

# 선로전환기 전류 패턴의 분류

최윤창\*, 사재원\*, 김희곤\*, 정용화\*, 김희영\*\*, 박대희\*, 윤석한\*\*\*

\*고려대학교 컴퓨터정보학과

\*\*고려대학교 응용통계학과

\*\*\*(주)세화

e-mail: ycc4477@korea.ac.kr

## Classification of Current Patterns in Electrical Point Machine

Younchang Choi\*, Jaewon Sa\*, Heegon Kim\*, Yongwha Chung\*,  
Hee-Young Kim\*\*, Daihee Park\* and SukHan Yoon\*\*\*

\*Dept. of Computer and Information Science, Korea University

\*\*Dept. of Applied Statistics, Korea University

\*\*\*Sehwa. Co.

### 요 약

최근 철도는 다양한 분야에서 사용됨에 따라 그 중요성이 점차 증가하고 있다. 따라서 철도의 안전한 주행을 위하여 철도를 구성하는 요소 관리 역시 중요하다. 철도를 구성하는 요소 중 열차의 진행 방향을 결정하는 선로전환기의 비정상 상황 탐지는 열차의 탈선 등과 같은 대형 사고를 예방하기 위해 매우 중요한 문제이다. 본 논문에서는 Fast Shapelets 알고리즘을 이용하여 선로전환기의 전류 패턴을 분류할 수 있는 방법을 제안한다. 실험 결과, Fast Shapelets 알고리즘을 이용하여 선로전환기의 전류 패턴들을 자동으로 분류할 수 있음을 확인하였다.

### 1. 서론

최근 철도는 여객 및 물류 사업 등 다양한 분야에서 사용되고 있으며, 에너지 효율적 측면과 친환경적인 수송수단으로 철도의 중요성이 점차 증가하고 있다. 따라서 열차의 안전한 주행을 위하여 철도를 구성하는 요소에 대한 관리의 매우 중요한 문제이다. 철도의 구성 요소 중 선로전환기는 신호 장치로서 열차의 주행 방향을 변경하는 중요한 요소이다. 선로전환기의 고장은 열차의 운행지연의 작은 사고부터 탈선과 같은 대형 사고를 일으킬 수 있기 때문에 선로전환기의 고장을 조기에 탐지하는 것은 매우 중요하다[1]. 2000년부터 2010년까지의 신호 장치 고장현황에 따르면 선로전환기 고장은 447건의 철도 신호장치 고장빈도 중 119건으로 전체 신호장치 고장의 27%를 차지하였으며[2], 선로전환기의 유지 및 보수에는 많은 인력과 시간이 소요되는 문제점이 존재한다. 또한, 작업도중 부주의에 의한 사상사고가 종종 발생하며, 열차의 운행이 끝난 야간에 유지 및 보수 작업을 실시하는 어려움이 존재한다. 따라서 선로전환기의 비정상 여부를 자동으로 탐지하는 것은 매우 중요한 문제이다.

이러한 문제를 해결하기 위하여 선로전환기의 고장 여부를 탐지하는 연구가 발표되고 있다. Asada 등 [3]은 Discrete Wavelet Transform (DWT)과 Support Vector Machine (SVM)을 이용하여 선로전환기의 전류 데이터에

적용함으로써 선로전환기의 고장을 탐지하는 방법을 제안하였다. 또한, Vileiniskis 등 [4]은 Uniform Scaling을 이용하여 선로전환기 전류 데이터에 적용함으로써 선로전환기의 고장을 탐지하는 방법을 제안하였다. 한편, 선로전환기의 비정상 전류 패턴을 탐지하기 위해 DTW를 이용하여 비정상 전류 패턴을 탐지하는 방법[5]이 제안되었다.

본 논문에서는 선로전환기로부터 획득한 전류 데이터에 Fast Shapelets 알고리즘을 적용하여 선로전환기의 전류 패턴을 자동으로 분류할 수 있는 방법을 제안한다. 즉, 전류 데이터에 Fast Shapelets 알고리즘을 적용하여 학습하고, 학습된 데이터를 이용하여 새로운 전류 데이터의 패턴을 자동으로 분류하는 기법을 제안한다.

### 2. 관련 연구

Shapelets 알고리즘[6]은 시계열 데이터 분류에 사용하는 알고리즘이다. Shapelets 알고리즘은 시계열 데이터로부터 학습을 통하여 특징을 갖는 ‘subsequence’를 추출하고 구분되지 않은 시계열 데이터를 분류한다. 이때, 특징을 갖는 subsequence를 shapelet으로 정의한다. 즉, class가 분류된 시계열 정보를 입력받아 학습한 후 shapelet과 임계 값을 획득한다. 획득한 shapelet을 이용하여 분류되지 않은 시계열 데이터를 입력받아 시계열 데이터의 전체를 비교하지 않고 shapelet과 시계열 데이터의 거리를 비교하여 임계 값을 기준으로 class를 분류한다. Shapelets 알고리즘은 기

존의 시계열 데이터 분류에 사용된 DTW와 같이 시계열 데이터의 전체를 비교하는 대신, subsequence인 shapelet만을 비교함으로써 수행 속도 측면에서 우수한 성능을 보인다. 또한, 수행결과를 통하여 직관적으로 해석이 가능한 shapelet의 시계열 데이터 정보를 얻을 수 있는 장점이 있다.

Fast Shapelets 알고리즘[7]은 기존 Shapelets 알고리즘[6]의 shapelet을 탐색하는 과정에서 시계열 데이터에 대하여 Symbolic Aggregate approxImation(SAX) 알고리즘[8]을 적용하는 차이점이 있다. SAX 알고리즘을 적용하여 시계열 데이터를 근사화한 후, 생성된 SAX Word를 이용하여 shapelet을 학습함으로써 기존의 Shapelets 알고리즘과 정확도는 유사하지만 수행속도 측면에서 우수한 성능을 가진 알고리즘이다. 본 논문에서는 학습 시간이 빠른 Fast Shapelets 알고리즘을 적용하여 선로전환기의 전류 패턴을 분류하는 실험을 진행하였다.

### 3. Fast Shapelets 알고리즘을 이용한 선로전환기 전류 패턴 분류

본 논문에서 제안하는 선로전환기의 전류 패턴 분석 방법에 대한 구조는 그림 2와 같다. 먼저 현재 실제 역에서 작동 중인 선로전환기 모니터링 시스템을 이용하여 선로전환기의 전류 데이터를 수집한다.



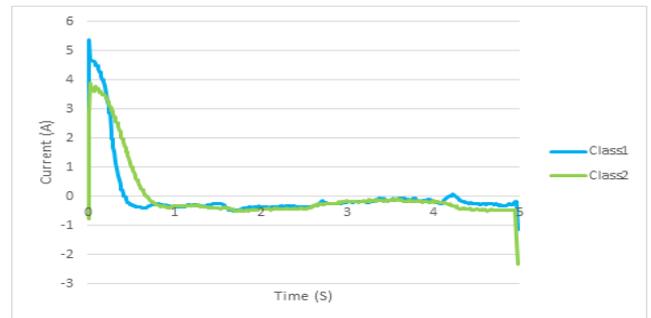
(그림 2) 선로전환기 전류 패턴 분류 방법

Fast Shapelets 알고리즘을 이용하기 위해서 먼저 실제 7개 역으로부터 선로전환기의 전류 데이터를 획득한다. Fast Shapelets 알고리즘은 기존의 Shapelets 알고리즘과 마찬가지로 학습하여 추출된 shapelet을 이용하여 시계열 파형을 있는 그대로 비교할 수 있는 장점이 있다. 이러한 장점을 이용하여 더욱 정밀한 비교를 수행하기 위해 수집된 전류 데이터에 대한 파형을 정규화할 필요가 있다.

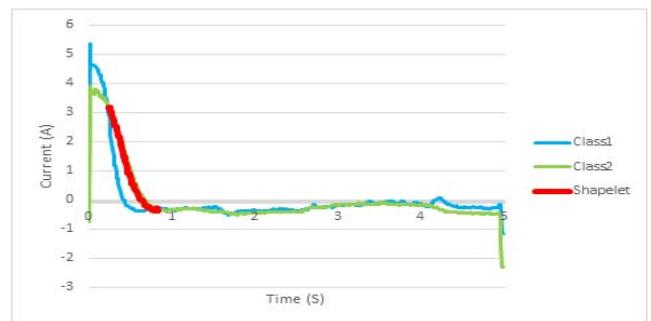
정규화를 수행하기 앞서, 전류 데이터의 길이, 전류 데이터의 피크치 그리고 전류 데이터의 적분 값 등의 “global” 특성을 이용하여 비정상으로 구분 가능한 데이터는 실험 데이터에서 제외한다. 이는 shapelet의 목적이 이러한 global 특성으로는 구분이 불가능한 시계열 데이터들

의 차이를 구분하기 위해 “local” 특성을 이용하기 때문이다. 이후 서로 길이가 약간씩 다른 전류 데이터에 Length-normalization을 적용함으로써 전류 데이터의 길이에 영향을 받지 않는 시계열 데이터를 획득한다. 그리고, Length-normalization을 적용한 전류 데이터에 Z-Score로 변환함으로써 모양이 비슷하지만 크기가 다른 데이터에 대하여 정규화를 수행한다. 즉, 데이터의 모양 자체를 분석하여 분류하기 위해 x축과 y축에 대한 정규화를 수행한다. 마지막으로, 변환된 데이터를 Fast Shapelets 알고리즘에 적용하여 전류 패턴을 분류함으로써 분류 수행시간 및 정확도를 측정한다.

그림 1은 Fast Shapelets 알고리즘을 적용한 전류 데이터를 나타낸 그림이다. 그림 1의 (a)는 서로 다른 Class로 분류된 전류 데이터를 그래프로 나타낸 그림이다. 그림 1 (b)는 ‘Class 1’과 ‘Class 2’를 구분할 수 있는 특징으로 빨간색 shapelet과 전류 데이터를 나타낸 그림이다. shapelet을 이용하여 입력받은 전류 데이터와 shapelet의 거리를 계산한 후 임계 값을 기준으로 class를 분류한다.



(a) 서로 다른 Class의 전류 데이터 그래프



(b) 전류 데이터와 shapelet의 그래프

(그림 1) Fast Shapelets 알고리즘을 적용한 전류 데이터

### 4. 실험 결과

본 논문에서의 실험 환경은 Intel Core® i5-4670 3.40GHz, 8GB RAM, Windows 7 Professional K에서 수행되었다. 선로전환기의 전류 데이터는 대전 유성구에 위치한 (주)세화에서 개발된 모니터링 시스템을 통하여 총 7개의 역의 전류 데이터가 수집(sampling rate: 100Hz)되었다. 7개의 역에서 수집된 선로전환기의 전류 데이터는 선로전

환기를 교체한 시점을 기준으로 교체 1년 전, 직전, 직후, 1년 후의 데이터로 구성되어 있다. 이러한 데이터 속성을 이용하여 전류 데이터를 선로전환기 교체시기에 따라 교체 전 전류 데이터를 'Shape 1', 교체 후 전류 데이터를 'Shape 2'의 파형으로 분류하였다. 각각의 역당 전류 데이터의 개수는 24~406개가 존재하였고, 각각의 역마다 포함된 다수의 선로전환기 전류 데이터를 절반으로 나눔으로써 training data와 testing data로 분류하였다. 표 1 은 역별 training data와 testing data의 개수를 나타낸다.

(표 1) 역별 training / testing data 개수

역이름	Training data	Testing data
A	204	202
B	24	23
C	72	69
D	12	12
E	57	56
F	33	31
G	59	59

7개 역의 전류 데이터를 이용하여 Fast Shapelets 알고리즘에 적용하였다. 실험에 앞서, 먼저 Fast Shapelets 알고리즘의 파라미터에서 shapelet의 길이를 정하는 파라미터인 max-length, min-length를 각각 100~500과 1로 설정하고, shapelet을 탐색하는 크기인 step-size를 10으로 설정하였다. 표 2은 역별 Fast Shapelets 알고리즘 적용 결과이다.

(표 2) 역 별 Fast Shapelets 수행결과

(a) A역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	9.73	5.759	98.537
200	15.64	5.972	98.537
300	18.70	5.629	98.537
400	20.69	5.767	98.537
500	21.81	6.120	98.537

(b) B역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	1.66	2.983	86.957
200	1.77	0.786	82.609
300	2.29	0.773	82.609
400	2.68	2.117	82.609
500	2.88	3.718	78.261

(c) C역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	3.46	2.900	100
200	5.26	2.862	100
300	6.38	3.070	100
400	6.87	2.794	100
500	7.29	4.327	100

(d) D역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	0.48	0.838	100
200	0.82	1.858	100
300	1.08	1.523	100
400	1.24	1.910	100
500	1.36	1.421	100

(e) E역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	2.91	2.171	89.286
200	4.53	2.066	89.286
300	5.22	5.882	89.286
400	5.89	4.749	89.286
500	6.21	4.279	89.286

(f) F역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	2.52	2.336	97.222
200	4.03	4.037	100
300	5.00	2.268	100
400	5.49	1.781	97.222
500	5.79	3.534	94.444

(g) G역 Fast Shapelets 수행결과

Max length	Training time (s)	Testing time (ms)	Accuracy (%)
100	2.86	1.445	100
200	4.49	1.637	100
300	5.37	1.663	100
400	5.81	4.935	100
500	6.20	4.170	100

실험 결과, B역과 E역(80%대 분류 정확도)을 제외한 나머지 역에서 'Shape 1'의 전류 패턴과 'Shape 2'의 전류 패턴을 약 95% 이상의 정확도로 분류할 수 있음을 확인하였다.

## 5. 결론

현재 철도 산업에서 선로전환기의 비정상 상황 탐지는 열차의 탈선 등과 같은 대형 사고를 예방하기 위해 매우 중요하다. 그러나 선로전환기의 고장 진단은 많은 인력을 필요로 하며, 교체 시기 분석은 매우 어려운 문제이다. 본 논문에서는 Fast Shapelets 알고리즘을 선로전환기의 전류 데이터에 적용함으로써 전류 패턴을 자동 분류하는 방법을 제안하였다.

7개의 역에서 획득된 선로전환기의 교체 전과 교체 후의 전류 패턴 데이터로 실험한 결과, Fast Shapelets 알고리즘으로 'Shape 1'의 전류 패턴과 'Shape 2'의 전류 패턴을 약 90%의 정확도로 분류할 수 있음을 확인하였다.

## 감사의 글

본 연구는 2015년도 중소기업청 기술혁신개발사업 혁신형 기업과제(S2312692)의 지원을 받아 수행된 연구결과임.

## 참고문헌

- [1] T. Asada and C. Robert, "Improving the Dependability of DC Point Machines with a Novel Condition Monitoring System," *Proc. of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, Vol. 227, No. 4, pp. 322-332, 2013.
- [2] K. Yoo and S. Rho, "A Study on the Safety System Modeling to Prevent Train Accident by Turn-out Failure," Conference of the Korean Society for Railway, pp. 724-730, 2011.
- [3] T. Asada, C. Roberts, and T. Koseki, "An Algorithm for Improved Performance of Railway Condition Monitoring Equipment," *Alternating-current Point Machine Case Study, Transportation Research Part C: Emerging Technologies*, Vol. 30, No. 1, pp. 81-92, 2013.
- [4] M. Vileiniskis, R. Remenyte-Prescott, and D. Rama, "A Fault Detection Method for Railway Point Systems," *Proc. of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, Vol. 230, No. 3, 2015.
- [5] H. Kim, J. Sa, Y. Chung, D. Park, and S. Yoon, "Fault Diagnosis of Railway Point Machines using Dynamic Time Warping," *Electronics Letters*, Vol. 52, No. 10, pp. 818-819, 2016.
- [6] L. Ye and E. Keogh, "Time Series Shapelets: A New Primitives for Data Mining," *Proc. of the ACM SIGKDD*, pp. 947-956, 2009.
- [7] T. Rakthanmanon and E. Keogh, "Fast shapelets: A scalable algorithm for discovering time series shapelets," *Proc. of the SIAM International Conference on Data Mining*, pp. 668-676, 2013.
- [8] J. Lin, E. Keogh and L. Wei, "Experiencing SAX: a novel symbolic representation of time series," *Data Mining and knowledge discovery*, Vol. 15, No. 2, pp. 107-144, 2007.