ciddi şekilde olabilmektedir [2]. Araç kütlesi, araçlarda hız sabitleme, vites değiştirme algoritmaları, çekiş kontrolü, frenleme ve yokuş kalkış gibi birçok araç fonksiyonunda girdi olarak kullanılmaktadır.

Yapılan çalışmalarda kütle ve eğim tahmini için çeşitli yöntemler önerilmiştir, ancak bu yöntemler esas olarak 2 kategoride toplanabilir: sensör tabanlı tahminler ve model tabanlı tahminler [3]. Genel olarak, sensör tabanlı tahmin yöntemleri, bir eğim sensörü [4] veya bir GPS (Küresel Konumlandırma Sistemi) alıcısı [5] gibi zamana bağlı yol eğimini tahmin etmek için en az bir sensör kullanır. Bu yöntemler çoğunlukla sadece yol eğimini tahmin etmek için kullanılır. Sensör tabanlı tahmin çoğunlukla sadece yol eğimini tahmin etmek için kullanılır. Model tabanlı yöntemler ise doğrudan yol eğimini ve araç kütlesini ya da sensör tabanlı sistemin tahmin ettiği yol eğimini kullanarak sadece araç kütlesini tahmin eden algoritmalarıdır.

Kütle ve eğim tahmin yöntemlerini kullandıkları dinamiklere göre de sınıflandırmak mümkündür[6]:

- Süspansiyon Dinamikleri: Rajamani ve Hedrick yaptıkları çalışmada süspansiyon sistemine entegre edilmiş 2 ivmeölçerin ve 1 tane LVDT verisin kullanarak kütle tahmini etmişlerdir[7].
- Yanal Araç Dinamikleri: Araç üzerinde oluşan yanal ivme ve yanal kuvvetlerden yola çıkılarak araç kütlesinin hesaplanmasıdır. Birden fazla çalışmada yanal araç dinamikleri bilgisi EKF kullanılarak araç kütlesi hesaplanmıştır[8], [9].

- Aktarma Organları Dinamikleri: Patenti alınan çalışmada kardan şaftının doğal frekansı kullanılarak kütle tahmin edilebilmiştir[10].
- Boylamsal Araç Dinamikleri - İteratif Yaklaşımlar: Tekerleklerle uygulanan net kuvvet ve ileri yönlü ivmelenin ilişkisinden kütlenin hesaplanmasını ifade etmektedir. Bu yöntemler aynı anda yol eğimini ve kütleyi, bazı koşullarda sadece kütleyi tahmin eden model tabanlı, iterasyona dayalı yaklaşımlardır. Literatürde en fazla çalışılan metoddur. Vahidi vd. yaptıkları çalışmalarda yol eğimi ve kütleyi model tabanlı olarak tahmin etmişlerdir[2], [11]. Benzer şekilde Kalman filtresi kullanılarak kütle tahminin yapıldığı çeşitli araştırmalar bulunmaktadır[1],[12].
- Boylamsal Araç Dinamikleri - Vaka Bazlı Yaklaşımlar: İleri ani ivmelenmeler, yavaşlamalar gibi belli durumları gözeterek tahmin yapan yaklaşımlardır. Klatt vites değişiminden kaynaklı oluşan ani ivmelenme ve yavaşlanma durumları kullanarak araç kütlesin tahmin etmiştir[13]. Benzer yaklaşımları kullanarak kütle tahmini yapan ilginç çalışmalar da vardır[14],[15].

Kütle tahmin yöntemlerinde yeni metod araştırmaları devam etmektedir. Yeni metodlar konusunda öne çıkan yaklaşımlardan biri makine öğrenmesidir. Makine öğrenmesi algoritmalarının kullanım alanının genişlemesi kütle tahmini için yapay zekanın kullanılmasını teşvik etmiştir ve birtakım çalışmalar yapılmıştır. Korayem vd. model tabanlı yöntemleri ve makine öğrenmesi yaklaşımlarını kullanarak araç kütlesini tahmin etmişlerdir[16]. Başka bir çalışmada makine öğrenmesi yöntemlerinden olan FFNN ve model tabanlı bir yaklaşım olan RLS ile farklı şartlarda karşılaştırılmalı olarak incelenmiştir[17].

1.2 Tezin Amacı

Literatürde yaygın olarak kullanılan 2 farklı model tabanlı kütle tahmin yöntemi bulunmaktadır. Bu metodlar literatürde tekil olarak veya karşılaştırılmalı olarak araştırılmıştır. Araştırmacıların bir kısmı algoritma tasarımını anlatmışken bir kısmı kalibrasyonunun nasıl yapılacağını anlatmıştır. Fakat ilgili metodlar gerçek araç kullanım koşulları, sistem değişkenleri ve çoklu data ile karşılaştırılması yapılmamıştır.

Bu tezin amacı araştırmacılara her iki yöntem için detaylı bir klavuz sağlamaktır. Tezin içeriğinde algoritma tasarımı, kalibrasyonu ve performans metrikleri detaylı olarak anlatılmıştır. Bunun yanında metodların birbirlerine göre avantajları, dezavantajları gerçek datalarla gösterilmiş, ileri araştırma yapmak isteyenlere ipuçları verilmiştir.

2 ALGORİTMA TASARIMI

2.1 Kütle Tahmin Algoritmalarına Giriş

Kütle tahmin algoritmaları araçların toplam kütlelerini hesaplamak için kullanılan algoritmalarlardır. Araçta bulunan sensörler vasıtasıyla veya model tabanlı olarak kütleyi hesaplamak mümkündür. Bu çalışmada model tabanlı yöntemler çalışılmıştır. Literatürde en yaygın olan model tabanlı kütle tahmin algoritmaları şöyledir:

- EKF (Extended Kalman Filter): Türkçe'ye "Genişletilmiş Kalman Filtresi" olarak çevrilmiştir. Nonlineer sistemler için kullanılan bir Kalman filtresidir.
- RLS (Recursive Least Square): "Ardışık En Küçük Kareler" olarak Türkçe'ye çevrilebilir. İterasyon yöntemiyle sabit bir değeri tahmin etmek için kullanılan bir yöntemdir.

Bu yöntemler literatürde çoğunlukla, sırasıyla, "EKF" ve "RLS" şeklinde kullanıldığından çalışmanın bundan sonraki kısmında bu isimler kullanılacaktır.

Model tabanlı kütle tahmin yöntemleri Newton'un ikinci hareket kanuna bağlı olarak hesaplanmaktadır:

$$F = m.a \quad (2.1)$$

F: Cisme uygulanan kuvvet [N]

m: Cismin kütlesi [kg]

a: Cismin ivmesi [m/s^2]

Araçlarda kütle tahmini için Newton'un ikinci hareket kanunu doğrudan uygulanamamaktadır. Bunun sebebi araçların kontrol ünitesinde hesaplanan

kuvvet ve ivmenin gürültülü olmasıdır. Dolayısıyla ilgili yöntemler kuvvet ve ivme arasında anlamlı ilişkiler kurmamızı sağlamaktadır.


Bir kütle tahmin algoritmasının, özellikle ekonomi sınıfı araçlar için, karşılaması gereken önemli pratik ihtiyaçlar vardır. Bunlar şöyle sıralanabilir[6]:

- Gerçek zamanlı çalışabilecek kadar basit yapıda olmalı
- Yeterli derecede doğru tahmin yapmalı
- Araçtaki yük değişimini hızlıca tahmin edebilmeli
- Tüm şartlarda belli bir doğrulukla sonuç verebilmeli
- Özellikle ekonomi sınıfı araçlar için ucuz olmalı

2.2 Yazılım Mimarisi

Her iki yöntemde aynı yazılım mimarisi kullanarak tasarlanmıştır. Her iki yöntemde tüm giriş sinyalleri ve aktivasyon koşulları aynı olmakla birlikte asıl farklılık kütle tahmin algoritmasında ortaya çıkmaktadır.

Yazılım mimarisi aşağıdaki gibidir:




Şekil 2.1 Yazılım mimarisinin şematik gösterimi

2.2.1 Araç Modeli ve Sinyal İşleme

Araç modeli tekerleklerle uygulanan net kuvveti bulmak için kullanılmaktadır. Net tekerlek kuvveti tekerlere uygulanan kuvvetten araca etki eden toplam direnç kuvvetlerinin çıkartılmasıyla bulunmaktadır.

Net tekerlek kuvveti aşağıdaki denklemler vasıtasıyla hesaplanabilir:



Şekil 2.2 Araca etki eden kuvvetlerin şematik gösterimi

$$F_{net} = F_p - F_a - F_g - F_r \quad (2.2)$$

$$F_p = \frac{T_e - J_e \omega_e r_g}{\eta} \quad (2.3)$$

$$r_g = \frac{r_w}{g_d g_f} \quad (2.4)$$

$$F_a = 0.5 C_d \rho A V^2 \quad (2.5)$$

$$F_g = M g \sin(\alpha) \quad (2.6)$$

$$F_r = M g \mu \cos(\alpha) \quad (2.7)$$

F_{net} : Net tekerlek kuvveti

F_p : Tahrik kuvveti

F_a : Aerodinamik direnc kuvveti

F_g : Eğim direnci

F_r : Yuvarlanma direnç kuvveti

T_e : Motor torku

J_e : Sistemin atalet

ω_e : Motor devir artışı

r_g : Toplam aktarma oranı

η_g : Şanzıman verimi

r_w : Tekerlek yarıçapı

g_d : Mevcut vites oranı

g_f : Diferansiyel oranı

C_d : Aerodinamik sürüklenme katsayısı

ρ : Hava yoğunluğu

A : Aracın ön yüzey alanı

V : Araç hızı

M : Aracın toplam kütlesi

g : Yerçekimi ivmesi

α : Yol eğimi

μ : Yuvarlanma direncini ifade etmektedir.

Araç modelinin yanısıra bu kısımda sinyal işleme de yapılmaktadır. Bunlardan en önemlisi araç ivmesinin hesaplanmasıdır. Araç ivmesi araç hızının türevinin alçak geçiren filtreden geçirilerek hesaplanmıştır.

Bunların yanında bazı yöntemlerde yol eğimi de bu kısımda hesaplanmaktadır. Fakat mevcut yazılımda yol eğimi halihazırda olduğundan buna gerek duyulmamıştır.

2.2.2 Aktivasyon Koşulları

Kütle tahmin algoritmaları sadece belli koşullarda aktif olacak şekilde çalıştırılmalıdır. Bunun sebebi algoritmanın giriş sinyallerinin, özellikle de net kuvvet hesabının, sadece belirli koşullarda doğru sonucu vermesidir. Tanımlanan aktivasyon koşulları aşağıdaki gibidir:

- Tork Konvertöründeki Slipaj: Slipaj motor devri ile şanzıman giriş şaftı hızlarının arasındaki farkın mutlak değeridir ve aktivasyon şartının sağlanabilmesi için daha sonra kalibre edilecek olan eşik değerden düşük olmalıdır. Bunun yanında gerek şart olarak lock-up kavrama diskinin de aktif olması şartı eklenmiştir.
- Fren Pedalı Konumu: Fren pedalının basılı olmaması gerekir.

- Tekerleklerdeki Slipaj: Tekerlekler arasındaki göreceli hızın patinajdan dolayı artmasını ifade etmektedir. Slipaj tekerlek kuvvetinde önemli kayıplara sebep olup kütle tahminini olumsuz etkilemektedir.
- Araç Hızı: Belirli araç hızının üstünde aktivasyona izin verilmektedir.
- İleri Yönlü İvme: Hem pozitif hem de negatif ivmelerde aktif edilebilecek şekilde tasarlanmıştır.
- Yanal İvme: Belirli yanal ivmenin üstünde aktivasyonu durduracak şekilde tasarlanmıştır.
- Minimum Motor Torku: Motorun sadece belli torkların üzerinde olduğu durumlarda aktivasyona izin vermek için tasarlanmıştır.

Kütle tahmin algoritmasını aktif edebilmek için yukarıdaki tüm koşulların sağlanması gerekmektedir; yani tüm koşullar birbirine "AND" mantık kapısıyla bağlanmıştır.

2.2.3 EKF Yöntemi

Kalman filtresi lineer bir sistemde random bir durumu değişkenini bulmak için kullanılmaktadır. Fakat birçok sistem lineer değil nonlineerdir. Dolayısıyla bu tür nonlineer sistemler EKF (Genişleştirilmiş Kalman Filtresi, Extended Kalman Filter) kullanılmaktadır[18]. EKF denklemleri "zaman güncelleme denklemleri" ve "ölçüm güncelleme denklemleri" olarak 2 grupta uygulanmıştır.

Zaman güncelleme denklemleri denklem (2.8), (2.9) ve (2.10)'da verildiği gibi uygulanmıştır.

$$\hat{x}_{k+1}^- = f(\hat{x}_k^-, u_k, 0) \quad (2.8)$$

$$\hat{P}_{k+1}^- = A_k P_k A_k^T + W_k Q_k W_k^T \quad (2.9)$$

$$\hat{z}_k = h(\hat{x}_k, 0) \quad (2.10)$$

Burada:

$\hat{x}_{k+1}^-$: k+1'inci adımdaki durum tahmini

$\hat{x}_k$: k'inci adımdaki gerçek durum vektörü

A_k ve W_k : k'inci adımdaki Jacobi determinantları

Q_k : k'inci adımdaki proses gürültü varyansı

z_k : Ölçüm vektörü

P_k : Tahmin hatası kovaryansını ifade etmektedir.

Ölçüm güncelleme denklemleri aşağıdaki verilen denklem (2.11), (2.12) ve (2.13)'teki gibi uygulanmıştır. Ölçüm güncelleme denklemleri, temel ayırık Kalman filtresini kullanan ölçümle durum ve kovaryans tahminlerini düzeltir.

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + V_k R_k V_k^T)^{-1} \quad (2.11)$$

$$\hat{x}_k = \hat{x}_k^- + K(z_k - h(\hat{x}_k^-, 0)) \quad (2.12)$$

$$P_k = (I - K_k H_k) P_k^- \quad (2.13)$$


Burada:

H_k ve V : k'inci adımdaki Jacobi ölçümü

R_k : Ölçüm hata kovaryansı

K_k : Kalman katsayısı (Kalman gain)

I : Başlangıç kovaryansı



Şekil 2.3 EKF operasyonunun şematik olarak gösterimi

2.2.4 RLS Yöntemi

RLS (Recursive Least Square) yöntemi Türkçe'ye "Ardışık en küçük kareler" olarak çevrilmekle çoğunlukla "RLS" şeklindeki kısaltması kullanılmaktadır. En küçük kareler tahminlerinde, doğrusal bir modelin bilinmeyen parametreleri, gerçekte gözlenen ve hesaplanan değerler arasındaki farkın karelerinin toplamı minimum olacak şekilde seçilir[19]. Lineer bir sistem için aşağıdaki "kayıp fonksiyonunu (loss function)" en aza indiren parametrelerin bulunması gerekmektedir[11]:

$$V(\hat{\theta}, 0) = \left(\frac{1}{2}\right) \sum_{i=1}^n (y(i) - \phi^T(i)\hat{\theta})^2 \quad (2.14)$$

İndirgeme parametrelerini çözerek aşağıdaki gibi kapalı form çözümünü elde ederiz:

$$\hat{\theta} = \left(\sum_{i=1}^n \phi(i)\phi^T(i)\right)^{-1} \left(\sum_{i=1}^n \phi(i)y(i)\right) \quad (2.15)$$

RLS çözümlerinde çoğu zaman gerçek zamanlı parametre tahmini ile ilgileniyoruz. Bu nedenle, yeni veriler anlık olarak kullanılabilir hale geldikçe denklem (1.15)'teki tahminleri yinelemeli olarak güncellememiz hesaplama açısından daha verimli olmaktadır. Özyinelemeli form şu şekilde verilir:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + L(k)(y(k) - \phi^T(k)\hat{\theta}(k-1)) \quad (2.16)$$

L(k) fonksiyonu:

$$L(k) = P(k)\phi(k) = P(k-1)\phi(k)(1 + \phi^T(k)P(k-1)\phi(k))^{-1} \quad (2.17)$$

ve P(k) fonksiyonu:

$$P(k) = (I - L(k)\phi^T(k))P(k-1) \quad (2.18)$$

şeklinde ifade edilir.

En küçük kareler yönteminin uygulandığı sistemlerde sistem parametreleri hızlı bir şekilde de değişebilir, yavaş ama sürekli de değişebilir. Sistem parametrelerinin sürekli değiştiği sistemlerde "unutma faktörü (forgetting factor)" konsepti

uygulanabilmektedir. Burada eski verilerin ağırlığının yeni verilere kıyasla kademeli olarak arttırılması sözkonusudur. Böyle bi durumda yukarıdaki denklemler şöyle değişmektedir:

$$V(\hat{\theta}, 0) = \left(\frac{1}{2}\right) \sum_{i=1}^n \lambda^{k-1} (y(i) - \phi^T(\hat{\theta}))^2 \quad (2.19)$$

Denklem (2.19)'daki λ unutma faktörünü ifade etmektedir. λ 0'dan büyük ve 1'e eşit veya 1'den küçük değerler alabilmektedir. Aynı denkleme λ uygulanırsa aşağıdaki denklemler:

$$L(k) = P(k)\phi(k) = P(k-1)\phi(k)(\lambda + \phi^T(k)P(k-1)\phi(k))^{-1} \quad (2.20)$$

ve

$$P(k) = (I - L(k)\phi^T(k))P(k-1)\frac{1}{\lambda} \quad (2.21)$$

şeklinde elde edilir. Burada:

$L(k)$: k'inci adımdaki güncelleme faktörü

$\phi(k)$: k'inci adımdaki ivmenin transpozesi

$P(k)$: k'inci adımdaki kovaryans matriks

$P(k-1)$: k-1'inci adımdaki kovaryans matriks

λ : Unutma faktörünü ifade etmektedir.

Unutma faktörünün uygulandığı RLS yöntemi, mühendisliğin çeşitli alanlarında zamanla değişen parametrelerin tahmini ve izlenmesinde yaygın olarak kullanılmaktadır. Bununla birlikte, sistemin uyarılması zayıf olduğunda, bu şema "wind-up" sorununa yol açabilir. Zayıf uyarımlar sırasında eski bilgiler sürekli olarak unutulurken çok az yeni dinamik bilgi gelir[11].

3.1 Kalibrasyon Yaklaşımlarına Giriş

Kütle tahmin algoritmaları jenerik yapıda algoritmalar olarak tasarlanmaktadır. Bu sebeple uygulandıkları sisteme adaptasyonu algoritma içindeki parametrelerin kalibrasyonu ile yapılmaktadır. Aksi halde doğru ve güvenilir sonuçlar almak mümkün değildir.

Akademik çalışmalarda Kalman filtresinin nasıl kalibre edileceği ile ilgili çeşitli çalışmalar vardır. Ancak RLS ile ilgili yeteri kadar kaynak bulunmamaktadır ve metodik bir yöntem önerilmemiştir.

Bu çalışmada her iki algoritmanın araç modeli, sinyal işleme ve aktivasyon koşullarının kalibrasyonu birebir aynı yapılmıştır ki bu yaklaşım doğru bir yaklaşımdır. Kütle tahmin algoritmalarında ise yöntemlerin farklı çalışma prensiplerinden dolayı farklı parametrelerin kalibrasyonu sözkonusudur. Burada Kalman filtresinin kalibrasyonunda literatürde önerilen metodik yaklaşımlar kullanılmıştır. RLS yönteminde ise daha az kalibrasyon parametresi bulunduğu için yetersiz literatür çalışmasına rağmen deneme yanılma yöntemiyle kalibrasyon yapılabilmektedir.


3.2 Sinyal İşleme ve Araç Modeli Kalibrasyonu

Bu kısımda araç ivmesinin hesaplanması ve net tekerlek kuvvetinin hesaplanması yapılmaktadır. Araç ivmesi araç hızının türevi alınarak ve alçak geçiren filtreden geçirilerek hesaplanmıştır. Buradaki tek kalibrasyon parametresi filtrenin katsayısıdır. Araç modeli kısmında ise net tekerlek kuvveti hesaplanmaktadır.

Her 2 parametrede normal şartlarda doğrudan araç datası kullanılarak kalibre edilmektedir. Fakat bu çalışmada kalibrasyon 2 aşamalı yapılmıştır. İlk aşamada AVL VSM'den alınan data ile kalibrasyon yapılmıştır ve sonrasında araç datasıyla valide edilmiş, gerektiğinde güncellenmeler yapılmıştır. Kullanılan araç modeli daha

öncesinde geliştirilmiş ve valide edilmiş bir modeldir.

AVL VSM'den referans data olarak standart bir emisyon çevrimi olan WLTP (Worldwide harmonized Light vehicles Test Procedure) datası alınmıştır.



Şekil 3.1 WLTP çevrimi


Net tekerlek kuvveti hesabında ilk kalibrasyon adımı araçtaki güç aktarma sistemlerinin fiziksel özelliklerinin algoritmada ilgili yerlere yazılmasıdır. Bunlar şöyle sıralanabilir:

- Aerodinamik sürüklenme katsayısı
- Yuvarlanma direnci
- Aracın ön yüzey alanı
- Tekerlek yarıçapı
- Motor, şaft ve tekerleklerin ataleti
- Şanzımanın verimi

Sistemin fiziksel özellikleri girildikten ve gürültülü sinyallere filtreleme işlemi yapıldıktan sonra net tekerlek kuvveti hesabı validasyona hazır hale gelmektedir. Validasyon için 2 farklı yol vardır:

- Şasi Dinamometresi: Aracın şasi dinamometresine yerleştirilerek bir çevrim veya belirli test prosedürünü takip ederek test edilmesidir. Test esnasında şasi dinamometresinden tekerleklere uygulanan kuvvetin ölçüm değerleri ve aracın kontrol ünitesinden hesaplanan kuvvet kayıt altına alınır. Sonrasında 2 değer karşılaştırılarak validasyon yapılır.
- Motor Dinamometresi: Motor dinamometresi motorun araçtan alınıp tek başına farklı ekipmanlarla test edilip birçok parametrenin ölçülmesine imkan sağlayan test ortamıdır. Motor dinamometresinde motorun tork değerleri aracın kontrol ünitesinde hesaplanan tork değeri ile eşleşecek şekilde kalibrasyon yapılır. Böylece net tekerlek kuvveti hesabının temel girdisi olan motor torku hesabı valide edilmiş olur. Geriye kalan işlemlerin uygulanmasıyla birlikte yüksek doğrulukta net tekerlek kuvvet hesabı elde edilir.

Gerek şasi gerek motor dinamometresi testleri oldukça pahalıdır ve zahmetlidir. Dolayısıyla çalışmamızda ilk kalibrasyon için modelde hesaplanan tekerlek kuvvetleri ile kütle tahmin algoritması için hesapladığımız kuvveti karşılaştırarak validasyon yapılmıştır. Literatürdeki diğer çalışmalardan farklı olmasına rağmen bu yöntem hem zaman tasarrufu hem de ekonomik tasarruf sağlamıştır. Gerçek araç testleriyle yapılan testlerde ise tekrar bir validasyona, algoritmanın performansının gayet iyi çıkması sayesinde, gerek duyulmamıştır.



Şekil 3.2 WLTP çevriminde tekerlek kuvvetinin validasyonu

Şekil 3.2’de görüldüğü gibi $\pm 1.5\%$ doğrulukta net tekerlek kuvveti elde edilmiştir.

3.3 Aktivasyon Koşullarının Kalibrasyonu

Aktivasyon koşullarının amacı kütle tahmin algoritmasının yanlış tahmin yapmasını engellemek için doğru aktivasyon zamanını belirlemektir. Aktivasyon için birden fazla şartın aynı anda sağlanması gerekmektedir. Aktivasyon koşullarının çok sıkı kalibre edilmesi modelin doğruluğu arttırabilir fakat cevap hızını düşürür. Tam aksine, çok esnek yapılması ise modelin cevap hızını arttırırken doğruluğunu azaltır.

Kalibrasyonda referans aldığımız çalışmada aktivasyon koşulları şöyle kalibre edilmiştir[6]:

- Araç savrulma oranı $< 1 \text{ derece/s}$
- İleri yönlü ivme $> 1 \text{ m/s}^2$
- Araç hızı $> 10 \text{ m/s}^2$
- Tekerleklerdeki slipaj < 0.05
- Net tekerlek kuvveti $> 500 \text{ N}$

Kalibrasyon değerleri şöyle belirlenmiştir:

- Tork Konvertöründeki Slipaj: Lock-up kavramanın aktif olması şartına ek olarak motor devri ve şanzıman priz direk mili arasındaki hız farkı maksimum 50 rpm olacak şekilde kalibre edilmiştir. 50 rpm aynı zamanda lock-up kavramada müsaade edilen maksimum slipaj miktarıdır.
- Fren Pedalı Konumu: Fren pedalı pozisyonu doğrudan 0 olarak kalibre edilmiştir. Böylece pedala çok az basıldığı şartlar dile ekarte edilmiştir..
- Tekerleklerdeki Slipaj: Tekerlekler arasındaki göreceli hız farkı %5’ten fazla olmayacak şekilde kalibre edilmiştir.
- Araç Hızı: Referans çalışmadaki gibi doğrudan 10 km/h olarak belirlenmiştir..
- İleri Yönlü İvme: Referans çalışmadaki değer büyük bulunmuş ve toplam aktivasyon süresini ciddi miktarda azalttığı görülmüştür. Hem düşük değerlerdeki gürültünün önlenmesi hem de aktivasyon süresini arttırmak için kalibrasyon değeri 0.1 m/s^2 olarak belirlenmiştir.

- Yanal İvme: Yanal ivme model datasına bakılarak ilk başta 0.1 m/s^2 olarak belirlenmiştir. Daha sonra araç datasıyla valide edilip 0.5 olarak güncellenmiştir.
- Minimum Motor Torku: Net tekerlek kuvveti yerine doğrudan motor torkuna eşik değeri konulmuştur. Belirlenen eşik değeri rölanti torkunun üstünde belirlenmeye çalışılmış ve 20 Nm olarak belirlenmiştir.

3.4 EKF Kalibrasyonu

EKF kalibrasyonu Kalman filtresinde kullanılan parametrelerin kalibrasyonunu ifade etmektedir. EKF’te aşağıdaki parametrelerin kalibre edilmesi gerekir:

- Başlangıç Kütlesi
- Hata Kovaryansı $P(0)$
- Proses Gürültü Varyansı (Q)
- Ölçüm Hata Kovaryansı (R)

Başlangıç kütlesi filtrede ilk iterasyon için kullanılmaktadır. Kalibrasyon değeri, genel Kalman filtreleme performansını doğrudan etkilemez ancak genel tahmin performansını etkileyebilir. Benzer şekilde hata kovaryansının ilk değerinin kalibrasyonda tanımlanması gerekir.

Kovaryans matrisleri Q ve R , Kalman filtresi için ek giriş parametreleridir. Pratik bir uygulamada gürültü kovaryansları önceden tahmin edilemediğinden, bu matrislerin değerleri sezgisel olarak seçilmelidir[20]. Hesabı etkileyen modelin tüm hataları, tutarsızlıkları ve gürültüleri nicel olarak Q ’ya dahil edilir. Filtre performansının, filtre parametresinin değerlerinin oranından etkilendiği de iyi bilinmektedir[21]. Bu çalışmada Q ve R seçimi araç dataları kullanılarak yapılan optimizasyon sonucu belirlenmiştir.

3.5 RLS Kalibrasyonu

RLS yöntemi hem hızlı yakınsayan hem de kararlı bir yöntem olarak kabul edilir ve sıklıkla kullanılır[22]. Bunun yanında kalibre etmesi daha kolay bir yöntemdir. RLS algoritmasında aşağıda belirtilen parametrelerin optimizasyonu gerekir:

- Başlangıç Kütlesi

- Hata Kovaryansı $P(0)$
- Lambda (unutma faktörü) (λ)

Başlangıç kütlesi EKF'e benzer şekilde ilk iterasyonu başlatmak için verilmesi gereken bir değerdir. Filtrenin performansını doğrudan etkilememekle birlikte yakınsama süresini etkilemektedir. Bu değer aracın boş ağırlığı olarak seçilmiştir.

Kovaryans matriksinin kalibrasyonu için literatürde önerilmiş bir metod bulunmamaktadır. Bu parametre çoklu araç datası kullanılarak en doğru sonucu verecek şekilde kalibre edilmiştir.

Lambda (unutma faktörü) eski verilerin sistem üzerindeki etkisinin azaltılması, böylece yeni bilgilerin etkisinin artırılması, verilerin doygunluğunun üstesinden gelinmesi ve algoritmanın parazit önleme yeteneğinin geliştirilmesi amacıyla kullanılmaktadır. Lambdanın değerine göre tahmine etkisi aşağıdaki gibi incelenebilir[18]:

Tablo 3.1 Lambdanın tahmin sonuçlarına etkisi.

Lambda Değeri	Sonuçlara Etkisi
$\lambda=0$	Sonuçlar lambdadan bağımsız olarak hesaplanır
$0<\lambda<1$	Geçmiş verilerin etkisini azaltır
$\lambda=1$	Standart RLS algoritması gibi davranır
$\lambda>1$	Geçmiş verilerin sonuçlara etkisi artırılır

Bu çalışmada Lambda değeri 1 olarak kalibre edilmiştir.

4

YÖNTEMLERİN KARŞILAŞTIRILMASI

4.1 Test Şartları

Yöntemlerin karşılaştırılması için 1 araçtan 2 farklı kütlede data toplanmıştır. Araç %60 ve %100 araç yüklerinde yapılmış olup her ağırlık için 3'er tane farklı rotalarda sürüşler yapılmıştır. Testler farklı sürücülerle şehir içi ve şehirdışı sürüşler yapılarak gerçekleştirilmiştir.

%60 yüklü aracın toplam sürüş datası Tablo 4.1'deki gibi özetlenebilir:

Tablo 4.1 %60 yüklü araç için toplanan dataların özeti.


	Toplam Aktivasyon Süresi [s]	Toplam Mesafe [km]	Toplam Sürüş Süresi [dk]
Data1	100	9.1	16.7
Data2	100	6.6	9.3
Data3	150	11.2	23.9

%60 yüklü araç datalarının detayları Şekil (4.1), (4.2) ve (4.3)'te histogram olarak gösterilmiştir. Buna göre:


- Araç hızı 20-60 kph arasında
- araç ivmesi $-0.8 - 0.9 \text{ m/s}^2$ arasında
- Yol eğimi $-2.5 - 2.5 \text{ pct}$ arasında yoğunlaşmıştır.

%100 yüklü araç için datalar detaylı olarak histogram halinde Şekil (4.4), (4.5) ve (4.6)'da verilmiştir. Buna göre:


- Araç hızı 30-50 ve 70-80 kph arasında
- araç ivmesi $-0.8 - 0.7 \text{ m/s}^2$ arasında
- Yol eğimi $-1.3 - 4.2 \text{ pct}$ arasında yoğunlaşmıştır.




Şekil 4.1 %60 yüklü durum için araç hızı histogramı.




Şekil 4.2 %60 yüklü durum için araç ivmesi histogramı.




Şekil 4.3 %60 yüklü durum için yol eğimi histogramı.



Şekil 4.4 %100 yüklü durum için araç hızı histogramı.



Şekil 4.5 %100 yüklü durum için araç ivmesi histogramı.



Şekil 4.6 %100 yüklü durum için yol eğimi histogramı.

%100 yüklü aracın toplam sürüş datası Tablo 4.2'deki gibi özetlenebilir:

Tablo 4.2 %100 yüklü araç için toplanan dataların özeti.

	Toplam Aktivasyon Süresi [s]	Toplam Mesafe [km]	Toplam Sürüş Süresi [dk]
Data1	150	14.0	30.0
Data2	150	10.5	26.7
Data3	300	49.2	47.0

4.2 Performans Metriklerinin Belirlenmesi

Bu bölümde geliştirile ve kalibre edilen 2 algoritmanın farklı metriklerle karşılaştırılıp objectif olarak birbirlerine göre avantaj dezavantajları anlatılmıştır. Konu farklı yöntemlerin karşılaştırılması olduğunda öncelikle "temel performans göstergeleri"nin belirlenmesi gerekir. Literatürde tez çalışmalarında araştırmacılar kendi performans göstergelerini ortaya koyup bu göstergelere göre karşılaştırma yapmışlardır. Ghotikar [23] yaptığı çalışmada 2 farklı kütle tahmin algoritmasını karşılaştırmak için şu kriterleri kullanmıştır:

- Tahmin Doğruluğu: Gerçek değere ne kadar doğrulukla tahminde bulunulduğunu ifade ediyor.
- Hassasiyet Analizi: Yol eğimindeki sapmaların yüzdesel olarak kütlede ne kadar hataya sebep olabileceğini ifade etmektedir.

Holm [24] yaptığı çalışmada algoritmanın performansını gösterebilmek için benzer şekilde tahmin doğruluğuna bakmıştır. Buna ek olarak hassasiyet analizleri yapmıştır. Çalışmada, hassasiyet analizi başlığı altında, aşağıdaki parametrelerin değişiminin sonuçlara etkisi incelenmiştir:

- Aerodinamik sürüklenme katsayısı C_d
- Yuvarlanma direnci μ
- Tekerlek yarıçapı r_w ve atalet kuvvetleri J_e
- Ölçüm hata kovaryansı R_k

Yapılan çalışmalarda her zaman tahmin doğruluğu ve hassasiyet analizi performans değerlendirilmede önemli metrikler olarak ortaya çıkmıştır. Bunların yanında,

gerçek zamanlı bir uygulama yapılmak istendiğinde ve gerçek şartlarda testler yapıldığında daha farklı metriklerle değerlendirme yapma ihtiyacı ortaya çıkmaktadır. Dolayısıyla, bu çalışmada literatürden alınan bilgilere ek olarak gerçek bir uygulama karşılaşılan sorunlarla beraber aşağıdaki kriterler temel performans göstergeleri olarak belirlenmiştir:

- Tahmin Doğruluğu: Gerçek değere yüzdesel olarak ne kadar yaklaşıldığını ifade ediyor.
- Tahmin Hızı: Gerçek kütle ne kadar sürede yakınsadığıdır.
- Kalibrasyon Geliştirme Eforu: Algoritmanın kalibre edilmesine harcanan zamanı ifade ediyor.
- İşletim Süresi: Algoritmanın simülasyonun başlama ve bitiş süresi arasındaki farkı ifade etmektedir.
- Hassasiyet Analizi: Literatürdeki çalışmalara benzer şekilde hassasiyet analizini ifade ediyor.

4.2.1 Tahmin Doğruluğu

Kütle tahmin algoritmalarının mümkün olduğu kadar doğru sonuç vermesi beklenmektedir. Sonuçlar ne kadar gerçeğe yakın olursa kütle değerinin girdi olarak kullanıldığı kontrol fonksiyonlarının hassasiyeti de o kadar arttırabilmektedir. Bölüm 3'te anlatılan kısımda yapılan kalibrasyon tüm testler boyunca aynı tutulmuştur. Böylece aynı kalibrasyonla farklı koşullarda algoritmaların doğruluğu ölçülebilmektedir. Aşağıdaki Tablo 4.3 ve Tablo 4.4'te her data için her 2 yöntemin verdiği sonuçlar ve gerçek değere kıyasla ne kadar hata yaptığı gösterilmiştir. Tablo 4.5 ise tüm datalarda mutlak değerce yüzdesel olarak her yöntemin ne kadar hata yaptığı ortalama olarak gösterilmiştir.

Tablo 4.3 %60 yüklü durumda EKF ve RLS yöntemlerinin sonuçları.

	Data1		Data2		Data3	
Aktivasyon Süresi [s]	EKF	RLS	EKF	RLS	EKF	RLS
0	54.8	54.8	54.8	54.8	54.8	54.8
50	55.2	64.1	62.1	74.9	60.2	64.1
100	58.6	64.1	64.5	66.7	63.1	64.3
150	-	-	-	-	65.4	65.3
Gerçek Kütle [%]	60.0	60.0	60.0	60.0	60.0	60.0
Hata [%]	1.4	-4.1	-4.5	-6.7	-5.4	-5.3

Tablo 4.4 %100 yüklü durumda EKF ve RLS yöntemlerinin sonuçları.

	Data1		Data2		Data3	
Aktivasyon Süresi [s]	EKF	RLS	EKF	RLS	EKF	RLS
0	54.8	54.8	54.8	54.8	54.8	54.8
50	87.0	100.8	70.7	73.4	70.6	105.6
100	104.6	104.5	80.3	82.7	76.4	107.9
150	106.3	106.5	95.2	94.0	78.4	99.9
200	-	-	-	-	81.6	100.6
300	-	-	-	-	90.9	98.6
Gerçek Kütle [%]	100.0	100.0	100.0	100.0	100.0	100.0
Hata [%]	-6.3	-6.5	4.8	6.0	9.1	1.4

Tablo 4.5 Her 2 yük durumu için yöntemlerin mutlak değerce ortalama hataları.

	Araç Yüğü [%]	EKF	RLS
Mutlak Değerce Ortalama Hata [%]	60	3.8	5.4
Mutlak Değerce Ortalama Hata [%]	100	6.7	4.6

%60 yüklü araç datalarında her 2 yöntemin de Data1 ve Data2’de 100. saniyede gerçek değere oldukça yakın bir değeri verdiği görülmektedir. Data3’de 150. saniyeye kadar aktivasyon devam etmesine rağmen 100. saniyede elde edilen değerlere çok yakın değerler elde edilmiştir. Bunlardan yola çıkarak her 2 yöntemin de 100 saniye aktivasyon süresinin sonunda gerçek kütleyle yakınsadığı söylenebilir.


%100 yüklü araç datalarında, diğer dataların aksine, 100 saniyelik aktivasyon süresinin yakınsama için yetmediği görülmektedir. Bunun sebeplerinden biri gerçek kütle ile başlangıç kütlesi arasındaki farkın fazla olmasıdır. Data1 ve Data2’de 150. saniyenin sonunda gerçek değere %6 civarında yakınsayan değerler elde edilmiştir. Fakat Data3’te EKF’in gerçek değere yakınsaması için yaklaşık 300 saniyelik aktivasyon süresi gerekmiştir. Buradan hareketle, başlangıç kütlesi ile gerçek kütle arasındaki fark arttığında EKF’in yakınsama için daha uzun süreye ihtiyaç duyduğu çıkarımı yapılabilir.

Tablo 4.5’ten genel hata oranlarına bakıldığında EKF’in ortalama %5.3 ile, RLS’in %5.0 ile tahmin yapabildiği görülmektedir ki bu değerler kabul edilebilir eşiktedirler.

4.2.2 Tahmin Hızı

Kütle tahmininde doğruluğun yanısıra yakınsama hızı da oldukça önemlidir. Algoritmanın mümkün olan en kısa sürede gerçek değere ulaşması istenmektedir. Bölüm 4.2.1’de açıklandığı üzere gerçek kütle ile başlangıç kütlelerinin birbirine yakın olduğu durumlarda her 2 yöntem de hızlıca yakınsamaktadır. Asıl fark gerçek kütle ile

başlangıç kütlelerinin arasındaki farkın arttığı durumda ortaya çıkmaktadır. Bu sebeple Tablo 4.5'te gösterilen dataları incelemek gerekmektedir. Yöntemlerin genel davranışı aynı olduğundan dolayı Data1 üzerinden gösterilmiştir.



Şekil 4.7 %100 yüklü durum için tahmin hızlarının karşılaştırılması.

Yukarıdaki şekilde %100 yüklü bir data için yöntemlerin zamana bağlı tahmin grafiği gösterilmiştir. Her 2 yöntemde düşük bir kütleden başlamasına rağmen RLS hızlıca gerçek değer yakınsamış ve 600.cü saniyede gerçek değeri vermeye başlamıştır. Fakat EKF çok daha yavaş şekilde yukarı yönlü tahmin meyiline girmiştir ve gerçek değere ancak kaydın son saniyelerinde, 2300.cü saniyede, ulaşmıştır. Dolayısıyla başlangıç ve gerçek kütle arasındaki farkın yüksek olduğu yerlerde RLS yöntemi EKF'e göre çok daha hızlı şekilde gerçek değere ulaşmaktadır. EKF'in yavaş kalmasının sebebi denklem (2.11), (2.12) ve (2.13)'te gösterilen ölçüm güncelleme denklemlerine sahip olmasıdır. Pratik uygulamalarda bu denklemlere, filtrenin düzgün çalışmasını sağlamak amacıyla, birtakım limitasyonlar konulmuştur. İlgili limitasyonlar algoritmanın k anında tahminde bulunurken aşılabilmekte ve anlık olarak kütlenin sıçrama yapmasının önüne geçilmektedir. Bu limitasyonlar yöntemin kararlı çalışmasını sağlarken bir yandan da hızlı sonuç vermesinin önüne geçmektedir. RLS'te böyle bir geri beslemeli kontrol olmadığından gerçek değere hızlıca yakınsayabilmektedir.

4.2.3 Kalibrasyon Eforu

Kütle tahmin algoritmalarında kullanılan denklemler literatürde mevcut olan çalışmalardan rahatlıkla elde edilebilmektedir. Ancak algoritmanın düzgün çalışması için, toplam geliştirme eforunun önemli bir kısmı kalibrasyona ayrılmalıdır.

Algoritmada sinyal işleme, tekerlek net kuvvet validasyonu ve aktivasyon koşullarının kalibrasyonu kullanılan yöntemden bağımsız olarak kalibre edilir. Buradaki farklılık yalnızca algoritmanın kullanılacağı araç sisteminin sistem dinamiklerine bağlı olarak değişiklik göstermektedir. Dolayısıyla kalibrasyon eforunun kıyaslaması yapılmak isteniyorsa doğrudan ilgili yöntemdeki parametre sayıları ve bunların kalibrasyonu için gereken efor dikkate alınmalıdır. Aşağıdaki tablolarda her 2 method için mevcut çalışmada harcanan süreler birimsizleştirilerek verilmiştir.

Tablo 4.6 EKF parametreleri ve kalibrasyon eforu.

Kalibrasyon Parametresi	Efor [birim süre]
Başlangıç Kütle	5
Hata Kovaryansı $P(0)$	10
Proses Gürültü Varyansı Q	10
Ölçüm Hata Varyansı R	10
Limitasyon Değerleri	10
EKF Toplam Efor [birim süre]	45

Tablo 4.7 RLS parametreleri ve kalibrasyon eforu.

Kalibrasyon Parametresi	Efor [birim süre]
Başlangıç Kütle	5
Hata Kovaryansı $P(0)$	10
Unutma Faktörü λ	10
RLS Toplam Efor [birim süre]	25

Yukarıdaki tablolarda görüldüğü üzere EKF’te 5 farklı parametrenin kalibre edilmesi gerekmektedir ve toplamda ihtiyaç duyulan efor 45 birim süre olarak belirtilmiştir. RLS’e baktığımızda ise görece daha az parametre vardır. Toplamda 3 farklı parametrenin kalibre edilmesi gerekmekte ve tahmini efor 25 birim süre olarak belirtilmiştir. Kıyaslama yapıldığında RLS kalibrasyonu için %45 daha az efor gerekmektedir.

4.2.4 İşletim Süresi

Simulink, MathWorks’ün dinamik sistemler için geliştirdiği bir modelleme ve simülasyon ortamıdır ve otomotiv sektöründe fazlaca kullanım alanı bulunmaktadır. Bu yüzden geliştirilen algoritmalar Matlab/Simulink ortamında geliştirilmiştir.

Endüstriyel yazılım geliştirmede giderek daha fazla yer bulan Matlab/Simulink gibi modelleme araçlarında aşağıdaki hususlara dikkat etmek gerekir[25]:

Simulink, temel hesaplama modeli olarak sürekli zaman kullanır, ancak ayırık zamanlı sinyalleri parçalı sabit sürekli zamanlı sinyaller olarak görüntüleyerek ayırık zamanlı modelleri de desteklemektedir[26].

- Kullanılan modelleme aracı, minimum kullanıcı etkileşimi ile çalışmalıdır.
- Yöntem, mevcut programda değişiklik yapılmadan müşterilerin geliştirme araçlarına entegre edilmelidir.
- Yöntem yeni yazılım yayınlarına kolayca uyum sağlayabilmelidir
- WCET (Worst-Case Execution Time) analiz yönteminin farklı donanımlara ayarlanabilir olması, yani uygulama veya yapılandırma çabası, WCET analiz yönteminin ekonomik kullanılabilirliği için yeterince küçük olmalıdır.

Gerçek zamanlı uygulamalarda algoritmanın işletim süresini bulabilmek için WCET analizleri kullanılır. Literatürde farklı durumlar için farklı WCET analizleri önerilmiştir. Bu çalışmada ölçüm tabanlı metod (measurement-based method) analiz için seçilmiştir. Ölçüm tabanlı metodlar donanımda veya bir simülatörde bazı girdiler için işlem veya işlem parçalarını çalıştırır. Daha sonra ölçülen süreleri alır ve gözlemlenen maksimum ve minimum işlem sürelerini veya bunların dağıtımını türetirler veya kod parçacıklarının ölçülen sürelerini işlemin tamamı için sonuçlar elde edecek şekilde birleştirir[27].

Simülasyonda kullanılan bilgisayarın özellikleri ve modellerin işletim süreleri aşağıdaki tablolarda verilmiştir.

Tablo 4.8 Analizde kullanılan bilgisayarın özellikleri.

Marka	HP
Model	EliteBook 845 G8 Notebook
İşlemci	AMD Ryzen 5 PRO 5650U 2.30 GHz
RAM	16 GB DDR4-3200 SDRAM (2 x 8 GB)
Ekran Kartı	AMD Radeon Graphics

Tablo 4.9'dan da görüldüğü üzere EKF ortalama 0.188 saniye işletim süresine sahipken RLS 0.144 saniye işletim süresine sahiptir. Buradan hareketle RLS'in işletim sistemine daha az yük oluşturduğu söylenebilir.

Tablo 4.9 İşletim süresi analiz sonuçları.

	Ölçüm Süresi [s]	EKF İşletim Süresi [s]	RLS İşletim Süresi [s]
Data1_%60 Yük	999.9	0.131	0.093
Data2_%60 Yük	560.9	0.078	0.053
Data3_%60 Yük	1435.1	0.178	0.134
Data1_%100 Yük	1801.7	0.214	0.169
Data2_%100 Yük	1602.9	0.192	0.152
Data3_%100 Yük	28228.0	0.337	0.262
Ortalama [s]	5771.4	0.188	0.144

4.2.5 Hassasiyet Analizi

Hassasiyet analizi algoritmanın küçük modelleme hatalarına karşı doğruluktan ne kadar saptığı veya genel olarak bu durumlarda nasıl davrandığını anlamak için yapılmaktadır. Hassasiyet analizinde aşağıdaki parametrelerin değişiminin ne kadar hataya yol açtığı incelenmiştir:

- Yuvarlanma direnci μ
- Aerodinamik sürüklenme katsayısı C_d
- Tekerlek yarıçapı r_w
- Yol eğimi α

Hassasiyet analizinde yukarıdaki her parametre için faktör tanımlanmıştır. Faktöre 0.8, 0.9, 1.0, 1.1 ve 1.2 değerleri verilip ilgili parametre ile çarpılarak model ortamında sonucun nasıl değiştiği incelenmiştir. Hataya bakılırken faktörün 1.0 olduğu değer referans olarak alınmıştır. Elde edilen sonuçlar aşağıdaki tablolarda gösterilmiştir.

Tablo 4.10 Yuvarlanma direnci olan hassasiyet.

Factor	EKF	RLS	Hata - EKF	Hata - RLS
-	%	%	%	%
0.8	61.09	57.38	-0.44	0.56
0.9	60.87	57.66	-0.22	0.28
1	60.65	57.94	0.00	0.00
1.1	60.43	58.22	0.22	-0.28
1.2	60.21	58.49	0.44	-0.55

Tablo 4.10'a baktığımızda yuvarlanma direncinin değişiminin her 2 methodda da maximum %0.55'lik bir hataya sebep olduğu görülmektedir. RLS'in EKF'e göre daha hassas olduğu görülse de etkisi oldukça düşük kalmaktadır. Bu sebeple yuvarlanma direncinin kütle tahmin algoritmalarını çok fazla etkilemediği çıkarımı yapılabilir.

Tablo 4.11 Aerodinamik sürüklenme katsayısına olan hassasiyet.

Faktör	EKF	RLS	Hata - EKF	Hata - RLS
-	%	%	%	%
0.8	60.63	57.92	0.02	0.02
0.9	60.64	57.93	0.01	0.01
1	60.65	57.94	0.00	0.00
1.1	60.66	57.95	-0.01	-0.01
1.2	60.67	57.96	-0.02	-0.02

Aerodinamik sürüklenme katsayısı aerodinamik direnci doğrudan etkileyen bir parametredir. Bunun yanında aerodinamik direnç araç hızının karesiyle doğru orantılı olarak artmaktadır. Referans alınan datada aerodinamik sürüklenme katsayısının düşüşüyle birlikte tahmin edilen kütlelerin ancak virgülden sonraki ikinci basamakta görülebilecek şekilde değiştiği ve azaldığı gözlemlenmiştir. Newton'un ikinci hareket yasası göz önüne alındığında bu beklenen bir sonuçtur. Tablodan sonuçlara baktığımızda ise her iki metodda da ancak %0.02'lik değişimler meydana gelmiştir. Model tabanlı kütle tahmin yöntemlerinin doğruluğu dikkate alındığında bu hata payları oldukça düşüktür ve aerodinamik sürüklenme katsayısının tahmin sonucunu çok az etkilediği söylenebilir.

Bunlara ek olarak, aerodinamik direnç araç hızının karesiyle doğru orantılı olarak arttığından, hassasiyet analizinde kullanılan araç hızı da önemli olmaktadır. Yüksek hızlar daha fazla hataya yol açması beklenir.

Tablo 4.12 Tekerlek yarıçapının değişimine olan hassasiyet.

Faktör	EKF	RLS	Hata - EKF	Hata - RLS
-	%	%	%	%
0.8	71.78	61.80	-11.13	-3.87
0.9	65.14	59.66	-4.49	-1.72
1	60.65	57.94	0.00	0.00
1.1	56.86	56.53	3.79	1.41
1.2	53.98	55.36	6.67	2.58

Tekerlek yarıçapı tekerlekteki torklardan kuvvete geçmek için kullanılan bir parametredir. Lastiğin ebatlarından hesaplanabilen bu parametre aracın yüküne göre küçük miktarlarda değişim göstermektedir. Buna literatürde "dinamik yarıçap" adı verilir; yük altında ezilen lastiğin yarıçapının küçülmesini ifade eder.

Tabloda verilen değerlere bakıldığında EKF'in tekerlek yarıçapına RLS'e oranla çok daha hassas olduğu görülmektedir. EKF mutlak değer olarak maksimum %11.13 hata yaparken RLS %3.87 hata yapmıştır. Buradan hareketle RLS'in EKF'e oranla tekerlek yarıçapına daha az hassas olduğu söylenebilir.

Tablo 4.13 Eğim değişimine gösterilen hassasiyet.

Faktör	EKF	RLS	Hata - EKF	Hata - RLS
-	%	%	%	%
0.8	61.52	64.16	-0.87	-6.22
0.9	61.08	61.04	-0.43	-3.10
1	60.65	57.94	0.00	0.00
1.1	60.22	56.03	0.43	1.91
1.2	59.80	55.31	0.85	2.63

Yol eğimi araç üstünde konumlandırılan sensör verisi ile hesaplanan araç ivmesi arasında lineer Kalman filtresi ile anlamlı bir ilişki kurularak hesaplanmıştır. Sensörün çevresel faktörlere bağlı olarak hassasiyetinin değişmesi eğim tahminin olumsuz yönde etkilemekte, eğimin %100 doğru hesaplanmasının önüne geçmektedir. Bunun yanında yol durumundaki ani değişiklikler, lineer Kalman filtresinin kalibrasyonu gibi etmenler eğimin her zaman doğru olarak hesaplanmasını engellemektedir. Bu yüzden kullanılacak kütle tahmin algoritmasının yol eğiminin değişimine mümkün olduğu kadar az hassasiyet göstermesi beklenmektedir.

Tablo 4.13'te verilen değerlere bakıldığında EKF'in yol eğiminin değişiminin etkisiyle mutlak değerce maksimum %0.87 hata yaptığı görülmektedir. Bununla birlikte RLS çok daha fazla hassasiyet göstererek %6.22 hata yapmıştır. Buradan hareketle RLS'in yol eğimine daha hassas bir metod olduğu çıkarımı yapılabilir.

5 SONUÇ VE ÖNERİLER

Araçlarda kütle tahmin algoritmaları günümüzde binek araçlardan ticari araçlara kadar birçok farklı araç tipinde kullanılmaktadır. Algoritmanın çıktısı araç kontrolünde kullanılan birçok fonksiyonun girdisi olduğundan doğru sonucu elde etmek oldukça önemlidir.

Çalışmaya konu olan yöntemler literatürde en fazla çalışılan yöntemler olmakta birlikte, yöntemlerin kapsamlı şekilde ele alındığı, pratik uygulamalarda karşımıza çıkacak doğru performans kriterlerinin belirlendiği ve gösterildiği çalışmalar bulunmamaktadır. Bu çalışma literatürde performans kriterlerine ilişkin karşılaştırmaya katkıda bulunacaktır.

EKF ve RLS yöntemlerine bakıldığında her 2 yöntem de birbirine yakın doğrulukta sonuçlar vermektedir. Yöntemlere genel olarak bakıldığında EKF daha karmaşık, daha fazla işlemci tüketen, görece yavaş ancak giriş parametrelerinden çoğunlukla daha az etkilenen; dolayısıyla zor koşullarda doğruluktan çok sapmayan bir yöntemdir. RLS'e baktığımızda ise hızlı reaksiyon veren, az işlemci tüketen fakat giriş parametrelerinden daha fazla etkilenen bir yöntemdir. Yöntemlerin kalibrasyon eforuna bakıldığında ise EKF'in görece karmaşık olmasından dolayı daha fazla efora ihtiyaç duyduğu görülmektedir.

Pratik uygulamalarda algoritmaların uygulanma biçimi yöntemlerin birbirlerine göre avantaj dezavantajlarının ağırlığını değiştirebilir. Ancak beklenen genelde aynı performans metriğinde korelasyonlu sonuçlar elde etmektedir.

İleri araştırma olarak hem model tabanlı hem de makine öğrenmesi gibi yenilikçi yaklaşımların uygulandığı yöntemlerle bu çalışmaya konu olan EKF ve RLS yöntemlerinin karşılaştırılması yapılabilir.

- [1] S. Kim, K. Shin, C. Yoo, K. Huh, "Development of algorithms for commercial vehicle mass and road grade estimation," *International Journal of Automotive Technology*, vol. 18, no. 6, pp. 1077–1083, 2017.
- [2] A. Vahidi, A. Stefanopoulou, H. Peng, "Experiments for online estimation of heavy vehicle's mass and time-varying road grade," in *ASME International Mechanical Engineering Congress and Exposition*, vol. 37130, 2003, pp. 451–458.
- [3] Y. Feng, L. Xiong, Z. Yu, T. Qu, "Recursive least square vehicle mass estimation based on acceleration partition," *Chinese Journal of Mechanical Engineering*, vol. 27, no. 3, pp. 448–458, 2014.
- [4] H. Ohnishi, J. Ishii, M. Kayano, H. Katayama, "A study on road slope estimation for automatic transmission control," *JSAE review*, vol. 21, no. 2, pp. 235–240, 2000.
- [5] H. S. Bae, J. Ryu, J. C. Gerdes, "Road grade and vehicle parameter estimation for longitudinal control using gps," in *Proceedings of the IEEE Conference on Intelligent Transportation Systems*, Citeseer, 2001, pp. 25–29.
- [6] H. K. Fathy, D. Kang, J. L. Stein, "Online vehicle mass estimation using recursive least squares and supervisory data extraction," in *2008 American control conference*, IEEE, 2008, pp. 1842–1848.
- [7] R. Rajamani, J. K. Hedrick, "Adaptive observers for active automotive suspensions: Theory and experiment," *IEEE Transactions on control systems technology*, vol. 3, no. 1, pp. 86–93, 1995.
- [8] M. Best, T. J. Gordon, "Combined state and parameter estimation of vehicle handling dynamics," 2000.
- [9] T. Wenzel, K. Burnham, M. Blundell, R. Williams, "Approach to vehicle state and parameter estimation using extended kalman filtering," in *Proceedings of the International Symposium on Advanced Vehicle Control (AVEC)*, 2004.
- [10] R. Fremd, *Apparatus for measuring the mass of a motor vehicle*, US Patent 4,656,876, Apr. 1987.
- [11] A. Vahidi, A. Stefanopoulou, H. Peng, "Recursive least squares with forgetting for online estimation of vehicle mass and road grade: Theory and experiments," *Vehicle System Dynamics*, vol. 43, no. 1, pp. 31–55, 2005.
- [12] T. Bonnedahl, "Road slope estimation using a longitudinal accelerometer and kalman filtering," *MSc Theses*, 2010.
- [13] A. Klatt, *Method and apparatus to automatically determine the weight or mass of a moving vehicle*, US Patent 4,548,079, Oct. 1985.

- [14] K. Reiner, H. Rieker, J. Stoll, *Device for determining the mass of a motor vehicle*, US Patent 4,941,365, Jul. 1990.
- [15] S. M. Bellinger, J. F. Kalill, B. C. Tyler, *System and method for estimating vehicle mass*, US Patent 6,567,734, May 2003.
- [16] A. H. Korayem, A. Khajepour, B. Fidan, "Trailer mass estimation using system model-based and machine learning approaches," *IEEE Transactions on Vehicular Technology*, vol. 69, no. 11, pp. 12 536–12 546, 2020.
- [17] Z. Yu, X. Hou, B. Leng, Y. Huang, "Mass estimation method for intelligent vehicles based on fusion of machine learning and vehicle dynamic model," *Autonomous Intelligent Systems*, vol. 2, no. 1, pp. 1–10, 2022.
- [18] M. Hu, W. Gao, Y. Zeng, H. Li, Z. Yu, "Vehicle mass and road grade estimation based on adaptive forgetting factor rls and ekf algorithm," in *2020 5th International Conference on Power and Renewable Energy (ICPRE)*, IEEE, 2020, pp. 342–346.
- [19] K. J. Åström, B. Wittenmark, *Adaptive control*. Courier Corporation, 2013.
- [20] A. G. Gelen, A. Atasoy, "A new method for kalman filter tuning," in *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, IEEE, 2018, pp. 1–6.
- [21] Y. Bar-Shalom, X. R. Li, T. Kirubarajan, *Estimation with applications to tracking and navigation: theory algorithms and software*. John Wiley & Sons, 2004.
- [22] E. Paulsson, L. Åsman, "Vehicle mass and road grade estimation using recursive least squares," 2016.
- [23] T. Ghotikar, "Estimation of vehicle mass and road grade," Ph.D. dissertation, Clemson University, 2008.
- [24] E. J. Holm, "Vehicle mass and road grade estimation using kalman filter," *Institutionen for Systemteknik, Department of Electrical Engineering*, vol. 16, 2011.
- [25] R. Kirner, P. Puschner, I. Wenzel, *et al.*, *Measurement-based worst-case execution time analysis using automatic test-data generation*. na, 2004.
- [26] R. Lublinerman, S. Tripakis, "Translating data flow to synchronous block diagrams," in *2008 IEEE/ACM/IFIP Workshop on Embedded Systems for Real-Time Multimedia*, IEEE, 2008, pp. 101–106.
- [27] R. Wilhelm *et al.*, "The worst-case execution-time problem—overview of methods and survey of tools," *ACM Transactions on Embedded Computing Systems (TECS)*, vol. 7, no. 3, pp. 1–53, 2008.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

Oruz, A., & Ergenç, A. T., (2022), Kalman Filter Mass Estimation Algorithm Calibration For A Light Duty Vehicle: Theory and Practice, IMASCON, pp. 195-203

