

가속도 센서 기반 지능형 타이어를 이용한 타이어 마모 추정

김 승 택^{*1)} · 정 다 솔¹⁾ · 최 세 범¹⁾ · 이 호 종²⁾ · 김 민 태²⁾

한국과학기술원 기계공학과¹⁾ · 한국타이어 연구담당²⁾

Tire Wear Estimation using Accelerometer based Intelligent Tire

Seungtaek Kim ^{*1)} · Dasol Jeong¹⁾ · Seibum Choi¹⁾ · Hojong Lee²⁾ · Mintae Kim²⁾

¹⁾Department of Mechanical Engineering, Korea Advanced Institute of Science and Technology, Daejeon 34141, Korea

²⁾Research Department, HANKOOK TIRE CO., 50, Yuseong-daero 935 beon-gil, Yuseong-gu, Daheon 34127, Republic of Korea

(Received / Revised / Accepted)

Abstract : In this paper, intelligent tire based tire wear estimation method is proposed. It is important to estimate tire wear because tire wear is closely related to vehicle safety, especially braking distance. The existing method of estimating tire wear is considering mileage and tire wear rate. However, this method has the limitation that the estimation of the tire wear rate should be preceded. Therefore, in this paper, tire wear estimation method using intelligent tires is proposed. Three wear parameters predominant to wear that can be obtained from an intelligent tire acceleration sensor are proposed: x-direction acceleration peak, z-direction acceleration peak, and z-direction jerk peak. Tendency between the corresponding factor and wear was confirmed through an indoor test. The effect of tire load, speed, and pressure on the wear factor was considered and tire wear was estimated using the support vector regression technique. Wear estimation performance was verified by indoor testing.

Key words : Intelligent tire(지능형 타이어), Tire wear estimation(타이어 마모 추정), Wear parameter(마모인자), Support vector regression(서포트 벡터 회귀)

Nomenclature

- \vec{x}_i : SVR input 벡터
- y_i : SVR output
- \vec{w} : hyper plane 법선 벡터
- b : bias
- ϵ : SVR 편차
- ξ_i, ξ_i^* : slack variable
- α_i^* : Lagrange multiplier
- C : constant
- σ : Gaussian function 표준편차

1. 서론

타이어 마모는 차량 운행 특히 차량 안전에 밀접한 정보이다. 특히, 제동거리에 대해서는 타이어 마모가 많이 진행된 상태에서 젖은 아스팔트에 제동거리가 매우 증가하는 연구 결과가 존재한다. 즉, 마모가 많이 진행된 타이어가 장착된 차량의 경우, 운전자는 차량은 제어하기 어렵게 되고 갑작스러운 상황에 닥치게 되면 차 사고로 이어지기도 한다. 따라서, 타이어 마모 추정을 위한 다양한 연구들이 선행되어왔다.

타이어 센서 적용에 기술적 한계 때문에 현재 사용하고 있는 타이어 마모 추정 방법은 차량 주행거

*최세범, E-mail: sbchoi@kaist.ac.kr

*초록색 글씨 부분은 그대로 두시면 됩니다

리를 고려하여 마모를 추정하는 것으로 다음과 같은 단점을 갖고 있다.¹⁻²⁾ 운전자마다 운전습관이 다양하고 차량의 주행환경이 다양하다는 것이다. 이는 주행 거리당 진행되는 마모량을 의미하는 마모율이 매우 다양하다는 것을 의미한다. 즉, 마모를 추정하기 이전에 마모율 추정 성능이 뒷받침되어야 한다는 단점이 있다.

본 연구에서는 지능형 타이어를 활용한 타이어 마모 새로운 추정 방법을 제안한다. 해당 방법은 상대적인 마모가 아닌 절대적인 마모를 측정하고 마모율에 영향을 받지 않는 장점이 있다.

지능형 타이어는 타이어 내부 구조에 부착된 센서로부터 다양한 타이어 정보를 얻을 수 있는 새로운 형태의 타이어이다.³⁾ 센서가 부착된 위치와 사용되는 센서 종류에 따라서 많은 형태의 지능형 타이어가 존재한다. 본 연구에서는 타이어 내부 구조 중 타이어 이너라이너(Inner liner)에 3축 가속도 센서가 부착된 지능형 타이어를 대상으로 한다.

2. 지능형 타이어

본 절에서는 x, z 방향의 가속도 신호와 z 방향 저크 신호의 특징 중에서 타이어 마모에 지배적인 인자를 찾아서 분석했고, 해당 인자를 마모 인자로 통칭했다. 이때, z 방향 저크 신호는 z 방향 가속도 신호를 시간에 대해서 미분한 신호이다. 최종적으로, 마모에 따른 마모 인자 경향성은 실험을 통해서 확인하였다.

2.1 마모 인자

타이어 마모가 증가하면서 타이어 트레드의 두

께는 감소하게 된다. 마찬가지로, 트레드의 질량은 감소하게 되고 트레드의 강성은 증가하게 된다. 따라서 트레드가 가지는 고유진동수는 증가하게 된다. 이때, 질량-스프링 시스템에서 얻을 수 있는 자유 진동 식(1)과 식(2)에 의해서 트레드 진동의 가속도 최댓값이 증가하게 될 것을 예상할 수 있다.

$$x(t) = A \cos(w_n t) \tag{1}$$

$$a(t) = \frac{d^2 x}{dt^2} = -A w_n^2 \cos(w_n t) \tag{2}$$

이는 곧 지능형 타이어 가속도 신호의 피크 값이 증가하는 것과 같다. 즉, 마모가 진행됨에 따라서 x z 방향의 가속도 신호와 z 방향 저크 신호 피크 값은 증가할 것으로 예상할 수 있다.

따라서 본 연구에서는, x 방향 가속도 피크, z 방향 가속도 피크, z 방향 저크 피크를 마모 인자로 설정했다. 그 중 z방향 가속도 피크는 두 개의 피크 중 첫 번째 피크만을 고려했다. 마모 인자에 대한 표시는 Fig. 1에서 확인할 수 있다.

2.2 마모 인자 경향성

마모 인자의 경향성을 실내 주행 시험기를 활용한 실내 실험을 통해서 확인하였다. 실험 조건의 경우 Table 1 와 같다. 실내 주행 시험기 위에서 회전하는 타이어에 대해서 하중 속도 압력 그리고 마모를 변경해가며 다양한 조건에 대해서 실험하였다. 타이어의 변형에 의한 신호만을 효과적으로 분석하기 위해서 Low pass filter를 사용하여 가속도 신호의 노이즈를 제거하였다.

Fig. 2은 마모 진행 상황에 따른 x 방향 가속도




Fig. 1 마모 인자

Table 1 실내 주행 시험기 조건

조건	설정
하중	217kg, 326kg, 435kg, 544kg, 652kg
속도	30km/h, 45km/h, 60km/h
압력	2.5bar 2.1bar 1.7bar
마모	0mm, 1mm, 2mm, 3mm, 4mm

피크, z 방향 가속도 피크, z 방향 저크 피크 세 개의 마모 인자를 나타낸 것이다. 마모 인자는 각 조건당 열 바퀴 평균을 내서 계산하였다. 그래프에서 확인할 수 있듯이 마모가 진행됨에 따라서 마모 인자가 각각 증가하는 경향성을 가진다는 것을 확인할 수 있다. 하지만, 마모 인자는 마모뿐만 아니라 타이어 하중 속도 압력과 같은 타이어 조건에도 영향을 받는다. 따라서, 마모 인자를 통해서 마모 정보를 얻기 위해서는 마모 외에 다른 타이어 조건에 대해서 고려하는 작업이 필요하다. 이에 관한 내용은 3절에서 다뤘다.

3. 마모 추정

본 절에서는 2절에서 제시한 마모 인자와 서포트 벡터 회귀를 활용하여 타이어의 마모를 추정하는 방법에 대해서 제시한다.

3.1 서포트 벡터 회귀(SVR)

본 연구에서는 SVR을 사용하여 마모를 추정하였다. SVR은 머신 러닝을 활용한 다양한 회귀법 중에서 적은 데이터로도 학습효과가 높고, 인공 신경망에 대비해 과적합 경향성이 적다는 장점이 있다.

SVR의 작동원리는 다음과 같다.⁴⁾ 식 (3)처럼 m개의 학습 데이터가 있을 때, 본 회귀 알고리즘의 목표는 참값 y_i 에서 ϵ 보다 큰 편차를 허용하지 않는 hyper plane을 세우는 것에 있다.

$$(\vec{x}_1, y_1), \dots, (\vec{x}_m, y_m), \vec{x}_i \in R^n, y_i \in R$$

$$\text{Hyper plane} : f(x) = \vec{w} \cdot \vec{x}_i + b \quad (3)$$

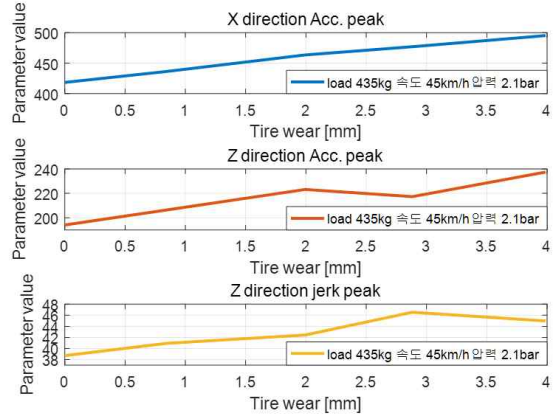


Fig. 2 마모 인자 경향성

$$\text{minimize } \frac{1}{2} \| w \|^2$$

$$\text{subject to } \begin{cases} \vec{y}_i - \vec{w} \cdot \vec{x}_i - b \leq \epsilon \\ \vec{w} \cdot \vec{x}_i + b - \vec{y}_i \leq \epsilon \end{cases} \quad (4)$$

하지만, 모든 학습 데이터에 대해서 위의 조건을 맞추기란 쉽지 않으므로, Slack 변수 ξ_i, ξ_i^* 을 도입하여 식 (5)과 같이 정리할 수 있다.

$$\text{minimize } \frac{1}{2} \| w \|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*)$$

$$\text{subject to } \begin{cases} \vec{y}_i - \vec{w} \cdot \vec{x}_i - b \leq \epsilon + \xi_i \\ \vec{w} \cdot \vec{x}_i + b - \vec{y}_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (5)$$

Karush-Kuhn-Tucker 조건과 Lagrange multiplier, Dual optimization problem에 의하여 식 (6)으로 정리된다. 해당 식은 학습 데이터의 비선형성을 고려하여 Kernel trick을 사용한 형태이다

$$\text{maximize}$$

$$-\frac{1}{2} \sum_{i,j=1}^m (a_i - a_i^*)(a_j - a_j^*)K(\vec{x}_i \cdot \vec{x}_j)$$

$$- \epsilon \sum_{i=1}^m (a_i + a_i^*) + \sum_{i=1}^m y_i (a_i - a_i^*)$$

$$\text{subject to } \begin{cases} -\epsilon \sum_{i=1}^m (a_i - a_i^*) = 0 \\ a_i, a_i^* \in [0, C] \end{cases} \quad (6)$$

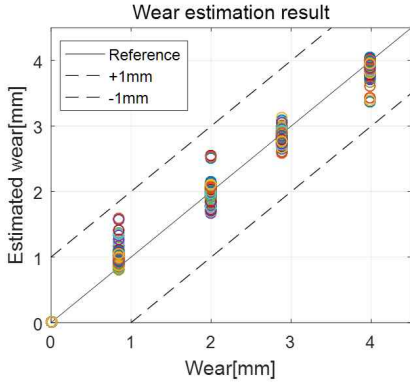


Fig. 3 마모 추정 결과

본 연구에서는 식 (7)과 같이 Kernel function으로 Gaussian function을 활용하였다. 최종적으로 hyperplane은 다음과 같이 구할 수 있다

$$K(\vec{x}_i, \vec{x}_j) = \exp\left(-\frac{\|\vec{x}_i - \vec{x}_j\|^2}{2\sigma^2}\right) \quad (7)$$

$$\vec{w} = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \vec{x}_i$$

Hyper plane : $f(x) = \vec{w} \cdot \vec{x}_i + b$ (8)

식 (9)은 SVR 모델의 학습 데이터 형태를 나타낸다. 6개의 입력값 중 3개는 마모인 자에 해당하고, 나머지 3개는 2절에서 언급한 타이어 조건을 위한 인자이다.

해당 인자는 하중, 압력, 속도를 지능형 타이어 가속도 신호로부터 얻기 쉬운 형태로 변환한 결과이다. 하중 정보는 압력과 접지장 정보로 대신 표현하였으며⁵⁾, 속도 정보는 한 바퀴당 가속도 신호 데이터 개수 정보로 표현하였다.

$$\vec{x}_i = (Acc\ x\ peak, Acc\ z\ peak, Jerk\ z\ peak, Contact\ length, 1/Data\ per\ cycle, Pressure) \quad (9)$$

$$y_i = Wear$$

3.2 타이어 마모 추정 성능 실험 검증

지능형 타이어를 이용한 마모 추정은 3.1절에서 언급된 SVR 모델을 통해서 추정된다. 전체 데이터에 대해서 무작위로 80%를 선정해 학습시켰고, 나머지 20% 데이터에 대해서 추정 성능을 검증하였다. 사용한 데이터 조건은 학습 Table 1와 같고 실

내 수행 시험기를 활용하여 얻은 데이터이다.

마모 추정 결과는 Fig. 3과 같다. 모든 구간에서 1mm 이내로 마모를 추정하였다. 결과적으로 지능형 타이어를 활용한 마모 추정 방법의 성능이 실내 시험을 통해 검증되었다.

4. 결론

본 연구에서는 지능형 타이어를 활용한 마모 추정 방법을 제안했다. 마모에 지배적인 마모 인자 3가지를 설정하였으며 이에 대한 경향성을 실험을 통해 확인하였다. 최종적으로, SVR을 통해서 마모를 추정하였으며 실험을 통해 추정 성능 검증을 하였다.

후 기

본 논문은 한국타이어의 지원으로 작성되었습니다.

References

- 1) C. Wang, H. Huang, X. Chen and J. Liu "The influence of the contact features on the tyre wear in steady-state conditions.", Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering 231.10, pp. 1326-1339, 2017
- 2) Singh, K. Bharat, and P. Jung. "Tire sensor-based robust mileage tracking system and method.", U.S. Patent No. 9,878,721. 2018.
- 3) H. Lee and S. Taheri. "Intelligent tires? A review of tire characterization literature." IEEE Intelligent Transportation Systems Magazine 9.2, pp. 114-135, 2017
- 4) H. Drucker, C. Burges, L. Kaufman, A. Smola and V. Vapnik "Support vector regression machines." Advances in neural information processing systems, pp. 133-161, 1997.
- 5) D. Jeong, J. Lee, S. Choi and M. Kim "Tire Load Estimation using Intelligent Tire with Accelerometer" KSAE Spring Conference Proceedings, pp. 6-9, 2018