

도시철도차량 주행차륜의 직경/플랜지 변화 데이터와 머신러닝 기법을 활용한 주행거리 예측 연구

노학락¹ · 임원식²

A Study on the Mileage Prediction of Urban Railway Vehicle using Wheel Diameter/Flange change Data and Machine Learning Techniques

Hak Rak Noh¹ · Won Sik Lim²

¹Corresponding Author

Won Sik Lim

Tel : +82-2-970-6392

E-mail : limws@seoultech.ac.kr

Received : July 20, 2023

Revised : August 7, 2023

Accepted : August 16, 2023

Copyright©2023 by The Korean Society of Safety All right reserved.

Abstract : The steel wheels of urban railway vehicles gather a lot of data through regular measurements during maintenance. However, limited research has been carried out utilizing this data, resulting in difficulties predicting the maintenance period. This paper studied a machine learning model suitable for mileage prediction by studying the characteristics of mileage change according to diameter and flange thickness changes. The results of this study indicate that the larger the diameter, the longer the travel distance, and the longest flange thickness is at 30 mm, which gradually shortened at other times. As a result of research on the machine learning prediction model, it was confirmed that the random forest model is the optimal model with a high coefficient of determination and a low root mean square error.

Key Words : wheel, flange, wear, mileage, machine learning

1. 서론

철도를 이용하는 승객의 안전과 편의는 차륜과 레일의 접촉에 의한 진동과 소음, 마모 등에 대하여 얼마나 효과적으로 대처하는지가 매우 중요한 이슈이다. 철도 차량의 차륜은 차량의 모든 하중을 지지하면서 승객과 차량의 안전을 위하여 가장 기초적이면서 중요한 역할을 하는 부품이므로 안전한 운영을 위하여 지속적이고 확실한 안전성이 보장되어야 하는 부품이다. 철제차륜의 경우 레일과 금속간 구름접촉에 따라 필연적으로 마모가 진행되며, 이는 차륜의 수명과 승차감 등의 성능에 큰 영향을 미치게 된다. 특히 도시철도 노선의 경우 대부분 도심을 통과하면서 복잡하고 급곡선이 많으며 잦은 주행과 제동으로 인해 속도의 변화가 크게 되어 차륜 사용환경에 악영향을 주게 된다.

차륜의 마모에 관하여 기존의 연구에서는 마모실험이나 해석적인 방법을 통하여 많은 연구가 진행되었다.

Lee 등¹⁾은 유한요소해석을 통한 차륜과 레일의 구름미끄럼 접촉시 마찰계수별 영향평가 및 손상예측수명을 분석하여 차륜-레일간 마찰계수가 0.25로 증가된다면 수명이 급속히 감소한다고 주장하였다. Lee 등²⁾은 차륜교환 주기 예측을 통한 차륜교환량 수급계획의 신뢰성 향상을 위하여 주행거리, 운행일수, 플랜지두께, 플랜지마모 등의 요소를 찾아 예측모델을 설계하여 RandomForest Regressor가 RMSE와 R-Squared 성능 평가지표에서 가장 예측 신뢰도가 높다고 주장하였다. Kim 등³⁾은 차륜의 제조과정중 생성된 압축잔류응력이 차륜의 열균열 또는 피로균열에 의한 피로파괴를 방지하는 효과가 있으며, 압축잔류응력이 인장잔류응력으로 변환하는 위치가 차륜사용한도를 결정하는 마모한계임을 주장하였다. Ahn 등⁴⁾은 트윈디스크 시험기를 이용한 마모 영향인자 시험을 통하여 차륜과 레일의 경계영역에서 마모특성은 속도보다 슬립율과 접촉압력의 영향을 크게 받는다고 주장하였다. F. Braghin a

¹서울과학기술대학교 글로벌철도시스템공학과 박사과정 (Department of Global Railway Systems, Seoul National University of Science and Technology)

²서울과학기술대학교 기계자동차공학과 교수 (Dep. Mechanical and Automotive Engineering, Seoul National University of Science and Technology)

등⁵⁾은 트윈 디스크 마모테스트를 기반으로 한 시험결과와 수치 시뮬레이션의 결과가 근사하게 나타남을 확인하였다.

철도 운영기관은 차륜의 마모와 찰상, 박리 등으로 인한 손상 발생시 정해진 기준에 따라 삭정을 시행하여 답면 프로파일을 복원하고 플랜지 두께를 보상하고 있다. 그러나 운행 조건과 다양한 변수에 따라 차륜의 삭정시기와 삭정량에 대한 정확한 예측을 하기는 매우 어렵다. 대부분의 운영기관에서는 차륜의 삭정을 위한 예측 모델이 존재하지 않고 삭정 기술자의 주관적 판단에 따라 삭정시기와 삭정의 량을 결정하고 있다. 이는 체계적이고 경제적인 차륜관리를 위하여는 불합리하며, 장기적으로 노선 전체의 차량운용 및 차륜수급 관리에 심각한 차질을 빚을 수 있으며 차륜삭정 장비의 운용에도 지장을 초래할 수 있다.

본 논문에서는 서울도시철도 A호선의 차륜에 대하여 신차륜부터 사용 한도시까지의 수명주기 동안 측정된 차륜의 치수 변화를 측정한 데이터를 분석하여 차륜의 주행거리(Mileage) 수명 예측 정확도 향상을 위한 연구를 진행하였다. 또한 데이터 과학 분야에서 널리 쓰이는 프로그래밍 언어인 R을 활용하여 다중선형회귀(Multiple Linear Regression, MLR), 결정트리(Decision Tree, DT), k-최근접 이웃(k-nearest neighbor, KNN), 랜덤 포레스트(Random Forest, RF), 서포트벡터 머신(Support Vector Machine, SVM), 딥러닝(Deep Neural Network, DNN)등의 머신러닝 기법들을 적용하여 주행거리 예측의 정확도를 비교 분석하였다. 이를 통해 최적의 예측모델을 제안하고자 한다.

2. 본론

2.1 차륜마모 특성과 주행거리

2.1.1 차량 및 운영 환경

본 연구에서 분석의 대상차량은 서울도시철도 A호선이며, 차량의 사양은 Table 1과 같이 8칸 1편성으로 4칸의 모터칸(4M)과 4칸의 트레일러칸(4T)으로 구성되어 있으며, 차량중량은 공차시 262.5Ton, 만차시

Table 1. Specification of test vehicle

Weight (Ton)	Arrangement	Brake	Bogie	Suspension
Empty car				
- TC : 33	4M 4T (TC-M -M-T)	Regenerative & Air Brake	H Type, Bolsterless	1st :
- M : 36				Chevron
- T : 29				Rubber
Full car				
- TC : 53	-T-M -M-TC)	Air Brake	H Type, Bolsterless	2nd :
- M : 56				Air Spring
- T : 49				

Table 2. Track conditions

Curve	R≤300 m	R≤301 ~400 m	R≤401 ~500 m	R>500 m	Total
Length (km)	10	10.3	9.1	84.3	113.7

462.8Ton이다. 대차틀은 H자형의 볼스터레스 형식으로 현수장치는 세브론고무(1차)와 공기스프링(2차)을 사용하며, 제동방식은 회생제동과 공기제동을 혼합하여 사용한다.

운영노선은 Table 2와 같이 총궤도 113.7 Km이며 반경 500 m 이하의 곡선구간은 29.4 km로 전체 구간의 25.9%이며 본선 전구간은 지하터널이며, 콘크리트 도상으로 되어 있다. 차량의 최고 운행속도는 80 km/h, 표정속도는 35 km/h이다.

2.1.2 차륜 형상 및 주행특성

A호선 전동차의 차륜은 KSR9221(철도차량용 차륜) RSW2(전기기관차 및 전동차) 규격의 철제 일체차륜으로 원형일 때 직경 860 mm이며, 답면 Profile은 2단 구배 1/20 경사답면으로 단면의 형상은 Fig. 1과 같다.

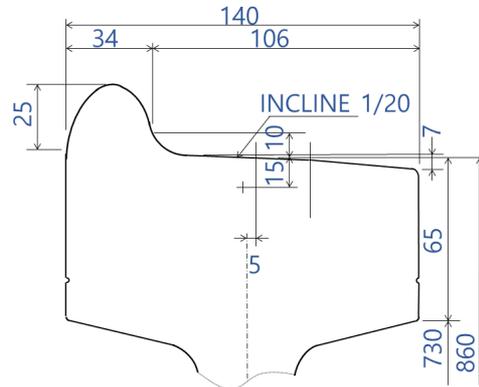


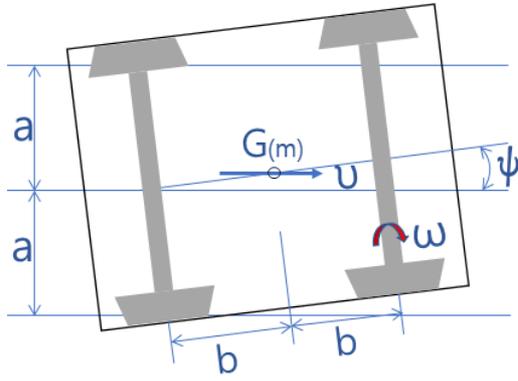
Fig. 1. Wheel geometry and dimension for field test.

차륜의 경사답면 형상은 필연적으로 기하학적 사행진동(Hunting)을 발생시키고 주행안정성에 큰 영향을 주게 된다.

Fig. 2는 두개의 윤축이 대차프레임에 조립되어 구속되어 있는 상태를 보여주며, 이때 사행진동은 관성력과 크리이프력의 균형으로부터 근사적으로 풀 수 있다.

기하학적 사행진동의 파장 S는 식 (1)과 같이 주어지며, 본 연구대상 차륜 형상의 경우 이론적인 파장의 길이는 27.6~26.3 m이다.

$$S = 2\pi \sqrt{\frac{ar}{\lambda} \left(1 + \frac{f_2 b^2}{f_1 a^2} \right)} \quad (1)$$



- v : Vehicle speed
- r : Wheel radius
- ω : Rotational angular speed of wheel
- m : Bogie weight
- $2a$: Distance between rail contact points of left/right wheels
- $2b$: Axis distance
- λ : Wheel tread gradient
- f_1, f_2 : Longitudinal/transverse creep coefficient
- ψ : Declination of bogie

Fig. 2. Hunting of railway bogie.

식 (1)에서 사행진동의 파장은 직경의 크기에 따라 증감됨을 알 수 있으며, 이에 따른 사행진동의 진동수(ν)는 식 (2)와 같이 나타낼 수 있다. 이론적으로 시속 80 km일 때 차량 사행동의 진동은 5.0~5.3 Hz 발생되게 된다.

$$\nu = v \sqrt{\frac{\lambda}{ar(1 + f_2 b^2 / f_1 a^2)}} = 2\pi \frac{v}{S} \quad (2)$$

식 (2)에 따라 차량 주행시 불안정도와 진동수는 속도의 증가에 따라 커지며, 사행진동의 파장(S)의 증가에 따라 작아지게 된다.

차량 주행시 불안정도와 진동수의 증가는 횡방향 하중의 증가와 차륜과 레일 접촉 압력 증가를 가져오게 되며, 결과적으로 차륜 플랜지의 마모와 수명에 영향을 주게된다.

2.1.3 분석 데이터 수집

본 연구에 활용된 데이터는 Table 3과 같이 A호선에서 운행하는 전동차 10개 편성의 차륜 수명주기 중 측정된 직경, 플랜지 두께 및 주행거리 데이터이다. 차륜의 주행거리는 편성별로 약 60만~73만 km이며 사용시기는 2010~2021년 기간중 운행한 차량을 선정하였다. 차륜 수명주기 중 총 4~5회의 삭정을 시행하여 차륜의 직경이 860 mm에서 780 mm로 감소할 때 까지를 대상으로 하였다.

Table 3. Driving data of test vehicle

Trains No.	Driving Distance (km)	Number of Wheel Trimmings	Quantity of Data
A01	702,207	4	1,559
A02	681,742	5	1,714
A03	731,306	5	1,599
A04	649,209	4	1,455
A05	604,313	5	1,763
A06	625,375	4	1,631
A07	695,899	4	1,618
A08	607,301	4	1,692
A09	632,360	4	1,538
A10	621,860	5	1,452

2.2 머신러닝 적용

2.2.1 머신러닝 기법 비교

일반적으로 많이 사용되고 있는 전통적 머신러닝 기반 모델은 MLR, DT, KNN, RF, SVM 등이 있으며, 최근 널리 사용되는 인공신경망 기반의 DNN이 있다.

MLR은 수치형 데이터 모델링으로 가장 일반적으로 쓰이는 모델로 독립변수들과 종속변수간의 관계의 강인성에 기초하여 빠른 예측이 가능한 장점이 있지만, 데이터가 선형 관계에 있지 않을 경우 정확도가 상당히 떨어지는 한계가 있다⁶⁾.

DT는 변수들의 특징들을 기반으로 데이터를 분할하는 트리 기반 모델로 직관적인 해석이 가능하고, 다양한 데이터 유형에 적용할 수 있으며, 분류와 회귀 모두에 사용될 수 있다⁷⁾.

KNN은 지도학습 방법의 하나로 비모수적인 알고리즘으로 분류와 회귀 문제 모두에 활용할 수 있다. 이 알고리즘은 직관적이고 이해하기 쉬운 편이지만, 데이터의 차원이 높아질수록 성능이 떨어질 수 있고, 모든 특성이 동일한 스케일을 가지도록 데이터 전처리가 필요하다⁸⁾.

RF는 여러개의 결정 트리를 기반으로 한 앙상블 학습 방법이다. 이 방법은 다수의 결정 트리를 생성하고, 그 트리들의 예측 결과를 투표(분류 문제의 경우) 또는 평균화(회귀 문제의 경우)하여 최종 예측 결과를 도출한다⁹⁾.

SVM은 선형 및 비선형 회귀 분석과 분류 문제를 해결하기 위해 자주 사용되는 기계학습 방법중 하나이다. 이 방법은 상대적으로 작은 데이터 세트에서도 높은 예측정확도를 제공할 수 있지만, 복잡하게 혼합된 특성을 가진 데이터에서는 중요한 특성이 무시되는 경향이 있다¹⁰⁾.

DNN은 최근 인공지능 기반 예측 모델중 가장 주목

받는 방법론 중 하나이다. 이는 인공신경망(Artificial Neural Networks, ANN)이라는 복잡한 상호작용 계산 모델을 기반으로 한다. ANN에서, 히든 레이어가 3개 이상인 모델을 특별히 DNN이라고 지칭한다¹¹⁾.

각기 다른 특징과 장단점을 가진 여러 머신러닝 모델들을 비교 분석하면서, 본 연구의 목적에 가장 적합한 예측 모델을 연구하였다.

2.2.2 모델 평가(CV, RMSE, R-squared)

본 연구에서는 모델들의 성능을 평가하기 위해 K-fold 교차 검증(Cross Validation, CV)을 적용하였으며, 예측 정확도 측정을 위해 평균제곱근오차(Root Mean Squared Error, RMSE)와 결정계수(Coefficient of Determinant, R-squared) 지표를 사용하였다.

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

$$R\text{-squared} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

n : Number of data
 y_i : Actual value of i th data
 \hat{y}_i : Model predictions for i th data
 \bar{y} : Average of real data

K-fold 교차 검증은 데이터셋을 K로 나누어서 학습과 검증을 K번 반복하여 성능을 평가하는 방법이다. 이 방법은 과적합 문제를 방지하는데 유용하며, 일반적으로 5-fold 또는 10-fold 교차 검증이 주로 채택된다.

RMSE는 실제값과 예측값의 차이인 오차의 절대값 평균을 의미하며, 값이 작을수록 예측 오차가 적다는 것을 나타낸다. R-squared는 예측 모델의 정확성을 나타내는 분산 기반의 성능 평가지표로, 이 값은 0부터 1 사이의 값을 가지며 값이 클수록 예측의 정확성이 높다는 것을 의미한다.

3. 주행거리 예측 연구

3.1 직경 및 플랜지 두께의 치수 변화

차륜의 수명은 답면부의 찰상, 박리 등으로 인한 표면 손상의 경우를 제외한다면 일반적으로 플랜지의 두께 마모로 인하여 플랜지 형상 원형 복원을 위한 삭정으로 직경이 감소되고 플랜지의 마모에 의하여 수명이

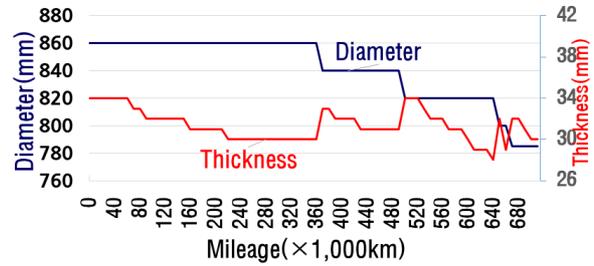


Fig. 3. Wear and reprofiling patterns of wheel diameter and flange thickness of train A01.

결정된다고 볼 수 있다.

Fig. 3은 연구대상 차량 중 1개 편성(A01)의 차륜 64개에 대한 평균 직경과 평균 플랜지 두께의 변화 패턴을 나타내고 있다. 직경이 원형인 860 mm에서 전체 차륜 수명의 절반정도의 주행거리를 보여주며, 840 mm 이후에는 직경이 작아질수록 플랜지의 마모가 급속하게 진행되어 주행거리가 짧아지고 차륜 답면 형상복원을 위한 삭정이 4회 시행되었음을 보여준다.

차륜 플랜지 두께의 관리기준은 34~23 mm 범위 이내로 유지하도록 규정되어 있으나 장기간의 전동차 운영 및 유지관리의 경험에 따라 플랜지 두께가 작아질수록 마모가 급격히 진행되고 과다 삭정의 문제 등에 따라 운영기관(서울교통공사)에서는 플랜지 두께를 27 mm 이상 유지하도록 권고하고 있다.

3.2 차륜 변수간 상관관계 분석

주행거리 예측 모델링을 위하여 3.1절에서 분석한 결과에 대한 직경과 플랜지 두께 그리고 주행거리간의 상관관계 분석을 선행하였다. Fig. 4는 R프로그램을 이용하여 분석대상 차량의 1개 편성(A01)에 대한 상관계수와 상관관계 히트맵을 보여준다.

주행거리와 직경의 상관계수는 0.59로 상당한 연관성이 있으며, 주행거리와 플랜지 두께의 상관계수는 0.17로 선형적 연관성은 매우 낮음을 보여준다.

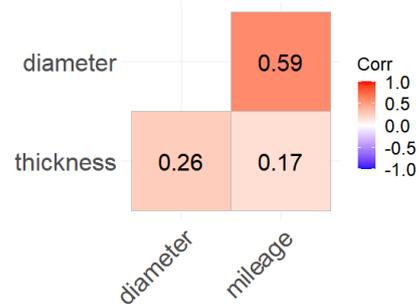


Fig. 4. Correlation analysis of wheel diameter, flange thickness and mileage of A01 train.

Table 4. Average mileage by wheel diameter and flange thickness of test vehicles

(Unit: km)

Diameter (mm)	Thickness (mm)												Average
	34	33	32	31	30	29	28	27	26	25	24	23	
860	20,610	22,534	48,304	75,410	93,950	92,257	58,572	118,657	-	-	-	-	49,898
855	-	-	19,913	18,772	19,494	18,239	18,413	9,687	9,687	-	-	-	18,955
850	14,172	32,500	14,115	18,041	25,758	45,237	55,981	61,544	58,604	-	-	-	29,664
845	5,736	15,951	18,551	29,491	39,817	54,701	43,418	35,956	34,756	-	-	-	29,098
840	18,163	20,625	24,383	30,261	36,815	38,382	24,619	16,633	17,604	12,663	15,217	-	26,148
835	10,703	22,916	24,153	21,034	15,760	10,483	11,087	25,879	31,075	35,724	-	-	20,518
830	16,545	32,703	33,463	24,584	17,499	16,146	10,837	10,703	5,895	6,339	-	-	22,049
825	42,603	42,588	32,132	27,796	20,599	15,596	13,165	10,629	10,838	8,398	10,324	5,970	23,084
820	38,326	22,827	30,544	28,139	25,442	16,944	12,979	10,328	6,871	5,906	-	-	24,035
815	10,535	12,432	23,813	37,147	38,153	24,205	15,469	10,800	13,109	6,785	-	-	25,147
810	13,809	16,607	24,019	17,029	15,512	12,435	14,274	13,912	4,889	5,547	3,344	-	16,876
805	16,598	15,271	14,313	16,400	11,944	20,734	17,300	11,435	3,700	6,160	-	-	15,112
800	18,356	19,550	17,538	15,169	14,538	13,691	12,299	10,771	8,927	10,185	6,373	-	15,336
795	10,199	6,458	9,825	10,318	10,900	12,170	12,411	15,457	9,556	10,252	2,988	-	9,851
790	24,474	15,616	15,930	14,237	13,056	10,810	13,500	18,182	14,102	4,210	-	-	16,329
785	14,076	14,974	17,902	15,421	13,580	12,877	12,992	10,691	10,525	-	-	-	14,921
780	12,700	12,141	11,673	11,105	10,412	10,944	10,768	9,717	6,900	10,833	-	-	11,320
Average	18,253	19,931	27,151	31,682	33,286	30,993	22,653	16,830	12,018	9,680	6,409	5,970	-

Table 4는 본 연구대상 10개 편성 전체에 대한 차륜 직경과 플랜지 두께의 변화에 따른 평균 주행거리를 나타낸다. 분석을 위하여 차륜 직경 860~780 mm 사이에서 5 mm 단위로 나누어 분류하였고, 플랜지 두께는 소수점 이하는 반올림하여 각각의 주행거리를 산출하였다.

Fig. 5는 Table 4의 연구대상 10개 편성의 직경변화에 따른 누적 주행거리와의 관계를 산점도로 나타낸 것으로 추세선이 곡선으로 나타나는 것은 직경이 860 mm에서 780 mm로 작아짐에 따라 직경별 주행거리가 짧아지는 것을 보여준다. 이와 같은 결과는 직경이 작아짐에 따라 사행진동의 파장(s)이 짧아지고 불안정도와

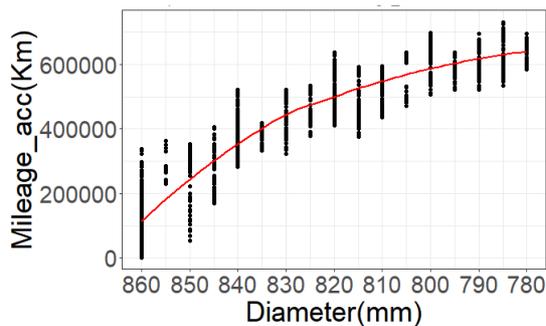


Fig. 5. Scatterplot of diameter and cumulative mileage.

진동(ν)이 크짐에 따라 차륜 플랜지와 레일의 접촉빈도와 강도가 커지며 플랜지의 마모량이 증가되어 주행거리가 짧아지는 것으로 분석된다.

Fig. 6은 Table 4의 10개 편성의 플랜지 두께와 주행거리와의 관계를 산점도로 나타낸 것으로 플랜지 두께가 규정된 범위중 30 mm에서 주행거리가 최대로 나타난다. 이와 같은 결과는 A호선의 경우 사행진동, 다른 운행조건에 따른 플랜지 마모의 패턴이 30 mm 전후에서 가장 안정화되며, 레일과의 간격도 이 지점에서 가장 적합한 것으로 추정할 수 있으나, 차종이나 운행조건에 따른 명확한 인과관계의 규명은 별도의 연구가 필요하다.

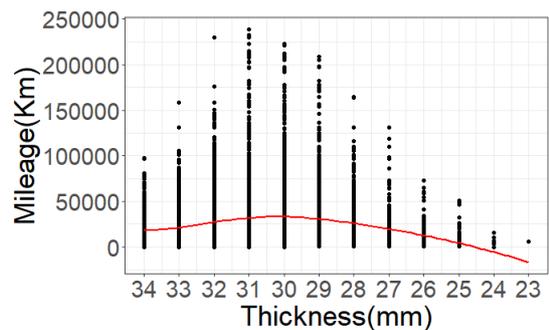


Fig. 6. Scatterplot of flange thickness and mileage.

3.3 예측 모델 비교 및 분석

주행거리 예측을 위해 R프로그램을 이용한 머신러닝 기법별로 5겹 교차 검증을 수행하였다.

Table 5는 분석대상 10개 편성을 편성별로 분석하여 머신러닝 기법별 RMSE와 R-squared값의 최대, 평균, 최소값을 보여준다.

평균 RMSE 값에 따르면, RF모델의 예측오차가 21,342 km로 가장 적으며, 다음으로 KNN(21,392 km), DNN(22,484 km), DT(23,061 km), MLR(28,063 km), SVM(30,150 km)의 순으로 나타났다.

평균 R-squared 값은 RF와 KNN 모델이 각각 0.51로 예측값의 정확도가 가장 높음을 나타내며, 다음으로 DNN(0.46), DT(0.41), MLR(0.17), SVM(0.15)의 순으로 나타났다.

Table 5. Comparison of maximum and minimum values for each machine learning model

Model	RF	KNN	DNN	DT	MLR	SVM	
RMSE (km)	Max	24,977	25,012	26,115	26,869	34,455	37,290
	Avg.	21,342	21,392	22,484	23,061	28,063	30,150
	Min	14,925	15,065	15,437	16,228	17,241	18,219
R-squared	Max	0.61	0.61	0.56	0.51	0.36	0.33
	Avg.	0.51	0.51	0.46	0.41	0.17	0.15
	Min	0.39	0.39	0.35	0.33	0.10	0.03

Fig. 7과 Fig. 8은 분석대상 1개 편성(A01)에 대한 모델간의 RMSE와 R-squared를 점도표(Dotplot)로 비교하여 보여준다.

RMSE는 오차가 가장 낮은 RF(19,849 km)와 오차가 가장 큰 SVM(26,033 km)의 차이가 6,184 km로 SVM의 오차가 약 31% 더 크게 발생되었다.

R-squared는 정확도가 가장 높은 RF(0.59) 대비 가장 낮은 SVM(0.33)의 차이가 0.26으로 RF모델의 정확도가

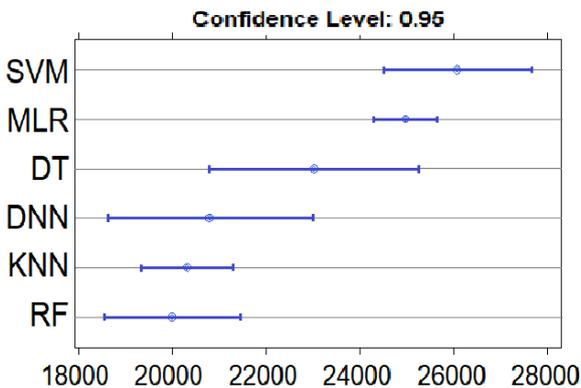


Fig. 7. RMSE of train A01 mileage.

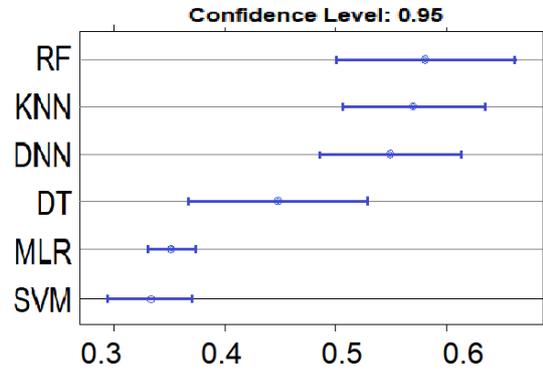


Fig. 8. R-squared of train A01 mileage.

약 44% 더 높게 나타난다.

이와 같은 결과는 RF모델이 차륜의 직경과 플랜지 두께를 변수로 하는 주행거리 예측 모델 중 타 모델과 비교하여 정확도가 가장 높으며, 오차가 상대적으로 낮은 모델임을 보여준다.

4. 결론

본 연구에서는 도시철도 차량 차륜의 수명주기중 주행거리 예측을 위하여 서울도시철도 A호선 전동차에 대하여 차륜 직경과 플랜지 두께의 변화에 따른 주행거리의 변화 및 머신러닝 기법을 활용한 최적의 예측 모델을 연구하여 다음과 같은 결론을 얻을 수 있었다.

- 직경과 주행거리의 관계는 직경이 원형 (860 mm) 일 때 차륜수명의 약 절반에 해당하는 주행거리를 보여주며, 직경이 감소함에 따라 주행거리가 짧아지는 경향을 보여 직경과 주행거리의 상관관계가 높은 것을 확인하였다. 이는 차륜의 수명 연장을 위하여 고려되어야 할 사항으로 판단된다.
- 플랜지 두께는 원형(34 mm)에서 일정량 마모가 진행된 이후 30 mm 전후에서 주행거리가 최대가 되며, 이후에는 점차 짧아진다. 이는 차륜 플랜지와 레일간의 간격과 차량의 사행진동간의 관계에서 플랜지 두께가 특정 범위에서 가장 안정화되는 것으로 추정할 수 있다.
- 머신러닝 예측모델에 대한 R-squared 교차검증 결과 RF와 KNN 모델의 정확도가 0.51로 가장 높으며, DNN은 0.46, DT는 0.41, MLR은 0.17, SVM은 0.15의 순으로 나타났다. RMSE는 SVM의 예측오차가 30,150 km로 가장 크고 MLR은 28,063 km, DT는 23,061 km, DNN은 22,484 km, KNN은 21,392 km, RF는 21,342 km의 순으로 나타난다.

따라서 차륜의 직경과 플랜지 두께를 변수로 하는 예측 모델 중 RF 모델이 가장 우수한 성능을 보여 준다.

References

- 1) S. H. Lee and H. K. Kim, "Estimation of Fatigue Damage due to Rolling Contact in a Railway Wheel Using FEM Analysis", J. Korean Soc. Saf., Vol. 26, No. 3, pp. 1-7, 2011.
- 2) D. Lee and G. Koo, "Study on Securing the Reliability of the Supply and Demand Plan for Wheel Exchange through the Prediction of Wheel Exchange Cycle", J. Korean Soc. Saf., Vol. 36, No. 6, pp. 86-93, 2021.
- 3) J. Y. Kim, S. S. Park and J. M. Kim, "A Study on Compressive Residual Stress Characteristics and Wear Limits of Steel Wheels for Railway Vehicles", Journal of Korean Society for Urban Railway, Vol. 9, No. 4, pp. 1151-1161, 2021.
- 4) J. G. Ahn, S. J. Kwon and H. K. Kim, "Wear Characteristics depended on Wear Index in Wheel-Rail Interface", Journal of Korean Society for Urban Railway, Vol. 1, No. 2, pp. 51-56, 2013.
- 5) F. Braghin, R. Lewis, R. S. Dwyer-Joyce and S. Bruni, "A Mathematical Model to Predict Railway Wheel Profile Evolution Due to Wear", Vol. 261, Issues 11-12, pp. 1253-1264, 2006.
- 6) S. H. Brown, "Multiple Linear Regression Analysis: A Matrix Approach with MATLAB", Alabama Journal of Mathematics, Vol. 34, pp. 1-3, 2009.
- 7) J. R. Quinlan, "Induction of Decision Trees", Machine Learning, Vol. 1, pp. 81-106, 1986.
- 8) N. S. Altman, "An Introduction to Kernel and Nearest-neighbor Nonparametric Regression", The American Statistician, Vol. 46, Issue 3, pp. 175-185, 1992.
- 9) L. Breiman, "Random Forests, Machine Learning", Vol. 45, pp. 5-32, 2001.
- 10) W. S. Noble, "What is a Support Vector Machine?", Nature Biotechnology, Vol. 24, pp. 1565-1567, 2006.
- 11) S. C. Wang, "Artificial Neural Network. in Interdisciplinary Computing in Java Programming Springer", Boston, MA, pp. 81-100, 2003.