

# LSTM 인공지능망을 이용한 자동차 A/S센터 수리 부품 수요 예측 모델 연구

정동균\* · 박영식\*\*

## <목 차>

- |                        |                   |
|------------------------|-------------------|
| I. 서론                  | III. 연구 방법        |
| II. 이론적 배경             | IV. 예측 모델 평가 및 검증 |
| 2.1 인공지능망 수요예측         | V. 결론 및 시사점       |
| 2.2 자동차 A/S센터 수리 부품 산업 | 참고문헌              |
| 2.3 LSTM 모델 및 성능평가     | <Abstract>        |

## I. 서론

국내 자동차 정비업의 시초는 구한말 고종황제 시절 일본인 애가와가 ‘애가와 자동차공업’에서 황실용 마차와 인력거를 수리하던 것이 시초이며, 1902년 고종황제 즉위 40주년 기념으로 미국 공관을 통해 포드A형 리무진 승용차 1대가 미국에서 들어오면서 자동차수리 업무까지 시작하게 되었다(최성희, 2005). 이는 국내 최초 자동차 정비업의 출현에 따른 수리 업무 중 부품 재고 및 수요 관리의 최초 시작 시점이라 할 수 있다.

현대·기아, GM대우, 르노삼성 등 국내 완성차 생산업체들이 생산하는 자동차는 연간 약

500만대로 한국은 미국, 일본, 독일 등에 이어 세계 여섯 번째 자동차 생산국으로 수출 및 내수시장의 확대에 따라 자동차 정비서비스 산업 역시 가파른 상승세를 보이고 있다(정이상, 정대현, 2018). 그러나 한국소비자원의 소비자시장평가에서 자동차수리서비스는 2019년 31개 서비스시장 중 31위로 최하위를 차지하였으며 소비자의 불만 및 피해가 큰 비중을 차지하고 있었다(오수진, 김민아, 2021). 최근 코로나19 팬데믹으로 인해 발생한 부품 공급 부족 사태는, 차량 수리시간 지연에 대한 소비자 불만을 더욱 증가시키고 있다.

자동차 정비서비스의 품질은 서비스 문의와 상담에 대한 친절한 해결, 직원들의 예의와 신뢰감, 고객이나 서비스 대상에 대한 관심 정도

\* 부경대학교 경영컨설팅협동과정, jdk1204@gmail.com(주저자)

\*\* 동명대학교 경영대학 항공서비스학과, okyspark@gmail.com(교신저자)

등의 상호작용 품질을 향상시키고 최신 장비, 훌륭한 설비, 시설 등의 물리적 품질 개선 노력으로 고객만족도를 더욱 더 증가시킬 수 있도록 해야 한다(박종오 등, 2010).

자동차 서비스센터를 찾는 고객들은 무엇보다도 자신의 자동차에 발생한 문제가 신속하고 완벽하게 수리되기를 원하고 있고, 서비스센터의 결과품질자원이 상호작용품질이나 환경품질보다 전반적인 서비스센터의 품질 인식에 더 관련성이 높은 것으로 나타났다(박소진, 2019).

<표 1>은 자동차 부품 연도별 매출 추이로 전체적인 증감률(%)은 2019년 대비 2020년 감소하였지만 A/S부품은 코로나19 영향에도 2020년 3조 5,636억 원으로 증가되었다(자동차공업협동 조합, 2022). 이와 같이 자동차 보수 및 A/S 부품 시장의 규모를 고려하면 자동차 부품시장을 효과적으로 관리하는 문제는 크게는 국가 경제적 관점에서 작게는 자동차 소유자 개개인의 경제적 관점에서 매우 관심 있는 사안이라 할 수 있다(오재건, 신현승, 2005).

한국소비자원은 자동차 부품 보유 기간을 동일한 형식의 자동차를 최종 판매한 날부터 8년(단, 성능·품질 상 하자가 없는 범위 내에서 유사 부품 사용가능)으로 명시하고 있다. 자동차

A/S센터는 단종 차량 모델이라도 8년 동안 수리 가능할 수 있도록 부품 수급을 유지하고 부품 부족으로 인한 수리 지연으로 고객 불만을 최소화하여야 한다. 이는 고객서비스 만족도를 향상시키고 수리비 중 부품 이윤을 극대화하기 위해서도 적정 부품 재고 보유는 중요한 사안이라 할 수 있기 때문이다.

예를 들어, 완성차 업체 ‘A’사의 경우는 서비스 부품을 공급하기 위한 취급 품목이 44만 품목인데, 이 중 월간 수요 품목이 평균 4만 5천 품목으로 전체의 10%을 차지하며, 나머지 90% 재고는 불균형 수요를 위한 대기 품목으로 나타났다(주우진 등 2004). 이는 부품 대기 품목에 대한 창고 및 관리 비용의 원인으로, 부품 수요에 대한 정확한 예측이 부품 대기 품목을 줄이는 방안이 요구되고 있다.

간헐적이고 불규칙적인 수요 패턴, 제품의 복잡성에 따른 많은 종류의 부품, 제품 수명주기 단축으로 인한 진부화(Obsolescence)의 위험성, 부품 부족으로 인한 고객 불만을 방지하기 위한 매우 높은 서비스 수준 요구사항 충족이라는 서비스 부품의 특성으로 인하여 수요의 예측에는 많은 어려움이 따르는 실정이다(권익현, 2017).

<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

본 연구에서는 자동차 A/S센터의 서비스 제품에 대하여 구매, 판매수량 및 수요 발생 기간의 보유 수량의 시계열 데이터와 LSTM 인공신경망 모델을 이용하여 수리 부품의 적정 재고수량 예측 모델을 구현하고자 한다. 또한 이를 통해 부품 부족으로 인한 수리 지연을 해소함으로써 고객 서비스 품질 향상 및 자동차 수리 서비스 시장의 고객만족에 기여하고자 한다. 마지막으로 긴급 주문으로 인한 고원가 구매와 과잉 보유 재고를 방지함으로써 보관 및 관리 비용을 절감하여 부품 재고 관리의 효율성을 향상 시키고자 한다.


2장에서는 국내 자동차 정비서비스 현황 및 A/S 부품 수요의 특징과 함께 LSTM 인공 신경망 모델을 설명하고 3장에서 본 연구의 프레임워크와 데이터 분석자료, 자동차 A/S 부품의 수요 발생 유형을 파악한 후 4장에서는 LSTM 인공 신경망 모델 적용하여 예측 성능을 비교한다. 5장에서는 결론과 시사점 그리고 본 연구의 한계점과 향후 연구 방향을 제시한다.

## II. 이론적 배경

### 2.1 인공신경망



(a) 단층 인공신경망



(b) 다층 인공신경망

<그림 1> 단층/다층 인공신경망 구조(Abraham, A., 2005)

#### 2.1.1 인공신경망(Artificial Neural Network, ANN)

인공신경망은 서로 연결되어 있는 뉴런(Neuron)과 뉴런이 정보를 주고받는 사람이나 동물의 신경계 구조를 기반한 수학적 모형으로 1958년 Rosenblatt의 퍼셉트론(Perceptron) 학습 규칙 개념의 등장에 따라 인공지능 개발 분야에서 큰 기대와 주목을 받았고, 이 후 1969년 Minsky and Papert가 퍼셉트론이 간단한 XOR 분류조차 수행할 수 없음을 수학적으로 증명하여 그 한계가 밝혀졌다. 하지만, 1986년 Rumelhart et al.이 은닉층을 가진 다층 퍼셉트론을 학습할 수 있는 방법으로 역전파 알고리즘(Back-propagation algorithm) 소개함으로써 인공신경망에 대한 다양한 연구와 적용이 발전되어 왔다(정성훈, 진창하, 2020).

인공신경망은 <그림 1>과 같이 데이터를 입력받기 위한 입력층(Input layer)과 입력된 데이터에 대한 학습을 수행하는 0 또는 1개 이상의 은닉층(Hidden layer) 그리고 최종적인 범주를 결정하기 위한 출력층(Output layer)으로 구성되어 있고 각 층은 입력값을 처리하기 위한 유닛(Unit) 또는 노드(Node)로 이루어져 있으며, 각각의 노드들은 활성화 함수를 통해 입력된 값들을 다음 층으로의 전달여부를 결정한다

(Abraham, A., 2005; 이재성, 2016).

인공신경망의 특수한 모델인 딥러닝(Deep learning)은 기존의 신경망을 다루는 네트워크들을 보다 더 큰 깊이 즉, 2개 이상의 은닉층을 갖는 인공신경망으로, 기존의 신경망보다 더 복잡한 모델을 사용하여 인식 성능을 향상시킨 결과라고 볼 수 있다(최희열, 민윤홍, 2015).

### 2.1.2 수요 예측(Demand Forecasting)

수요예측(Demand Forecasting)은 소비자들이 구매하고자 하는 재화나 서비스의 판매 가능성을 과거의 정보나 자료를 이용하여 추정하는 과정으로, 산업 측면에서 볼 때 산업 전체의 수요가 질적, 양적으로 어떤 경향을 나타내고 어떤 상태에 있는가를 과거 및 현재의 자료를 기초하여 예측하는 것이다(김종배 등, 2021). 그리고 수요 패턴은 크게 규칙성과 불규칙성으로 나누어지며, 규칙적인 패턴은 주문이 정기적이고 주문량이 일정한 경우로 주로 회귀모형이나 시계열 모형을 통해서 수요를 예측하는 방법들이 사용된다. 그러나 불규칙적이고 주문량의 변동 폭이 큰 경우 이러한 수요는 간헐적 수요라고 하고 기존의 방식으로는 수요 예측의 오류 발생 가능성이 높다(유병철, 박영태, 2021).

시계열 데이터의 전통적인 수요 예측 모형으로는 Box Jenkins의 ARIMA이다(Box, G. E. et al., 2015). 규칙적인 패턴의 수요의 주기적인 관측 값에 대한 추세와 경향에 적합한 ARIMA 모형은 불규칙적이고 간헐적인 시계열 데이터에는 적용할 수 없다(박진욱, 박상현, 2017).

자동차의 수리 부품은 판매 후 서비스(After-sales Service) 부품으로 그 종류가 매우 다양하

고 산업계에 차지하는 비중 또한 매우 크다. 그리고 서비스 부품에 대한 수요 예측을 통해 얻을 수 있는 이익(예: 재고비용감소 및 고객 서비스 수준 증가 등)이 매우 클 것으로 예상 된다(권익현, 2017). 그러나 서비스 부품의 주요 특성인 불규칙적인 수요 패턴과 간헐적 수요는 전통적인 ARIMA모형으로는 한계를 보이고 있다(박진욱, 박상현, 2017, 병훈, 김현철, 2017, 김재성 등, 2020).

### 2.1.3 연구사례

인공신경망을 이용한 수요 예측은 다양한 산업 분야에서 과거의 축적된 시계열 데이터를 인공신경망 모델에 적용 및 예측하여 기업 경영 계획 수립 및 주요 의사결정에 활용하고 있다. 예를 들어, 이영찬과 서창갑(2001)은 인공신경망과 시계열 모델을 이용하여 항공기 기내식 수요예측의 예측력 개선 방안을 제시함으로써, 기내식의 낭비를 줄여 정시 출발 및 비용 절감으로 가격 경쟁력 향상과 고품질의 고객 서비스에 기여하였다. 공동석 등(2010)은 도시 계획단계에서 활용할 수 있는 에너지수요예측 기법을 인공신경망을 기반으로 수요예측 시뮬레이션을 구현함으로써 에너지 사용량 프로파일 분석 및 수요에 기반 한 도시차원의 에너지 사용계획 가능성을 제시하였다. 박진욱과 박상현(2017)은 주기성과 자기 상관성이 존재하지 않는 일별 야구 관중 수 예측은 ARIMA 분석 절차를 적용할 수 없는 한계로 인공신경망 모형을 활용함으로써 자기 상관성이 존재하지 않은 시계열 자료의 예측을 가능케 하였다. 오병훈과 김현철(2017)은 육군 장비정비정보체계의 퀘드 특정장비의 품목별 소요실적 자료를 평균수요

발생구간(ADI)과 변동계수(CV<sup>2</sup>)로 구분하여 ARIMA, 지수평활, Croston, TSB 인공지능망을 적용하여 예측 실험 결과, 인공지능망 기법이 가장 오차가 적은 우수한 결과로 극단적인 수요 변동에 대해 유연하게 대응함으로써 간헐적 수리부속의 수요예측 연구의 계기가 마련되었다. 마지막으로 최정기와 최진영(2021)은 간헐적 수요를 갖는 철도 차량 유지보수 부품을 위한 수요 예측 문제를 개선하기 위해 기계학습 기반 수요 예측 모델을 제안하였으며, 부품을 수요의 평균 발생 주기(ADI)와 수요량의 변동성을 나타내는 변동계수(CV<sup>2</sup>)를 기준으로 유사한 특징을 나타내는 부품들로 군집화하여 의사결정나무트리, 랜덤 포레스트, 인공 신경망 알고리즘을 활용하여 수요 예측을 실시한 결과 군집 수가 7개인 경우 인공 신경망 알고리즘이 가장 우수한 성능을 보였다.

이와 같이 인공지능망 기법은 시계열 데이터에 대한 수요 예측 연구에 활발히 활용되고 있다. 그러나 학습 시간이 장기화 될 경우 에러신호가 유실되는 장기 의존성 문제가 나타나게 되었다. 이를 극복하기 위해 새로운 인공지능망 모델인 장단기메모리(LSTM)가 출현하였고, 다음과 같이 수요 예측을 위한 LSTM 모델 연구도 꾸준히 증가하고 있다. 신성호 등(2018)은 자연 재해로부터 받을 수 있는 여러 영향 중 농산물 가격 변화에 대한 효과적인 대응 방안을 수립하기 위해 딥러닝 기반의 농산물 가격 예측 모델을 제안하여 LSTM 모델이 약 93%의 높은 정확도 예측력을 검증함으로써 농산물 수급을 위한 정부 정책 수립 및 일반 소비자들에게도 유용한 정보로 활용될 수 있을 것으로 기대된다고 하였다. 조영기와 이현수(2020)는 지

능화 및 고도화된 고품질 전력 서비스인 스마트 그리드 구축을 위해서는 전력 데이터를 이용한 전력 수요 예측이 가장 중요한 선행 연구로, 시계열 적용과 회귀분석을 이용한 기존 예측보다 인공 신경망을 통한 전력 수요 예측이 데이터의 평균이나 오차가 아닌 신경망 학습에 초점을 맞춘 LSTM이 우수하였으며 LSTM 모형에 Attention Mechanism을 결합한 MA-LSTM은 적은 시계열 데이터 보유 시 예측 연구 등에 대한 적용 가능성을 제시하였다. 김종진과 김지연(2020)은 미국의 대표적인 글로벌 기업들에 대한 주가 데이터를 바탕으로 딥러닝 모델인 LSTM을 이용한 주가 예측 모델을 구현하고 적용함으로써, 주식과 같은 금융 분야에도 예외 없이 효과를 보고 있으며, LSTM 모델은 시계열 데이터에 대한 예측 모델로서 검증하였다. 이현상과 오세훈(2020)은 KOSPI, KOSDAQ, KONEX에 속하는 비금융업 2,362개 기업의 대상으로 최근 18년 간의 재무적, 비재무적 데이터를 활용하여 기업 신용 등급을 예측할 수 있는 LSTM 기반 딥러닝 모델을 구축하였고 이를 통해 기업 신용 위험 예측에 있어서 단기적 관점에서의 예측뿐만 아니라 장기적 관점에서의 예측 또한 가능해졌다. 김재성(2020)등의 연구에 따르면 가구 부자재를 생산하고 있는 제조업체의 생산, 자재 및 물류 등의 계획과 관리 그리고 고객의 니즈와 트렌드 변화에 따라 정확한 수요를 예측하고자 통계적 예측 기법인 ARIMA, 인공지능분석기법인 다변량 LSTM, 다변량 LSTM, 1D-CNN으로 예측을 진행하였다. 그 결과, 추세를 반영할 수 있는 다변량 LSTM의 예측 성능이 가장 우수하였다. 민소아와 정윤서(2021)의 연구에

서는 환경 및 교통 문제 현안의 대안으로 공공 자전거 이용 활성화 정책 양산 및 그 사용량의 증가로 공공자전거의 일별 대여 이력을 바탕으로 공공 자전거 수요 예측을 위한 모형들을 비교 분석한 결과 딥러닝 기반의 LSTM 모형이

벡터 자기회귀 모형(VAR), 서포트 벡터 회귀 모형(SVR) 보다 뛰어난 예측 성능을 높게 평가되었다.

위의 연구 사례와 같이 기존 인공지능망 기반 수요 예측 연구는 시계열 데이터 특성과 예

<표 2> 인공지능망 수요 예측 사례

연구자	연구내용	ANN모형	평가지표
이영찬과 서창갑 (2001)	인공신경망과 시계열 모델을 이용하여 항공기 기내식 수요예측의 예측력 개선 방안을 제시.	Hyper-Hybrid ANN	NMSE, MAE, MSE
공동석 등 (2010)	에너지 사용량 프로파일 분석 및 수요에 기반한 도시차원의 에너지 사용계획 가능성을 제시.	Multi-Perceptron ANN	MSE, MBE, RMSE
박진욱과 박상현 (2017)	주기성과 자기 상관성이 존재하지 않는 일별 야구 관중 수를 예측함으로써 자기 상관성이 존재하지 않은 시계열 자료의 예측 가능성 제시.	Feed Forward ANN	RMSE, MAPE
오병훈과 김현철 (2017)	특정장비 소요실적 자료를 평균수요발생구간(ADI)과 변경계수(CV <sup>2</sup> ) 구분된 간헐적 수요 품목 예측을 전통적 통계 기법 및 ANN 모델에 대한 비교 연구 결과, 극단적인 수요의 경우 ANN 모델이 우수성 입증.	Feed Forward ANN	MAE
최정기와 최진영 (2021)	철도 차량 유지보수 부품을 평균수요발생구간(ADI)과 변경계수(CV <sup>2</sup> )로 수요의 특성을 추출(군집화)하여 수요가 일정하지 않는 부품에 대한 예측모델 제안.	ANN	MSE, MAE
이현상과 오세훈 (2020)	재무적, 비재무적 데이터 기반의 기업신용 등급 예측 모델을 구현하여 장·단기적 관점에서의 예측 가능성을 제시.	DNN CNN LSTM	Accuracy Precision Recall F1-score
신성호 등 (2018)	농산물 가격 변화(수요)에 대한 효과적인 대응 방안을 수립하기 위한 LSTM 기반 농산물 가격 예측 모델을 제안.	LSTM	RMSE
조영기와 이현수 (2020)	ARIMA와 LSTM 모델을 이용한 전력 수요 예측 연구 결과 LSTM 모델이 우수하였으며 적은 시계열 데이터를 예측할 수 있는 MA-LSTM 모형 제시.	LSTM MA-LSTM	RMSE
김재성 등 (2020)	제품군별 가구 판매 수요 예측에 대하여 통계적 예측 기법인 ARIMA와 ANN의 단변량 LSTM, 다변량 LSTM, 1D-CNN 비교 연구 결과 추세를 반영할 수 있는 다변량 LSTM 모델 제안.	LSTM 1D-CNN	MAPE, RMSE, RMSLE
김종진과 김지연 (2020)	주식과 같은 금융 분야의 시계열 데이터에 대한 예측모델을 검증하였으며 모델 성능향상을 위한 하이퍼파라미터 설정과 적용 함수에 대한 실증적인 실험 연구.	LSTM	RMSE
민소아와 정윤서 (2021)	공공자전거 일별 대여 시계열 데이터를 이용하여 시계열 군집분석, 머신러닝과 인공신경망 모델을 활용한 예측 성능 비교 연구.	LSTM	RMSE, MAE

측에 적합한 모델 선정 보다는 성능 향상에 대한 연구였다(이영찬, 서창갑, 2001, 공동석 등, 2010, 박진욱, 박상현, 2017, 오병훈, 김현철, 2017). 그리고 최근 시계열 데이터 예측 성능이 우수한 LSTM 모델 연구에서도 간헐적 수요의 이상치(Outlier)를 극복할 수 있는 다양한 평가 지표들이 고려되지 않았다(신성호 등, 2018, 조형기, 이현수, 2020, 김종진, 김지연, 2020, 이현상, 오세훈, 2020, 민소아, 정윤서, 2021). 이러한 연구들과는 달리 본 연구는 자동차 A/S센터 서비스 부품의 수요 시계열 데이터를 평균수요 발생구간(ADI)과 변동계수(CV<sup>2</sup>)를 부품별로 산출한 후 수요 특징을 파악하고 수요 유형 중 간헐적 수요 특성의 부품에 대한 시계열 데이터를 LSTM 인공 신경망 모델에 적용하였다. 모델 평가 지표는 이상치에 덜 민감하고 강건한 MAPE, RMSE, RMSLE를 이용하여 모델 성능 평가를 수행하여 최적의 자동차 A/S 수리 부품에 대한 수요 예측 모델을 제안하였다.

## 2.2 자동차 정비서비스 및 A/S 부품 수요 특징

### 2.2.1 자동차 정비서비스

자동차의 정비서비스는 고객의 생명과 재산을 보호하는 기능과 자연 환경보호의 역할과 함께 자동차 수명의 연장과 연료소모 방지 등의 경제 지향적 측면의 중요한 역할을 담당하며, 자동차 고장에 대한 사전정비와 예방점검은 자동차의 수명연장은 물론 연료소모를 방지해 줌으로써 국가경제에도 이바지한다(여주대학 산업기술연구소, 2001).

자동차 정비서비스를 전문적으로 수행하는 자동차 정비업은 자동차를 점검하고 정비하여, 자동차의 구조 및 장치의 변경작업을 업으로 하는 것을 의미하므로, 자동차 정비서비스는 차량 유지, 차량수리 그리고 차량문제 해결 등과 같은 판매 후 서비스 요소로 작용한다(김영석, 2017).

자동차 점검이란 자동차 구조장치의 기능이 정상적인지의 여부를 확인하는 것이며 정비는 급유, 조정부품의 교환수리 그 외의 자동차 구조, 장치의 기능을 정상적으로 회복, 유지하기 위한 행위이다(김형길, 오영희, 2003). 자동차 정비업은 모든 종류의 자동차에 대한 점검, 정비 및 구조변경, 작업으로 종합 정비업(1급 정비업체)은 종합병원처럼 자동차의 종합 정비를 시행할 수 있으며, 소형 정비업(2급 정비업체)은 대형을 제외한 종합정비를 시행할 수 있고, 부분 정비업(카센터)은 엔진, 미션, 파워스티어링 기어, 인젝션펌프 등의 작업을 제외한 소모성 부품 및 소모품 교환 등을 시행할 수 있다(김수도, 2011).

자동차관리사업은 자동차 관리법에 따라 자동차 매매업, 자동차 정비업, 자동차 해체재활용업으로 구분된다. 2021년 12월 국내 자동차관리사업 현황으로 연도별 정비업 현황을 보면, <표 3>과 같이 매년 점진적으로 증가하고 있으며, 자동차 등록 대수 또한 <표 4>의 자동차 등록 현황에 나타난 것과 같이 매년 2% 이상 증가되었다. 정비서비스센터의 입고 대수도 매년 증가하면서 차량 입고 시 부품 부족으로 인한 수리 지연을 최소화하고 안전재고를 유지하여 고객 정비서비스 품질 향상에도 기여하기 위해서는 A/S 부품에 대한 수요 예측이 중요한 요소로 부각될 것으로 보인다.

<표 3> 자동차관리사업 현황(2021년 12월 기준 사업체 수)

구분	정비업					매매업	해체 재활용업	성능 점검업	지정 정비
	종합	소형	전문	원동기	소계				
합계	4,473	2,205	29,540	236	36,454	6,301	560	475	1,876
서울	179	316	2,899	4	3,398	526	0	29	62
부산	160	190	1,481	11	1,842	381	9	29	82
대구	148	119	1,443	16	1,726	636	11	51	72
인천	270	130	1,339	6	1,745	283	6	16	72
광주	206	59	1,065	8	1,338	256	8	14	50
대전	133	36	975	7	1,151	292	7	12	42
울산	111	60	731	6	908	183	9	8	50
경기	1,155	635	7,333	60	9,183	1,377	148	101	420
강원	186	101	1,279	4	1,570	216	34	27	105
충북	218	52	1,175	13	1,458	240	33	12	89
충남	325	80	1,726	23	2,154	327	47	21	143
전북	273	49	1,442	10	1,774	321	48	16	115
전남	350	88	1,480	9	1,927	251	51	48	150
경북	314	111	2,208	27	2,660	438	75	37	198
경남	349	160	2,457	26	2,992	486	58	45	168
제주	77	11	403	6	497	83	11	6	50
세종	19	8	104	0	131	5	5	3	8
연도별 정비업 현황			2015	2016	2017	2018	2019	2020	2021
			35,350	35,618	35,866	36,104	35,847	35,956	36,454

출처: 국토교통 통계누리, 자동차관리사업제현황 분기

<표 4> 자동차 등록현황

	2021	2013	2014	2015	2016	2017	2018	2019	2020
등록대수(만대)	1,887	1,940	2,012	2,099	2,180	2,253	2,320	2,368	2,437
전년대비 증가대수(천대)	433	530	717	871	813	725	674	475	689
전년대비 증감비(%)	2.3	2.8	3.7	4.3	3.9	3.3	3.0	2.0	2.9

출처: e-나라지표, 자동차 등록 현황

### 2.2.2 자동차 A/S센터 부품 분류 및 수요의 특징

#### (1) 자동차 A/S센터 부품 분류

자동차 A/S용 부품은 판매된 차량의 본원적 기능을 유지하기 위해 소요되는 부품을 가리키며, 기능적으로 필요한 기능 부품을 ‘보수용 부품’이라고 부르고 ‘기능성 부품’과 ‘소모성 부품’으로 나눌 수 있으며, 반드시 필요하지 않

나 편의성 향상이나 장식 목적으로 사용되는 부품을 ‘용품’이라고 부른다(오재건, 신현승, 2005). 자동차 부품은 유통과정에 따라 3가지 형태로 분류되며, 첫 번째는 자동차 회사 또는 그 회사의 자회사에서 인증하고 공급하는 신규 부품으로 일반적으로 ‘순정 부품’이라고 불리며, 인증 과정에서 부품의 불량과 성능을 확인하여 유통하기 때문에 안정성이 보장된다. 둘째



는 신규 부품이지만 인증 받지 못한 부품으로 통상 ‘비 순정 부품’ 또는 ‘비품’이라고 불리며 ‘순정 부품’에 비하여 70~80% 저렴한 가격대를 형성하고 있다. 셋째는 성능 저하나 사고 또는 폐차로 인하여 발생하는 코어 부품을 활용한 ‘재활용 부품’으로 구분된다(김기현, 이홍철, 2014). 자동차 부품 물류 센터의 취급 상품은 SKU(Stock Keeping Unit) 기준으로 38,000 가지 이상 보유하고 관리하고 있다. 각각의 SKU는 자동차 수리에 필수적인 상품이며 신차가 출고되고 10년 간 정기적인 수리를 해야 하기에 물류센터의 부품 수는 점점 증가하는 추세이며 부품 물류센터의 전체적인 상품의 구성은 크게 휠더, 커버, 범퍼, 헤드램프, 후드, 브레이크 라이닝, 사이드 패널, 기타 소모품 등 다양하다(박병준, 여기태, 2021).

(2) 자동차 A/S센터 부품 수요의 특징

<그림 2>와 같이 자동차 A/S용 부품 수요 패턴을 보면, 불규칙적인 고장율과 예측할 수 없는 자동차 사고 등으로 그 수요와 공급이 일정하지 않고 모든 차종 부품을 보유하는 것은 보관 창고 공간이나 관리 비용 등의 문제로 일부 한정된 소량의 부품만 보관하고 있어 해당 부

품의 수리 발생 시마다 항상 긴박하게 부품 공급 주문이 이루어지고 있다.

연구 대상으로 선정된 해당 서비스센터의 경우 2021년 월 평균 1,200대를 입고하여 수리를 진행하지만 보유 부품은 6,000개로 부족한 부품은 상황에 따라 긴급, 주별, 월별 주문으로 보충하고 있다. 긴급 주문은 부품 공급사가 부품을 보유하고 있는 경우 당일 또는 다음 날 배송 받을 수 있는 주문으로 구매 시 할인율이 가장 낮고 다음으로 주별, 월별 주문 순으로 할인율이 높아진다. 따라서, 본 연구의 부품 수요 예측 모델은 부품 수요를 미리 예측하고 선 주문 및 재고를 보유함으로써 저 원가 구매로 인한 부품 이윤의 극대화와 부품 부족으로 인한 수리 지연을 미연에 방지하여 고객 서비스 향상에 기여할 것으로 기대된다.


2.3 LSTM 인공 신경망 모델 및 성능 평가

2.3.1 LSTM 인공신경망 모델

LSTM(Long Short-Term Memory)은 장단기 메모리 인공신경망 모델로 학습 시간이 장기화되면서 반복적인 역전파(Back-propagation)로 학습시간이 오래 걸리고 에러 신호가 유실되는



<그림 2> 자동차 A/S 부품 수요의 특징(강민경 등, 2014)



<그림 3> 표준 RNN 구조의 단일 레이어 순환 모듈(Olah, 2015)

순환신경망(Recurrent Neural Network, RNN)의 문제를 극복하기 위해 그래디언트 기반 학습 알고리즘과 연계된 새로운 순환 신경망 모델이다(Hochreiter, et al, 1997). 모든 순환 신경망은 신경망의 반복 순환하는 모듈의 체인 형태로 <그림 3>과 같이 단일 레이어 구성된 표준 RNN 모델로 출력  $Y_t$ 는 이전 입력 값  $X_{t-1}$ 의  $h_{t-1}$ 과  $X_t$ 를 하이퍼볼릭타나젠트(Hyperbolic Tangent, tanh) 활성화 함수(Activation function)의 출력으로 식 (1)과 (2)와 같다.


$$Y_t = W_{hy}h_t + b_y \quad (1)$$

$$h_t = \tanh(W_{hh}h_{t-1} + W_{xh}X_t + b_h) \quad (2)$$

이와 같이 RNN 모델은 tanh 함수 특성 때문

에 W(Weight) 값이 특정 값에 수렴하게 되어 시간이 지남에 따라 훨씬 이전에 입력된 데이터의 영향력이 감소하는 장기 의존성 문제가 발생한다(김영균, 김민구, 2019).

LSTM 인공신경망 모델은 RNN의 장기 의존성 문제를 해결하기 위해 1997년 Hochreiter, S. Schmidhuber, J.에 의해 등장하게 되었다. Hochreiter, S. Schmidhuber, J.의 표준 LSTM은 임의의 시간 시차에 걸쳐 정보를 저장하고 오류 신호를 이전 시간으로 전송할 수 있는 장점이 있지만, 특정 시계열의 경우 메모리 블록의 셀 상태가 선형적으로 무제한 증가하면서 출력 셀의 포화 상태로 메모리 셀의 저장 기능이 멈추게 되는 문제를 해결하기 위하여 입력 게이트(input gate, it) 앞 단에 망각 게이트



<그림 4> LSTM 구조의 4개 레이어 상호 작용 순환 모듈(Olah, 2015)

(forget gate, ft)를 추가하여 오래된 메모리 셀에 대하여 리셋 또는 점진적으로 리셋 함으로써 메모리 블록을 재설정 후 입력 게이트로 전송한다(Gers et, al., 2000).

따라서, Hochreiter, S. Schmidhuber, J(1997).와 Gers et, al.,(2000, 2001)의 이론에 따라 <그림 4>와 같은 메모리 블록 내에 망각 게이트(Forget gate, ft), 입력 게이트(Input gate, it), 출력 게이트(Output gate, ot)와 CEC(Constant Error Carousel, Ct)의 로직으로 동작하는 기본적인 LSTM 모델이 등장하게 되었으며 각 게이트와 CEC 로직은 아래와 같다(Olah, 2015).

수식(1) 망각 게이트는 이전 히든 상태값(ht-1)과 현재의 입력 값(Xt)을 시그모이드(Sigmoid)하여 이전 CEC(Ct-1) 저장 상태(또는 여부)를 결정한다.

$$f_t = \sigma(W_t \cdot [h_{t-1}, X_t + b_t]) \quad (1)$$

수식(2) 입력 게이트는 이전 히든 상태 값과 신규 입력 값을 시그모이드하여 업데이트한 값과 수식(3) 이전 히든 상태 값과 신규 입력 값의 tanh로 신규 벡터 값을 계산한 후 수식(2)와 수식(3)을 곱셈하여 저장해야 되는 신규 입력 예상 값을 결정한다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t + b_i]) \quad (2)$$

$$\tilde{C} = \tanh(W_c \cdot [h_{t-1}, X_t] + b_i) \quad (3)$$

수식(4) CEC(Ct)는 이전 상태 값(Ct-1)과 망각 게이트(ft)를 곱하여 이전 상태 값의 유지 정도 값(0~1, 0 전체 삭제, 1 전체 유지)과 입력

게이트(it)와 신규 입력에 대한 벡터값의 곱을 더하여 현재 상태의 CEC(Ct)를 결정한다.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

수식(5) 출력 게이트는 이전 히든 상태 값과 신규 입력 값의 시그모이드하여 출력 값을 결정하고 수식(6)은 현재의 히든 값으로 출력 게이트의 값(ot)과 현재의 CEC(Ct)의 tanh 값을 곱셈으로 결정된다.

$$o_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

요약하면, 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.

### 2.3.2 LSTM 모델 성능 평가

LSTM 인공 신경망 모델의 평가 측정 지표로 표준통계지표 중 근접성 측정 기준이 되는 MAE(Mean Absolute Error), MPE(Mean Percentage Error), MSE(Mean Squared Error), MAPE(Mean Absolute Percentage Error), RMSE(Root Mean Squared Error), RMSLE(Root Mean Squared Log Error) 등을 사용하고 있다.(Harrou, F., et al., 2020, Adekoya, A. F., et al., 2021, Khan, S., et al., 2021, 김재성 등, 2020).

본 논문은 기간에 따른 수치가 차이가 크고

이상치에 덜 민감한 MAPE, RMSE, RMSLE으로 성능 평가를 진행하였다.

(1) MAPE(Mean Absolute Percentage Error)

평균 절대 백분율 오차로 MAE(Mean Absolute Error)를 퍼센트로 변환한 것으로 실제값과 예측값의 오차(잔차)의 절대값의 평균을 기간으로 나누어 백분율로 계산한 것으로 기간에 따라 수치의 차이가 큰 경우 유용한 지표이다.

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \cdot 100}{n}$$

(2) RMSE(Root Mean Squared Error)

평균 제곱근 오차로 오차(잔차)의 제곱 평균 MSE(Mean Squared Error)의 제곱근으로 MSE보다 이상치에 덜 민감하고 수식은 아래와 같다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

(3) RMSLE(Root Mean Square Log Error)

평균 제곱근 로그 오차로 평균 제곱 로그 오차 MSLE(Mean Squared Error)의 제곱근으로 RMSE보다 이상치에 강하고 실제값과 예측값의 상대적 오차를 측정하는 지표이다.

$$RMSLE = \log \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

MAPE는 위에서 언급한 것과 같이 백분율 값으로 MAPE가 3이면 예측값이 실제값과 평균적으로 3%차이를 의미하고 RMSE는 실제값과 예측값의 차이가 직관적이다. 따라서, RMSE가 3이라면 평균적으로 3정도의 값이 실제값과 잘못 예측되었다. RMSLE는 실제값의 상대적 오차로 오차는 같지만 실제값과 예측값의 수치가 크기가 다른 경우 예측 모델의 성능을 비교할 수 있는 지표이다.

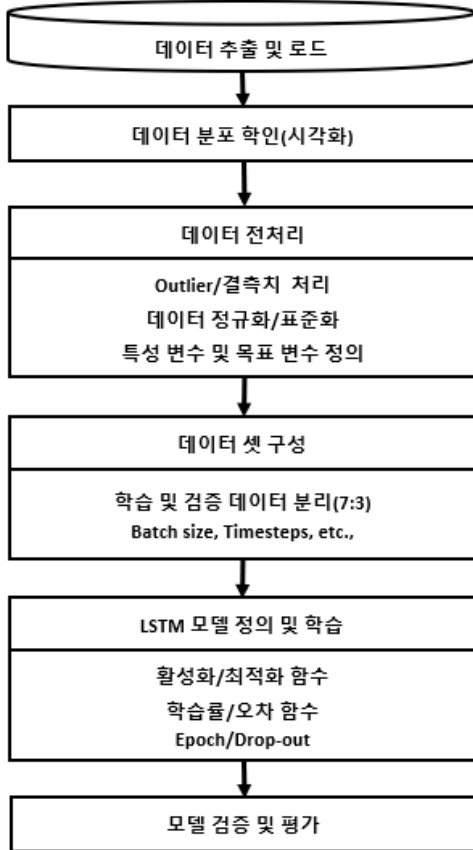
### Ⅲ. 연구방법

월 입고 대수 1,200대 규모의 소형 정비업(2급 정비업체)이상 종합 정비가 가능한 자동차 서비스센터의 부품 중 장식을 위한 ‘용품’을 제외한 보수용 부품 및 자동차 제조사나 그 회사에 부품을 공급하는 자회사의 인증 신규 부품인 ‘순정 부품’을 수요 예측 대상으로 한정하였다.

제조사의 공식 서비스센터는 제조사에서 제공하는 부품 재고 관리 시스템으로 주문, 발주, 입고 후 수리에 대한 업무 프로세스로 관리하고 있다. 이와 같이 축적된 부품 수요 시계열 데이터를 추출하여 각 부품의 수요 유형을 파악한 후 연구 대상 부품들을 일별, 주별, 월별 수요 데이터를 파이썬 주피터 노트북을 이용하여 LSTM 모델에 적용 및 수요 예측을 수행하였다.

수요 예측은 일별, 주별, 월별의 부품 이전 재고 수량과 구매, 판매 수량으로 최적의 보유 재고 수량을 예측할 수 있는 모델을 구현하였다. 예측 모델의 성능 평가는 MAPE, RMSE, RMSLE 지표로 비교 평가 진행하였으며, 예측

모델 구성도는 <그림 5>와 같다.



<그림 5> 수요 예측 모델 구성도

### 3.1 데이터 선정

본 연구는 종합 정비 수리업을 하고 있는 국

내 수입 자동차 A/S센터의 전체 부품에 대한 수요 데이터 추출하여 2021년까지 판매 이력을 가진 부품을 대상으로, Syntetos et, al(2005)의 평균 수요 간격(ADI, Average demand interval) 과 수요 크기의 변동계수(CV<sup>2</sup>, coefficient of variation)로 <표 5>와 같이 수요 발생 유형을 구분하고 유형별로 분석 데이터를 선정하였다.

평균 수요 간격(ADI)은 0이 아닌 두 수요 사이의 평균 간격으로 수식은 아래와 같다. ADI가 1.9이면 평균적으로 1.9 시간 주기마다 0이 아닌 수요가 발생한다고 할 수 있다.

$$\text{평균수요간격 (ADI)} = \frac{\text{대상기간}}{\text{0수요가아닌기간의수}}$$

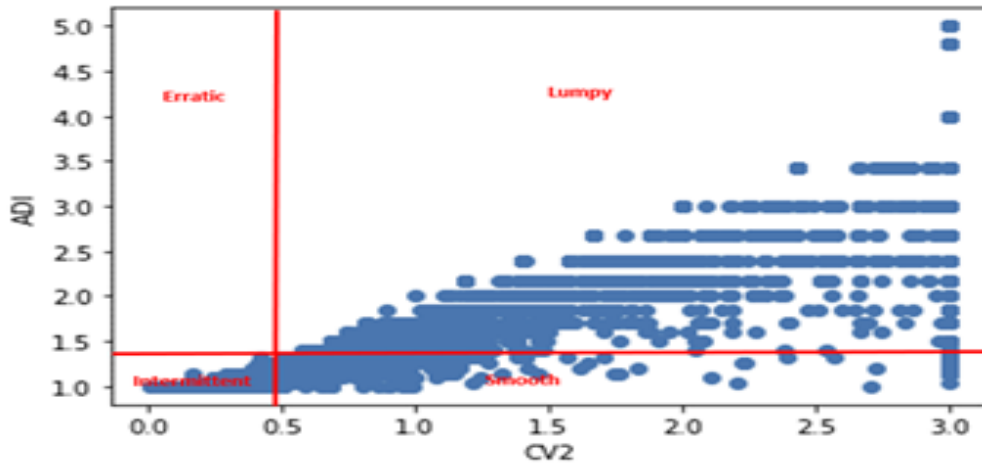
변동 계수(CV<sup>2</sup>)는 데이터의 흩어진 정도이며 시계열 변동성을 나타내는 척도로 수식은 아래와 같다.

$$\text{변동계수 (CV}^2\text{)} = \frac{\text{표준편차}}{\text{평균}}$$

본 연구의 데이터는 2020년 3월부터 2022년 2월까지의 2년(24개월)의 대상기간으로 ADI와 CV<sup>2</sup>를 각 A/S 부품별로 산출 및 수요 발생 유형을 구분하였으며 각 유형별 분포는 <그림 6>

<표 5> 수요 발생 유형 구분

유형	설명	분류 기준
Smooth (원만한 수요)	수요발생 기간과 수량이 규칙적으로 발생하는 품목	ADI < 1.32 and CV <sup>2</sup> <0.49
Intermittent (간헐적 수요)	수요수량의 변동이 거의 없지만 수요 간격이 크게 변화하는 품목	ADI < 1.32 and CV <sup>2</sup> >=0.49
Erratic (불규칙 수요)	수요량이 불규칙적으로 발생하는 품목	ADI >= 1.32 and CV <sup>2</sup> <0.49
Lumpy (무더기 수요)	특정시기에 한 번에 많은 수량이 발생하는 불규칙 품목	ADI >= 1.32 and CV <sup>2</sup> >=0.49



<그림 6> 2020년 3월부터 2022년 2월까지의 2년(24개월)간 부품 유형별 분포

과 같다.

연구 대상 A/S센터의 수리 부품 16,882개 중 무더기 수요(Lumpy)가 16,295개로 96.52%로 대부분을 차지하고 있으며, 규칙적인 수요(Smooth)와 간헐적 수요(Intermittent)가 각각 333개 1.97%와 253개 1.50% 그리고 불규칙적인 수요(Erratic)는 거의 발생하지 않았다. 비교적 수요 발생 기간이 짧은 Smooth와 Intermittent 부품은 오일 또는 에어 필터, 브레이크 패드나 디스크와 같은 정기적으로 교체가 필요한 소모성 부품으로 수요 예측이 비교적 원활하지만 수요 발생 기간이 길고 변동성이 큰 Lumpy는 수요가 불규칙적이고 비선형적 형태로 전통적 시계열 예측 기법으로 예측하는

데는 제한이 있다(Hill et, al., 1996). 따라서, 본 연구는 부품 유형이 Lumpy 부품의 시계열 데이터를 LSTM 인공 신경망 모델에 적용하여 수요 예측 모델을 구현하였다.

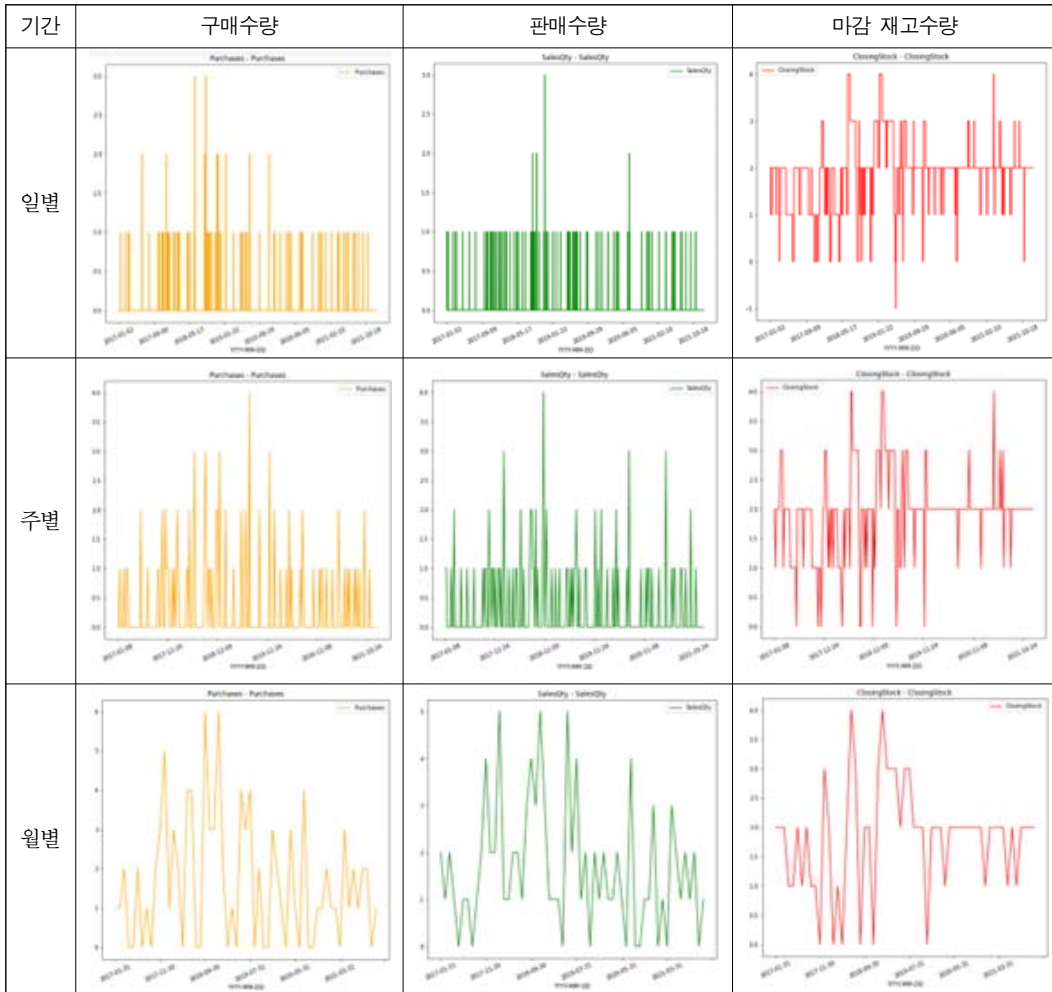
### 3.2 데이터 셋

2017년 1월부터 2021년 12월 기간 동안 판매 및 구매 수요가 있는 Lumpy 부품을 대상으로 <표 6>과 같이 일별, 주별, 월별 데이터 추출하여 데이터 셋을 구성하였다.

수요 발생일(Date)의 일(day)은 수집된 데이터의 전체 일자로 학습 대상 기간을 모두 포함하고 있다. 주(Week)는 매주 금요일 마감일, 월

<표 6> 부품 수요 시계열 데이터 셋 정의

No	Variant	Description	Feature	Target
1	Date	수요 발생일/주/월(판매, 구매)		
2	Previous_Stock	이전 재고 수량	●	
3	Purchase_Qty	실 구매 수량	●	
4	Sales_Qty	실 판매 수량	●	
5	Closing_Stock	마감 재고 수량		●



<그림 7> 최근 3년간 일/월/주별 구매, 판매, 보유 재고 수량

(Month)은 월 말일로 생성되었다. 이전 재고 수량(Previous\_Stock)은 실 구매 또는 판매 후 남은 재고 수량이고 마감 재고 수량(Closing\_Stock)은 일별, 주별, 월별 마감 후 남은 재고 수량으로 본 연구에서 예측하고자 하는 목표 변수이다.

<그림 7>은 2017년 1월부터 2021년 12월까지 최근 3년간 부품 구매, 판매, 재고 보유 수량 그래프로 특정 시기에 불규칙적으로 수량 변동

이 큰 Lumpy 수요 유형의 특징을 보이고 있다.

#### IV. 예측 모델 평가 및 검증

2017년 1월부터 2021년 12월까지의 일별, 주별, 월별 부품 수요 데이터에 대하여 각각 70%는 학습데이터, 나머지 30%는 테스트 데이터로 분리하여 LSTM 모델에 적용하여 학습 및

평가를 진행하였다. 먼저, 입력 데이터 값에 대하여 정확한 학습 및 테스트를 위해 데이터 정규화를 진행했으며 정규화 방식은 이상치 문제를 해결할 수 있는 Z-점수 정규화(Z-Score Normalization)를 이용하였다. 입력값 X가 평균과 같으면 0, 크면 양수, 작으면 음수 값을 구한 후 특정 값 이상으로 큰 경우 이상치로 제거되었다.

$$Z-Score = \frac{(\text{입력값 } X - \text{평균})}{\text{표준편차}}$$

이와 같이 데이터 전처리 이후 일별, 주별, 월별 시계열 데이터를 LSTM 모델에 적용하여 예측이 진행되었다. 모델의 성능은 하이퍼파라미터 값이 중요한 역할을 하고 있으며 각각의 값을 조정하면서 예측이 진행되었다.

<표 7>은 각 시계열 데이터의 LSTM 예측 모델 파라미터 값으로 각 레이어의 Output에 대하여 다음 레이어의 전달 여부를 결정하는 활성화(Activation)함수는 relu/tanh로 이용하고 손실함수의 최소값 학습을 위한 최적화(Optimizer)함수로 일별 데이터는 Adam, 주별과 월별은 sgd로 설정되었다. 학습률은 각각 0.001, Epochs는 200으로 적용하였으나, Early-Stopping(Patience)을 10으로 설정하여 과적합(Over fitting)을 방지하였다. 한 번에 학습할 수 있는 Batch Size는 일별, 주별, 월별 각각 30, 10, 5로 설정으로 예측을 수행하였다.

<표 8>은 각 시계열 데이터에 대한 LSTM 모델의 평가 지표로, 일별 시계열 데이터가 다른 시계열 데이터 보다 우수하게 예측되었다. 즉, MAPE를 보면 평균값과 4.8% 차이로 가장

낮았고 RMSE 또한 0.057로 정규화된 실제 값과의 평균의 차이가 다른 시계열 데이터보다 낮게 나타났다. 월별로 갈수록 부품 수요 데이터의 수치가 크게 바뀌는데 RMSLE 평가 지표 또한 일별 데이터가 가장 낮은 결과 값으로 LSTM 모델에 적용된 시계열 데이터 중 일별 시계열 데이터의 예측이 우수하게 나타났다.

본 연구의 LSTM모델의 시계열 데이터 예측은 데이터 셋 크기에 영향이 큰 것으로 판단이 된다. 수집된 데이터 셋에 대하여 데이터 전처리 과정을 거친 후에 일별 수요 데이터 셋은 1,807개, 주별과 월별은 각각 248, 42개로 줄어들면서 훈련 데이터가 충분하지 않은 주별, 월별 시계열 데이터의 성능이 급격히 저하되었다. 예측 성능 향상을 위해 데이터 셋의 수집 기간이 늘어나면 수리 부품의 단종이나 대체 부품이 성능 저하의 다른 원인이 될 수 있다. 따라서, 수요가 불규칙적인 간헐적 수요의 무더기 부품 특성과 특정 기간이 지나면 부품의 단종이나 대체 부품으로 사용 기간이 한정된 서비스센터의 수리 부품의 수요 예측은 충분한 데이터 셋도 중요하겠지만 단종이나 대체 부품으로, 수요의 종료 시점도 중요한 요인이 될 것이다.

<그림 8>은 Z-Score로 정규화된 일별 시계열 데이터에 대한 LSTM 모델의 실제 값과 예측 값 그래프로 예측 값이 비교적 실제 값을 잘 추종하고 있다. 해당 수리 부품의 일 마감 실제고 수량은 5년간 평균적으로 2개(Z-Score = 0.6)를 유지하고 있으며 재고 수량이 많은 경우 최대 4개(Z-Score = 1.0)이고 최소 0개(Z-Score = 0.2)로 부품 수요는 간헐적으로 1개 ~ 2개가 발생되고 있다. 모델의 예측도 실제고 수량을




반영하고 있지만 수요가 가파르게 상승하고 하락하는 구간(Red box)에서는 차이를 보이고 있다. 그러나 전반적으로는 평가지표의 오차 범위

<표 7> 각 시계열 데이터의 하이퍼파라미터 설정 값

하이퍼파라미터	일별	주별	월별
Activation	relu/tanh	relu/tanh	relu/tanh
Optimizer	Adam	sgd	sgd
Learning rate	0.0001	0.0001	0.0001
Epochs	200	200	200
Early-Stopping(Patience)	10	10	10
Batch Size	30	10	5

<표 8> 각 시계열 데이터의 성능 비교

평가지표	일별	주별	월별
MAPE(%)	4.7759	8.5684	21.7689
RMSE	0.0570	0.0936	0.0948
RMSLE	0.0367	0.0596	0.0690



<그림 8> 일별 시계열 데이터 LSTM 모델 실제값 vs 예측값

## V. 결론 및 시사점

본 연구는 자동차 A/S센터의 수리 부품 중 특정 기간에 불규칙적으로 무더기 수요가 발생하는 Lumpy 수요 유형에 대하여 일별, 주별, 월별 수요 데이터를 LSTM 모델에 적용하여 최적의 재고 보유 수량 예측 모델을 구현하였다.

해당 연구 대상 자동차 A/S 서비스센터의 16,259개 부품을 대상으로 ADI와 CV<sup>2</sup>를 이용하여 4가지 수요 발생 유형을 구분하였으며, 해당 수리 부품의 96.5%가 수요 불규칙적이고 특정 기간에 수요가 발생하는 Lumpy 수요 유형의 특징을 가지고 있었다. 따라서, Lumpy 수요 유형에 대하여 2017년 1월부터 2021년 12월까지 5년 동안의 부품 구매, 판매 그리고 재고수량의 데이터를 일별, 주별, 월별로 구분한 후 LSTM 모델에 적용하여 예측이 진행되었다.

각 시계열 데이터 중 일별 시계열 데이터가 MAPE, RMSE, RMSLE 값이 가장 낮은 값으로 우수하게 예측이 되었으며 다음으로 주별, 월별 시계열 데이터로 예측 성능이 떨어졌다. 이는 주별, 월별로 갈수록 학습 데이터가 줄어든 원인으로 이를 해결하기 위해 수요 발생 기간을 늘릴 경우 차량 모델의 단종과 대체 순정 부품 사용으로 기존 부품의 수요가 발생하지 않아 예측 성능이 여전이 저하되었다. 충분한 학습데이터도 중요하겠지만 외부영향에 따른 수요기간 산정도 자동차 A/S 부품 수요 예측에 중요한 요소로 제시되고 있다.

학문적 의의로는 인공지능망 LSTM 모델을 이용하여 자동차 A/S 서비스 수리 부품 중 Lumpy 수요 유형과 같이 수요가 일정하지 않고 특정 기간에 수요가 다수 발생하는 서비스

정비 부품 재고 수량 예측 모형을 제안하였다. 또한, Lumpy 부품의 시계열 데이터를 LSTM 모델에 적용하여 예측성능을 평가하고 검증함으로써 최적의 부품 재고 수요 예측이 가능한 일반화된 모형 구현 및 활용 가능성을 제시하였다.

하지만, 본 연구는 학문적 시사점보다 실무적인 시사점이 더 크다고 할 수 있다. 즉, 적정 부품 보유 재고를 예측함으로써 긴급한 부품 구매로 인한 고원가 구매를 방지함으로써 자동차 A/S센터의 부품 이윤을 향상시킬 수 있다. 이에 따라, A/S센터에서는 초과 보유 재고를 줄임으로써 보관 및 관리 비용을 절감하고, 부품 부족으로 인한 수리 시간 지연을 줄여 고객 서비스 만족도 향상에 기여할 수 있다. 그리고 부품 구매, 판매 및 재고 관리와 같이 서비스센터 경영 계획 수립 시 예측된 부품 수요 데이터는 주요 의사결정 지원에 활용할 수 있다.

본 연구의 한계점으로는 부품 구매, 판매 수량과 기간에 따른 보유 수량의 시계열 데이터 셋으로만 모델이 구현되었다. 수요 예측에는 이러한 시계열 데이터 이외에 예측성능에 영향을 미칠 수 있는 차량 모델별 판매 대수, 연식, 서비스센터 수리 대수 등과 같이 외부 요인을 특성 변수가 고려되지 않았다. 그리고 부품 수요 유형을 ADI와 CV<sup>2</sup>에 따른 4가지 유형으로 한정되었다. 1,600개 이상의 다양한 부품을 4가지 유형으로만 분류하고 분석하는 것은 예측 모형의 일반화에 한계로 작용할 수 있다.

향후에는 위와 같은 연구의 한계점을 고려하여 단순한 부품 수요 시계열 데이터 이외의 수요 예측성능에 영향을 미칠 수 있는 외부 요인을 분석한 후 특성 변수로 추가하면 모델 성능

향상에 기여할 것으로 기대된다. 또한 부품 수요 유형을 부품 수요 특성에 맞게 세분화하여 LSTM 모델에 적용하여 성능을 비교 분석함으로써 자동차 A/S서비스센터의 수리 부품 예측 모델의 성능을 향상시키고자 한다. LSTM의 은닉층에 대한 계산과 구현을 간소화한 게이트 순환 유닛(Gate Recurrent Unit, GRU) 모델 (Chung et al., 2014)과 LSTM 모델과도 비교 연구 함으로써 자동차 A/S센터 수리부품의 수요 예측 모델 일반화 연구에 기여하고자 한다.

## 참고문헌

- 장민경, 김도현, 오수진, “자동차 A/S용 부품 수요 예측 모형 개발”, 대한산업공학회 추계학술대회논문집, 2104, pp. 255-271.
- 공동석, 곽영훈, 허정호, “도심지역 에너지계획을 위한 인공지능경망 기반의 에너지수요 예측에 관한 연구”, 대한건축학회, 제25권 제2회, 2010, pp. 221-230.
- 권익현, “부품 수명주기를 고려한 서비스 부품의 수요예측에 관한 연구”, 대한안전경영과학회지, Vol 19, No 3, 2017, pp. 97-107.
- 김기현, 이홍철, “자동차 재활용 부품 수요 예측 방법론”, 대한산업공학회 춘계공동학술대회, 논문집, 2014, pp. 31-38.
- 김수도, “우리나라 자동차 정비사업의 발전 방향에 관한 연구”, 고려대학교 정책대학원 석사 학위 논문, 2011.
- 김영균, 김민구, “단순 RNN과 RNN/LSTM을 이용한 주택시장 매매가 예측 비교 연구”, 한국정보과학회 학술발표논문집, 2018, pp. 2154-2156.
- 김영석, “SERVQUAL 모형을 이용한 수입자동차 정비서비스 품질평가에 관한 연구 (메르세데스-벤츠 성산 서비스센터의 사례를 중심으로)”, 서울시립대학교 경영대학원 석사 학위 논문, 2007.
- 김재성, 양여진, 오민지, 이성웅, 권순동, 주완섭, “딥러닝 기법을 활용한 가구 부자재 주문 수요예측”, 한국빅데이터학회지, 제5권 제2호, 2020, pp. 111-120.
- 김종배, 김유선, 박민영, “우리나라 기업들의 수요예측 실태에 관한 연구 -2011년과 2020년 설문조사 비교·분석”, 한국유통물류정책학회, 제8권 제4호, 2021, pp. 87-107.
- 김종진, 김지연, “LSTM을 이용한 추가예측 모델의 학습방법에 따른 성능분석”, 한국디지털정책학회, 제18권 제11호, 2020, pp. 259-266.
- 김형길, 오영희, “자동차 정비서비스의 고객만족에 관한 연구”, 산경논집, 제11권, 2003, pp. 118-120.
- 민소아, 정윤서, “서울시 공공자전거 수요예측 모형 비교 연구”, 한국데이터정보과학회, 제32권 제3호, 2021, pp. 585-592.
- 박병준, 여기태, “시스템다이내믹스를 활용한 수입 자동차 소모품 출고예측에 관한 연구 - A 수입 자동차 부품 물류센터를 중심으로”, 한국디지털정책학회, 제19권 제1호, 2021, pp. 67-75.
- 박소진, “자동차산업에서 고객만족과 충성도를 위한 통합 모델-자동차, 영업소, 서비스

- 센터의 지각된 품질이 고객만족과 충성도에 미치는 영향”, 한국유통물류정책학회, 제6권 제1호, 2019, pp. 19-36.
- 박종오, 박인선, 양창수, “자동차 정비서비스의 품질이 고객만족과 고객충성도에 미치는 영향”, 한국서비스 경영학회, 제11권 제5호, 2010, pp. 176-198.
- 박진욱, 박상현, “인공신경망을 이용한 한국프로야구 관중 수요 예측에 관한 연구”, 정보처리학회, 제6권 제12호, 2017, pp. 565-572.
- 송명구, 김경유, 안소현, “텍스트 분석을 통한 국내 자동차 산업구조 변화”, KiET 산업연구원, 연구자료 2021-10.
- 신성호, 이미경, 송사광, “LSTM 네트워크를 활용한 농산물 가격 예측 모델”, 한국컨텐츠학회, 제18권 제11호, 2018, pp. 416-429.
- 여주대학 산업기술연구소, “자동차 정비사업체의 경영분석과 표준작업시간 책정에 관한 연구”, 2001.
- 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.
- 유병철, 박영태, “항공화물의 간헐적 수요예측에 대한 비교 모형 연구-Croston 모형과 Holts 모형을 중심으로”, 한국항공경제학회지, 제37권, 제1호, 2021, pp. 71-85.
- 이영찬, 서창갑, “인공신경망을 이용한 항공기 기내식 수요예측의 예측력 개선 방안 연구”, 한국정보시스템학회, 제10권, 제2호, 2001, pp. 151-164.
- 이재성, “심층 신경망의 발전 과정과 이해”, 한국통신학회, 제33권, 제10호, 2016, pp.40-48.
- 이현상, 오세훈, “시계열 예측을 위한 LSTM 기반 딥러닝: 기업 신용평점 예측 사례”, 한국정보시스템학회, 제29권, 제1호, 2020, pp. 241-265
- 정성훈, 진창하, “머신러닝 방법을 이용한 오피스 임대료 산정 - 랜덤포레스트, 인공신경망, 서포트 벡터 머신 활용 중심으로”, 부동산학 연구, 제26집, 제2호, 2020, pp. 23-53.
- 정이상, 정대현, “자동차 정비산업의 CRM 지향을 위한 통합 데이터베이스 설계”, 한국컴퓨터정보학회, 제23권, 제5호, 2018, pp. 55-63.
- 조영기, 이현수, “변형된 Attention 메커니즘 기반의 LSTM을 통한 전력수요 예측 프레임워크”, 한국지능시스템학회, 제30권, 제3호, 2020, pp. 242-250.
- 주우진, 김현식, 송미령, “자동차 A/S 부품 유통에서의 정보비대칭성에 관한 연구”, 경영논집, 제38권, 제4호, 2004, pp. 99-123.
- 최성희, “한국의 자동차정비산업(1)”, 한국자동차 공학회 오토저널, 제27권 제1호, 2005, pp. 166-122.
- 최정기, 최진영, “간헐적 수요를 갖는 철도 차량 유지 보수 부품을 위한 기계학습 기반 수요 예측 개선”, 대한설비관리학회, 제26권, 제3호, 2021, pp. 17-25.

- 최희열, 민윤홍, “특집명 01:지능형 정보 시스템 ; 딥러닝 소개 및 주요 이슈”, 한국정보처리학회, 제22권, 제1호, 2015, pp.7-15.
- 오수진, 김민아, “2021 한국의 소비자시장평가 지표”, 한국소비자원, 2022.
- Abraham, A., “Artificial Neural Networks”, *Handbook of Measuring System Design*, 2005.
- Adekoya, A. F., Nti, I. K., and Weyori, B. A., “Long Short-Term Memory Network for Predicting Exchange Rate of the Ghanaian Cedi”, *FinTech*, Vol 1, No. 1, 2021, pp. 25-43.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., and Ljung, G. M., “Time Series Analysis: Forecasting and Control”, *John Wiley and Sons*, 2015.
- Chung, J., Gulcehre, C., Cho, K., and Bengio, Y., “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling”, *arXiv preprint arXiv:1412.3555*, 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.
- Harrou, F., Cheng, T., Sun, Y., Leiknes, T., and Ghaffour, N., “A Data-driven Soft Sensor to Forecast Energy Consumption in Wastewater Treatment Plants: A Case Study”, *IEEE Sensors Journal*, Vol. 21, No. 4, 2021, pp. 4908-4917.
- Hill, T., O’Conner, M., and Remus, W., “Artificial Neural Network Models for Times Forecasts”, *Management Science*, Vol. 42(7), 1996 pp. 1082-1092.
- Hochreiter, S., Schmidhuber, J., “Long Short-Term Memory”, *Neural Computation*, Vol. 9, 1997, pp. 1735-1780.
- Khan, S., Ali Khan, M., Zafar, A., Javed, M. F., Aslam, F., Musarat, M. A., and Vatin, N. I., “Predicting the Ultimate Axial Capacity of Uniaxially Loaded CFST Columns Using Multiphysics Artificial Intelligence”, *Materials*, Vol. 15, No. 1, 2021, pp. 1-39.
- Olah, C, “Understanding LSTM Network -Colah’s Blog”, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, 2015.
- Syntetos, A. A., Boylan, J. E., “On the Categorization of Demand Patterns”, *Journal of the Operational Research Society*, Vol. 56, No. 3, 2005, pp. 495-503.
- e-나라지표, <https://www.index.go.kr/>, 2021
- 국토교통 통계누리, <https://stat.molit.go.kr/>, 2021
- 한국 자동차 산업협동조합, <https://www.kaica.or.kr/>, 2022

**정 동 균 (Jung, Dong Kun)**



부경대학교 경영학과 석사 학위를 취득하고 부경대학교 경영컨설팅 협동과정 박사 과정을 수료하였으며, 주요 관심 분야는 BigData, Machine Learning, Sales Force Automation 등이다.

**박 영 식 (Park, Young Sik)**



동아대학교 경영학사, 동 대학원 일반대학원 관광경영학 석/박사. 현재 동명대학교 경영대학 항공서비스학과 교수로 재직 중.

주요 관심분야: MIS, 고객 정보관리, 고객 만족, Smart Tourism 등

<Abstract>

## **A Study on the Demand Prediction Model for Repair Parts of Automotive After-sales Service Center Using LSTM Artificial Neural Network**

Jung, Dong Kun · Park, Young Sik

### **Purpose**

The purpose of this study is to identify the demand pattern categorization of repair parts of Automotive After-sales Service(A/S) and proposes a demand prediction model for Auto repair parts using Long Short-Term Memory (LSTM) of artificial neural networks (ANN). The optimal parts inventory quantity prediction model is implemented by applying daily, weekly, and monthly the parts demand data to the LSTM model for the Lumpy demand which is irregularly in a specific period among repair parts of the Automotive A/S service.

### **Design/methodology/approach**

This study classified the four demand pattern categorization with 2 years demand time-series data of repair parts according to the Average demand interval(ADI) and coefficient of variation ( $CV^2$ ) of demand size. Of the 16,295 parts in the A/S service shop studied, 96.5% had a Lumpy demand pattern that large quantities occurred at a specific period. lumpy demand pattern's repair parts in the last three years is predicted by applying them to the LSTM for daily, weekly, and monthly time-series data. as the model prediction performance evaluation index, MAPE, RMSE, and RMSLE that can measure the error between the predicted value and the actual value were used.

### **Findings**

As a result of this study, Daily time-series data were excellently predicted as indicators with the lowest MAPE, RMSE, and RMSLE values, followed by Weekly and Monthly time-series data. This is due to the decrease in training data for Weekly and Monthly. even if the demand period is extended to get the training data, the prediction performance is still low due to the discontinuation

of current vehicle models and the use of alternative parts that they are contributed to no more demand. Therefore, sufficient training data is important, but the selection of the prediction demand period is also a critical factor.

**Keyword:** ANN, LSTM, Time-series data, Repair parts demand, ADI, CV<sup>2</sup>, Lumpy pattern

\* 이 논문은 2022년 7월 7일 접수, 2022년 8월 26일 1차 심사, 2022년 9월 24일 게재 확정되었습니다.