

순환신경망을 이용한 자동차 A/S 서비스 부품 수요 예측 모델 연구

정동균 (부경대학교 경영컨설팅 협동과정, 주저자 jdk1204@gmail.com)
이현규 (부경대학교 경영학부 교수, 교신저자 hyunqlee@pknu.ac.kr)

… Abstract …

The purpose of this study is to predict the demand for Auto repair parts in Automotive A/S Centers based on Recurrent Neural Network (RNN). The parts demand data set extracted Parts Inventory Management System and classified the demand pattern with demand time-series data of repair parts depending on the Average demand interval(ADI) and coefficient of variation (CV^2). Most of Auto repair parts has the intermittent demand patten which is irregularly and high demand in a specific period and it's difficult to predict using the traditional demand prediction model like ARIMA. This study is implemented and evaluated the performance about the demand prediction model using the daily time-series data set of Auto repair parts based on RNN models which are SimpleRNN, LSTM, GRU and evaluated the model performance by Loss Function such as MAPE(%), RMSE, RMSLE that can measure the loss between prediction value and actual value. As the result, LSTM Model had the lowest loss value, followed by SimpleRNN and GRU Model but the difference of loss value is very low therefore, this study suggested the possibility to predict the Auto repair parts demand based on RNN models and it will be useful and expects the cost saving effect to Parts inventory mangers at Automotive A/S Service Centers.

Key Words : Auto parts demand, ADI, CV^2 , RNN, LSTM, GRU, Intermittent patten.

I. 서 론

국내 자동차 정비업은 현대·기아, GM 대우, 르노 삼성 등 국내 완성차 생산 업체의 성장과 1987년 수입자동차 개방 이후 판매량 증가로 전국적으로 확대되고 있다. 그러나 한구소비자원의 소비자 시장평가에서 자동차수리서비스는 2019년 31개 서비스 시장 중 31위로 최하위

를 차지하였고 소비자의 불만 및 피해가 큰 비중을 차지하고 있다(오수진·김민아, 2021). 최근 코로나19 팬데믹으로 인해 발생한 부품 공급 부족 사태는, 차량 수리시간 지연에 대한 소비자 불만을 더욱 증가시키고 있다. 국토부 통계누리에 따르면 2021년 12월 기준 국내 자동차관리 사업체 수는 36,454개 업체가 등록되어 운영 중에 있고 매년 증가 추세를 보이

고 있다. 그리고 자동차 부품 연도별 매출 추이 <표 1>을 보면 전체적인 증감률(%)은 감소하고 있지만 A/S 부품은 코로나 19 영향에도 꾸준히 증가하였다 (자동차공업협동조합, 2022).

인한 수리 지연을 해소함으로써 고객 서비스 품질 향상 및 자동차 수리 서비스 시장의 고객 만족에도 기여하고자 한다. 마지막으로, 긴급한 주문으로 인한 고원자 구매와 과잉 재고를 방지함으로써 보

<표 1> 자동차 부품 연도별 매출 추이

구 분	매출실적(억원)				증감률(%)
	OEM	A/S	수출	합계	
2013	507,352	30,441	224,469	762,262	0.7
2014	519,993	31,200	229,992	781,185	2.5
2015	484,810	33,937	233,834	752,581	-3.7
2016	466,784	32,675	259,511	758,970	0.8
2017	472,985	33,109	220,843	726,937	-4.2
2018	467,190	32,708	214,525	714,423	-1.7
2019	506,312	35,442	219,387	761,141	6.5
2020	509,089	35,636	184,808	729,533	-4.2

이와 같이 자동차 유지 보수 및 A/S 부품 시장 산업의 규모를 볼 때, 자동차 부품 시장을 효과적으로 관리하는 것은 국가 경제적 관점에서나 자동차 소유자 개인의 경제적 관점에서 매우 관심있는 사안이라 할 수 있다(오재건·신현승, 2002).

따라서, 본 연구는 자동차 A/S 서비스 센터의 수리 부품에 대하여 구매, 판매 수량 및 수요 발생 기간의 보유 수량, 일 마감 재고 수량의 수요 시계열 데이터와 순환신경망의 SimpeRNN, LSTM, GRU 모델을 이용하여 수리 부품의 적정 재고 보유 수량을 예측할 수 있는 인공지능 예측 모델을 구현하고자 한다. 본 연구의 예측 모델은 부품 부족으로

간 및 관리 비용을 절감하여 부품 재고 관리의 효율성을 향상 시키고자 한다.


본 연구는 다음과 같은 단계로 진행된다. 첫째, 자동차 A/S 서비스 센터의 부품 재고 관리 시스템에서 부품 수요 데이터를 추출한 후 평균수요간격(ADI)와 수요 크기의 변동계수(CV²)를 이용하여 수요 발생 유형을 분석한다. 둘째, 수요 유형 중 가장 많은 수요 유형을 차지하는 부품의 데이터 셋을 대상으로 순환신경망 모델을 이용하여 학습을 진행한다. 마지막으로, 테스트 데이터를 학습된 모델에 적용하여 모델 성능을 손실함수를 이용하여 비교·평가하고 검증한다.

II. 선행 연구

1. 순환신경망


1) 순환 신경망(RNN)

순환 신경망은 입력 상태뿐만 아니라 내부에서 이미 처리된 이전 상태 값에 따라 출력 값이 영향을 받는다. 이러한 특징 때문에 연속적인 데이터를 처리할 때 주요 사용한다(Bod'en, A., 2001; 정경중·최재식, 2015).



<그림 1> SimpleRNN 구조(Olah, 2015)

<그림 1>은 SimpleRNN으로 입력값을 처리하기 위한 메모리 블록이 유닛(Unit) 또는 노드(Node)로 이루어져 있으며 각각의 노드들은 활성화 함수와 가중치(Weight)를 통해 입력된 값들을 다음 층으로의 전달 여부를 결정한다. 즉, 시간이 흐름에 따른 데이터 변동 값을 계산하여 연속해서 입력될 데이터의 예측값을 계산한다(Sutskever et al., 2014).




<그림 2> LSTM 구조(Olah, 2015)

SimpleRNN은 학습 시간이 장기화되면서 훨씬 이전에 입력된 데이터의 값이 매우 작은 값으로 감소하거나 크게 증가되는 장기 의존성 문제로 모델의 예측 성능 저하를 초래하게 되었다.

Hochreiter and Schmidhuber(1997).와 Gers et, al.,(2000, 2001)은 SimpleRNN의 장기 의존성 문제를 해결하기 위해 <그림 2>와 같이 메모리 블록 내에 망각 게이트, 입력 게이트, 출력 게이트를 추가한 장단기메모리(LSTM) 모델을 고안하였다. 망각 게이트는 이전 메모리 셀 값을 얼마나 잊어버릴지 결정하고 입력 게이트는 신규 입력 값의 크기를, 출력 게이트는 출력 값의 크기를 결정하는 로직으로 장기 의존성 문제를 줄일 수 있다.

<그림 3>은 게이트 순환 유닛(GRU) 모델로 LSTM 은닉층의 계산과 구현을 훨씬 더 간소한 RNN의 새로운 유형의 신경망 모델로 별도의 메모리 셀 없이 유닛 내부의 정보흐름을 조절하는 게이트 유닛을 가지고 있다(Cho et al., 2014).



<그림 3> GRU 구조

2. 수요예측 연구

수요예측은 소비자들이 구매하고자 하

는 재화나 서비스의 판매 가능성을 과거의 정보나 자료를 이용하여 추정하는 과정이다(김종배 외, 2021). 시계열 데이터의 전통적인 수요 예측 모형으로는 Box Jenkins의 ARIMA 모형이 있다. 규칙적인 패턴 수요의 주기적인 값에 대한 추세와 경향에 적합하지만 불규칙적이고 간헐적인 시계열 데이터에는 적용하기에는 어려움이 있다. 이에 박진욱·박상현(2017)은 주기성과 자기 상관성이 존재하지 않는 일별 야구 관중 수 시계열 데이터를 순환 신경망 모형에 적용 예측함으로써 자기 상관성이 존재하지 않는 시계열 자료의 예측 가능성을 제시하였다.

오병훈·김현철(2017)은 육군 정비정보 체계의 케도 특정장비의 품목별 소요 실적 자료를 평균수요발생구간(ADI)와 변동계수(CV²)로 이용하여 수요 유형을 구분하고 수요 유형 중 불규칙적이고 특정 기간에 수요가 많이 발생하는 품목을 대상으로 수요 예측 결과 순환신경망의 오차가 전통적인 통계 예측 기법인 ARIMA보다 우수한 결과를 도출하였다.

III. 연구방법

1. 자료 수집 및 데이터 전처리

월 입고 대수 1,200대 규모의 종합 정비가 가능한 자동차 A/S 서비스 센터의 부품 재고 관리 시스템의 부품 수요 데이터를 추출한 후 평균수요간격(ADI)와 변동계수(CV²)로 부품 수요 유형을 파악

하였다. 대부분의 부품은 수요가 불규칙적이고 특정 기간에 다수의 수요가 발생하는 간헐적 수요의 특성으로 나타났다.

간헐적 수요 유형의 부품에 대하여 2017년 1월부터 2021년 12월까지의 5년간의 수요 시계열 데이터를 <표2>와 같이 데이터 셋을 구성하였다. 신경망 모델에 적용하기 전에 이상치, 결측치 처리 및 정규화와 표준화로 데이터 전처리를 수행하였다.

<표 2> 부품 수요 시계열 데이터 셋

변수	설명
Date	수요 발생일
Pre_Stock	구매/판매 후 재고 수
P_Qty	구매 수량
S_Qty	판매 수량
Close_Stock	일마감 재고 수량

2. 모델 학습 및 성능 평가


데이터 전처리 과정을 마친 데이터 셋을 각각 7:3으로 학습 데이터셋과 테스트 데이터 셋으로 구분하여 SampleRNN, LSTM, GRU모델에 적용하여 학습 및 테스트를 진행하였다.

각 모델의 성능 평가는 손실 함수 MAPE(%), RMSE, RMSLE 값으로 검증하였다. 손실 함수는 실제값과 모델의 예측값에 대한 차이로 수치가 낮을수록 예측 성능이 우수하다.


<표 3> 모델별 성능 평가

Models	MAPE(%)	RMSE	RMSLE
RNN	3.69	0.0549	0.0358
LSTM	3.54	0.0536	0.0349
GRU	4.85	0.0547	0.0354


<표 3>의 모델별 성능 평가 지표와 같이 LSTM 모델이 모든 평가 지표가 가장 낮게 나타나면서 가장 우수한 성능을 보이고 있다. 그러나 각 모델별 평가 지표의 수치가 크게 차지 나지 않고 있다. 그리고 <그림 4>의 각 모델별 실제값과 예측값 그래프로 모든 모델이 예측값이 실제값을 비교적 잘 추종하고 있다.



(a) SimpleRNN 실제값 vs 예측값



(b) LSTM 실제값 vs 예측값



(c) GRU 실제값 vs 예측값

<그림 4> 모델별 실제값 vs 예측값

IV. 결론 및 시사점

본 연구는 자동차 A/S 서비스 센터

수리 부품 중 수요가 불규칙적이고 특정 기간에 다수의 수요가 발생하는 간헐적 수요 부품을 대상으로 순환 신경망 모델 학습을 통하여 예측 성능을 비교 평가하였다. 연구 결과 LSTM 모델이 모든 평가 지표에서 성능이 가장 우수하게 평가되었지만 각 모델별 평가 수치의 차이는 크지 않았다. 따라서, 자동차 A/S 수리 부품과 같이 수요가 불규칙적이고 주기성이나 자기상관이 낮은 시계열 데이터 수요 예측의 경우 인공신경망의 한 분류인 순환신경망 모델이 적합하다고 할 수 있다.

따라서, 본 연구는 자동차 A/S 서비스 센터의 수리 부품의 간헐적 수요에 대한 순환신경망 예측 모형을 검증하고 제시하였다. 수리 부품의 수요와 적정 보유 재고 수량을 예측함으로써 고원가 구매를 방지하여 부품 이윤을 향상시킬 수 있다. 그리고 초과 보유 재고를 줄임으로써 보관 및 관리 비용을 절감하고 부품 부족으로 인한 수리 시간 지연을 줄여 고객 서비스 만족도 향상에 도움이 될 것이다.

향후에는 부품 시계열 데이터뿐만 아니라 예측 성능에 영향을 미칠 수 있는 외부 요인 즉, 차량 모델별 판매 대수, 연식, 입고 대수 등을 추가하여 분석함으로써 자동차 A/S 서비스센터 수리 부품의 수요 예측모델 일반화 연구에 기여하고자 한다.

참 고 문 헌

- 김종배, 김유선, 박민영, “우리나라 기업들의 수요예측 실태에 관한 연구 -2011년과 2020년 설문조사 비교·분석-”, 한국유통물류정책학회, 제8권 제4호, 2021, pp. 87-107.
- 오병훈, 김현철, “인공신경망을 이용한 수리부속 간헐적 수요예측”, 한국정보처리학회, 제24권 제2호, 2017, PP. 824-826.
- 오재건, 신현승, “국내 자동차 A/S용 부품 유통 문제와 대책 연구”, 한국자동차공학회, 제2권, 2005, pp. 1,143-1,148.
- 정경중, 최재식, “심층 순환 신경망”, 정보화학회지 제33권 제8호, 2015, pp. 39-43.
- Bod’en, M., “A guide to recurrent neural networks and backpropagation”, In THE DALLAS PROJECT, SICS TECHNICAL REPORT T2002:03, SICS, 2002.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y., “Learning phrase representations using RNN encoder-decoder for statistical machine translation”, arXiv preprint arXiv:1406.1078, 2014.
- Gers, F.A., Schmidhuber, J. and Cummins, F., “Learning to forget Continual prediction with LSTM”, Neural Computation, Vol. 12, 2000, pp. 2451-2471.
- Gers, F.A., Schraudolph N.N. and Schmidhuber, J., “Learning Precise Timing with LSTM Recurrent Networks”, Journal of Machine Learning Research, Vol. 3, 2002, pp. 115-143.
- Hochreiter, S., Schmidhuber, J., “Long short-term memory”, Neural Computation, Vol. 9, 1997, pp. 1735-1780.
- Olah, C, “Understanding LSTM Network-colah’s blog”, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.
- 오수진, 김민아, “2021 한국의 소비자시장평가지표”, 한국소비자원, 2022.
- 한국 자동차 산업협동조합, <https://www.kaica.or.kr/>, 2022