creative commons
COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

경 영 학 박 사 학 위 논 문

순환신경망(RNN) 기반 자동차 A/S 서비스 센터 수리 부품 수요 예측 모델 연구

2023년 2월

부 경 대 학 교 대 학 원

경영컨설팅 협동과정

정 동 균

경 영 학 박 사 학 위 논 문

순환신경망(RNN) 기반 자동차 A/S 서비스 센터 수리 부품 수요 예측 모델 연구

지도교수 이 현 규

이 논문을 경영학박사 학위논문으로 제출함.

2023년 2월

부 경 대 학 교 대 학 원

경영컨설팅 협동과정

정 동 균

정동균의 경영학박사 학위논문을 인준함

2023년 2월 17일

위원장 공 학 박사 (인)

위 원 경영학 박사 (인)

위 원 경영학 박사 (인)

위 원 경영학 박사 (인)

위 원 경영학 박사 (인)

< 목 차>

제 1 장 서론 ····· 1

제 1 절 연구의 배경 및 목적 ····· 1

1. 연구의 배경 ····· 1

2. 연구의 목적 ····· 6

제 2 절 연구의 범위와 구성 ····· 8

1. 연구의 범위 ····· 8

2. 연구의 구성 ····· 11

제 2 장 이론적 배경 ····· 12

제 1 절 인공신경망 ····· 12

1. 인공신경망(ANN, Artificial Neural Network) ····· 12

2. 인공신경망 분류 ····· 15

제 2 절 순환신경망 ····· 20

1. 단순 순환신경망(Recurrent Neural Network, SimpleRNN) ····· 20

2. 장단기메모리(Long Short-Term Memory, LSTM) ····· 21

3. 게이트 순환 유닛(Gated Recurrent Unit, GRU) ····· 24

제 3 절 순환신경망 모델 성능 평가 ····· 27

1. 하이퍼파라미터(Hyperparameters) ····· 27

2. 모델 성능 평가지표 ····· 39

제 4 절 순환신경망 수요 예측 사례 ····· 41

1. 수요예측(Demand Forecasting) ····· 41

2. 수요 유형(Demand Type) ····· 42

3. 연구사례 ····· 45
제 5 절 자동차 정비 서비스 및 A/S 수리 부품 ····· 52
1. 자동차 정비 서비스 ····· 52
2. 자동차 A/S 부품 분류 및 수요의 특징 ····· 54

제 3 장 연구방법 ····· 59

제 1 절 연구개요 및 개략 프레임워크 ····· 59
1. 연구개요 ····· 59
2. 연구 프레임워크 ····· 60
제 2 절 상세 프레임워크 ····· 63
1. 분석 데이터 선정 ····· 63
2. 데이터 셋 구성 ····· 72
3. 데이터 전처리 ····· 77
4. 모델 최적화 및 모델 적용 ····· 78

제 4 장 연구 결과 ····· 80

제 1 절 예측 데이터 셋 분석 ····· 80
제 2 절 예측 결과 ····· 96

제 5 장 결론 ····· 107

제 1 절 연구결과의 요약 ····· 107
제 2 절 연구의 시사점 ····· 111
제 3 절 연구의 한계점 및 향후 연구 ····· 116

참고문헌 ····· 118

<표 목차>

<표 1-1> 자동차 부품 연도별 매출 실적 ····· 3
<표 2-1> 활성화 함수 종류 ····· 31
<표 2-2> 최적화 함수 종류 ····· 34
<표 2-3> 수요발생 유형 구분(오병훈·김현철, 2017) ····· 43
<표 2-4> 인공신경망 수요 예측 사례에 따른 ANN 모델 및 평가 지표 49
<표 2-5> 자동차관리사업 현황 ····· 53
<표 2-6> 자동차 등록현황 ····· 54
<표 3-1> 부품별 3년간 월수요 데이터 셋 ····· 64
<표 3-2> 수리 부품 수요유형 ····· 65
<표 3-3> 2년 간 총 재고 대비 수요 유형 ····· 65
<표 3-4> 2년간 원가 및 부품 매출별 수요 유형 ····· 66
<표 3-5> Smooth 수요 유형 샘플 ····· 68
<표 3-6> Intermittent 수요 유형 샘플 ····· 69
<표 3-7> Lumpy 수요 유형 샘플 ····· 70
<표 3-8> Intermittent 수요 예측 연구 ····· 71
<표 3-9> 부품 수요 유형별 수량 및 평균 판매가(원) ····· 72
<표 3-10> 부품 수요 시계열 데이터 셋 정의 ····· 73
<표 3-11> Lumpy 부품 유형 시계열 데이터 샘플 ····· 74
<표 3-12> scikit-learn 표준화 방식 ····· 77
<표 3-13> 각 시계열 데이터의 하이퍼파라메터 설정 값 ····· 78

<표 3-14> 기간별 ARIMA 최적모델 ····· 79
<표 4-1> 원본 수요 데이터 샘플 ····· 81
<표 4-2> 기간별 표준화(Standardization) 평균과 분산 ····· 83
<표 4-3> 특성 및 목표 데이터 셋 생성 ····· 88
<표 4-4> 일별 순환신경망 예측 모델 평가 ····· 93
<표 4-5> 주별 순환신경망 예측 모델 평가 ····· 94
<표 4-6> 월별 순환신경망 예측 모델 평가 ····· 95
<표 4-7> 모델별·시계열 데이터별 성능 비교 ····· 97
<표 4-8> 2021 월별 백오더(B-Order) 수량 비교 ····· 102
<표 4-9> 2021년 월별 주문 유형별 부품 수량 비교 ····· 103
<표 4-10> 2021년 월별 주문 유형별 부품 원가 금액(단위: 천원) 비교 · 104
<표 4-11> 2021 월별 서비스 센터 매출 금액(단위: 천원) 비교 ····· 105

<그림목차>

<그림 1-1> 연도별 정비업 현황(국토부 통계 누리, 2022) ····· 3
<그림 1-2> A/S 수리부품 매출 ····· 4
<그림 2-1> 단층/다층 인공신경망 ····· 13
<그림 2-2> 인공신경망의 기본 구조(이재성, 2016) ····· 15
<그림 2-3> 합성곱신경망 기본 구조(Lecun et al., 1996) ····· 17
<그림 2-4> 숫자이미지 분류 모델 학습 과정(https://tensorflow.blog/) ·· 17
<그립 2-5> 순환신경망의 기본구조(정경중·최재식, 2015) ····· 19
<그립 2-6> 단순RNN 구조의 단일 레이어 순환 모듈(Olah, 2015) ····· 21
<그립 2-7> LSTM 구조의 4개 레이어 상호 작용 순환 모듈(Olah, 2015) 22
<그림 2-8> LSTM&GRU 모델 구조(Chung et al., 2014) ····· 25
<그림 2-9> 은닉층 및 유닛 수량 ····· 28
<그림 2-10> 드랍 아웃 신경망 모델(https://sungjk.github.io/) ····· 29
<그림 2-11> 경사하강법(Gradient Descent)(http://www.kocw.net/) ····· 36
<그림 2-12> 수요유형별 수요기간 vs 수량 그래프(https://frepple.com/) 44
<그림 3-1> 연구의 프레임워크 ····· 62
<그림 3-2> 부품 유형별 분포 ····· 67
<그림 3-3> Smooth 수요 유형 부품 ····· 68
<그림 3-4> Intermittent 수요 유형 부품 샘플 ····· 69
<그림 3-5> Lumpy 수요 유형 부품 샘플 ····· 70
<그림 3-6> 일별, 주별, 월별 판매 및 구매 수요 ····· 76

<그림 4-1> 각 기간별 수요 데이터 정규분포 ····· 82
<그림 4-2> 표준화 된 각 기간별 수요 데이터 정규분포 ····· 84
<그림 4-3> Z-Score 정규화된 기간별 수요 데이터 정규분포 ····· 85
<그림 4-4> 학습 데이터 Wondwo Size 예시 ····· 86
<그림 4-5> 단순RNN 훈련과정 시각화 ····· 90
<그림 4-6> LSTM 훈련과정 시각화 ····· 91
<그림 4-7> GRU 훈련과정 시각화 ····· 92
<그림 4-8> 각 예측 모델별, 기간별 평가지표 비교 ····· 97
<그림 4-9> 모델별 일별 시계열 데이터 실제값 vs 예측값 ····· 99
<그림 5-1> 일별 GRU 손실 함수 시각화 ····· 110

A Study on the Demand Prediction Model for Repair Parts of Automotive After-sales Service Center Based on Recurrent Neural Network

Jung, Dong Kun

Interdisciplinary Program of Business Administration Consulting
The Graduate School, Pukyong National University

Abstract

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 Recurrent neural networks (ANN). The optimal parts inventory quantity prediction model is implemented by applying daily, weekly, and monthly the parts demand data to the SimpleRNN, LSTM, GRU and ARIMA model for the Lumpy demand which is irregularly in a specific period among repair parts of the Automotive A/S service.

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 five years is predicted by applying them to the SimpleRNN, LSTM GRU and ARIMA for daily, weekly, and monthly time-series data. the model prediction performance evaluation index, MAPE(%), RMSE, and RMSLE that can measure the error between the actual and the prediction value.

As the result of this study, Daily time-series data with LSTM, GRU were excellently predicted and the indicators is the lowest MAPE(%), RMSE, and RMSLE followed by Weekly and Monthly time-series data. This is due to the

volume of training data for Weekly and Monthly. even if the demand period is extended to get the more training data, the prediction performance is still low due to the discontinuation of current parts 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 *:* SimpleRNN, LSTM, GRU, Time-series data, Repair parts demand, ADI, CV^2, Lumpy pattern

제 1 장 서론

제 1 절 연구의 배경 및 목적

1. 연구의 배경

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

현대·기아, GM대우, 르노삼성 등 최근 국내 완성차 생산업체에서 생산하는 자동차는 연간 약 500만 대이며 한국은 미국, 일본, 독일 등에 이어 세계 여섯 번째 자동차 생산국으로 수출 및 내수시장의 확대에 따라 자동차 정비 서비스 산업 역시 가파른 상승세를 보이고 있다(정이상·정대현, 2018). 자동차 정비 서비스는 자동차 사용에 따른 정비·보증수리, 부품 구매 등의 서비스로 분류된다(박종오 외, 2010). 자동차 서비스 센터를 찾는 고객들은 무엇보다도 자신의 자동차에 발생한 문제가 신속하고 완벽하게 수리되기를 원하고 있다(박소진, 2019). 그러나 국내 자동차 정비 서비스는 한국소비자원의 소비자 시장평가에서 2019년부터 2021년까지 21개의 서비스시장부문에서 최하위를 차지하였다(https://www.kca.go.kr). 이는 최근 코로나19 팬데믹으로 발생된 부품 공급 부족 사태로 인한, 차량 수리시간 지연이라는 자동차 수리 서비스에 대한 품질평가 중 신뢰성 평가의 저하

원인이라 할 수 있다.

한국소비자원은 자동차 부품 보유 기간을 동일한 형식의 자동차를 최종 판매한 날부터 8년(단, 성능·품질상 하자가 없는 범위 내에서 유사 부품 사용 가능)으로 명시하고 있다. 자동차 A/S 서비스 센터는 단종 차량 모델이라도 8년 동안 수리 가능할 수 있도록 부품 수급을 유지하여 부품 부족으로 인한 수리 지연을 최소화하여야 한다.

따라서 자동차 수리 서비스의 품질을 향상시키고, 자동차 정비로 인한 수익 중 부품 이윤을 극대화하기 위해서도 적정한 수준의 부품 재고 유지 및 관리는 자동차 A/S 서비스 센터 비즈니스의 중요한 사안이라 할 수 있다.

완성차 업체 'A' 사의 경우는 부품을 공급하기 위한 취급 품목이 44만 품목인데, 이 중 월간 수요 품목이 평균 4만 5천 품목으로 전체의 10%를 차지하고 있다. 나머지 90% 재고는 불균형 수요를 위한 대기 품목으로 나타났다(주우진 외 2004). 이는 부품 대기 품목에 대한 창고 및 관리 비용의 원인으로 부품 수요에 대한 정확한 예측이 부품 대기 품목을 줄이는 방안이 될 수 있다.

국토부 통계 누리의 2021년 12월 기준 국내 자동차관리사업의 연도별 정비업 현황 <그림 1-1>에 따르면, 원동기 정비업을 포함하여 전국 36,454개 자동차 정비업체가 등록되어 운영 중이며 매년 증가 추세를 보이고 있다 (https://stat.molit.go.kr).

<그림 1-1> 연도별 정비업 현황(국토부 통계 누리, 2022)

자동차 부품 연도별 매출 실적 <표 1-1>을 보면, 2014년 이후부터 감소하였지만 2021년에는 코로나로 인한 전체 산업에 미치는 영향이 줄어들면서 9.6% 증가한 80조 7,427억 원 매출 실적을 기록하였다.

<표 1-1> 자동차 부품 연도별 매출 실적(자동차공업협동 조합, 2022)

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	2.4
2015	484,810	33,937	233,834	752,581	-3.8
2016	466,784	32,675	259,511	758,970	0.8
2017	472,985	33,109	220,843	726,937	-4.4
2018	467,190	32,708	214,525	714,423	-1.8
2019	506,312	35,442	219,387	761,141	6.1
2020	509,089	35,636	184,808	729,533	-4.3
2021	552,215	38,655	216,557	807,427	9.6

*OEM : 신차 제조용 주문자 상표부착

A/S 수리부품의 매출은 전체 부품 매출의 4%~5% 비중을 차지하고 있지만, <그림 1-2>를 보면, A/S 수리부품은 2016년과 2017년을 제외하고 가파른 상승세를 보이고 있다. 이와 같이 자동차 정비업 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).

<그림 1-2> A/S 수리부품 매출

본 연구는 자동차 A/S 서비스 센터 수리 부품의 수요 시계열 데이터와 순환신경망 모델을 활용하여 수리 부품 수요를 예측한 후 최적의 보유 재고 예측 모델을 구현하고자 한다.

수요 시계열 데이터는 구매, 판매 수량, 수요 발생 기간의 보유 및 마감 재고 수량의 이력으로 구성되어 있다. 수요 시계열 데이터는 수요 이력에 따라 수요 유형을 구분할 수 있다. 수요 유형은 Syntetos et al(2005)의 평균수요 간격(ADI)와 변동계수(CV^2)의 값으로 Smooth, Intermittent, Erratic, Lumpy의 4가지 유형으로 구분하고 있다. 그리고 수요 유형 중 Lumpy 수요는 소량의 매우 불규칙적인 유형으로 다른 수요 유형 비하면 일반적인

예측모형으로는 불가할 정도이다(정원희 외, 2020; 송민규· 마정목. 2022; Rožanec et al., 2022,). 따라서 본 연구는 인공신경망의 한 분류인 순환신경망을 이용하여 자동차 A/S 서비스 부품 중 Lumpy 수요 유형의 수요 예측을 통하여 최적의 보유 재고 예측 모델을 구현하고자 한다. 그리고 본 연구의 예측 모델을 실무에 반영함으로써 부품 부족으로 인한 수리 지연을 해소하고 긴급 주문에 따른 고 원가 구매와 과잉 보유 재고를 방지하여 자동차 A/S 서비스 센터의 전반적인 매출과 업무 향상에 기여할 것으로 기대된다.

본 연구 대상인 자동차 A/S 서비스 센터의 부품에 대한 수요 분석 결과 운행 중 유지 보수를 위한 소모성 부품이 Smooth와 Intermittent 수요 유형이고 고장, 마모, 사고로 인한 부품이 Lumpy 수요 유형이다. 유형별 부품 품목 기준으로는 95% 이상이고 총 재고량 기준으로는 32%이면서 고가의 부품에 해당하는 부품이다. 그리고 전체 부품 매출의 60%(2021 기준)를 차지하지만 수요 발생 기간이 다른 수요 유형에 비하여 길고 불규칙적으로 발생하고 있다. 그리고 고객 방문 및 차량 중 부품이 없는 경우 주문하는 것을 백 오더(Back Order)라고 하는데, 백 오더 구매가 40% 이상 차지하고 있다. 백 오더의 증가는 부품 부족으로 인한 수리 지연의 원인도 되겠지만 서비스 센터의 효율적인 운영에도 영향을 미치게 된다. 즉, 미 출고 차량이 많은 경우 더 이상 신규 입고를 받지 못하는 상황이 발생하여 전체적인 서비스 센터 운영과 매출에 심각한 영향을 미치는 원인이 된다.

서비스 센터의 전반적인 업무를 책임지고 있는 A/S 서비스 매니저에 따르면 부품 부족으로 인한 수리 지연과 미 출고는 서비스 센터의 작업 공간의 효율적인 이용에 방해가 될 뿐 아니라 신규 서비스 고객 예약이 길어지고 정비사들의 비생산적인 작업 시간의 증가로 전반적인 서비스 센터 운영에 영향을 미치고 있다. 이와 같은 서비스 센터 현장 상황과 함께 장기적

인 관점에서 효율적인 서비스 센터 운영과 계획 수립 시 Lumpy 수요 예측이 중요한 사안이 될 것입니다. 또한, 보관 및 관리 비용을 절감하여 부품 재고 관리의 효율성을 향상 시킨다. 마지막으로, 자동차 A/S 서비스 센터의 전박적인 경영 계획 수립 시 정확한 부품 수요 예측과 재고 관리 계획으로 주요한 의사 결정 요인으로 기여할 것으로 기대된다.

2. 연구의 목적

과거의 축척된 데이터를 이용한 인공신경망 모델 학습에 따른 예측 연구는 많은 연구자들에 의해 진행되었고 그 연구 결과도 상당한 성과가 발휘되었다. 비즈니스 데이터와 결합한 인공신경망 예측 모델은 경제, 의료, 교육, 농업 등 각종 산업의 다양한 분야에서 예측 결과를 기반으로 주요 운영 및 경영 의사결정에 활용되고 있다(정동균 외, 2021). 하지만 서비스 산업의 서비스 부품은 간헐적이고 불규칙적인 수요 패턴, 제품의 복잡성에 따른 많은 종류의 부품, 제품 수명주기 단축으로 인한 장기 재고와 Dead stock의 위험성과 부담, 부품 부족으로 인한 공급의 긴박성과 고객 불만 방지라는 특성을 가지고 있고 이는 매우 높은 서비스 수준을 요구한다. 따라서 이와 같은 서비스 부품의 특성은 적정 수순의 서비스 부품 수요 예측에는 많은 어려움이 따르는 실정이다(권익현, 2017; 박진욱·박상현, 2017; 오병훈·김현철, 2017; 최정기·최진영, 2021).

본 연구는 첫째, 자동차 A/S 서비스 센터의 수리 부품 수요의 다년간 데이터를 재고관리시스템으로부터 추출 한 후 예측 데이터 셋을 생성한다. 생성된 예측 데이터 셋의 수요 이력을 바탕으로 평균수요 간격(ADI)과 수요 크기의 변동 계수(CV^2)를 활용하여 수리 부품의 수요 발생 유형을 분석하고자 한다.

둘째, 분석된 각각의 수요 발생 유형에 따라 부품들의 특성을 파악하고

각 수요 유형에 대한 적합한 수요 예측 연구 모형을 분석한다. 그리고 자동차 수리 부품의 수요 발생 유형 중 특정기간에 수요가 발생하면서 수요가 불규칙적인 Lumpy 수요 유형 부품에 대한 수요 시계열 데이터 셋를 생성한다.

셋째, 데이터 표준화(Standardization)와 정규화(Normalization) 과정을 거쳐 이상치(Outlier)와 결측치(Missing value)에 대한 데이터 전처리를 수행한다. 전처리 완료된 데이터 셋에 대하여 순환신경망(Recurrent Neural Network, RNN)과 기존 순환신경망의 단점을 보완한 장단기메모리(Long Short-Term Memory, LSTM), 게이트 순환 유닛(Gate Recurrent Unit, GRU) 모델에 적용하여 각 기간별 수요 시계열 데이터 학습을 수행하고자 한다.

넷째, 학습이 완료된 각각의 순환신경망 예측 모델을 손실함수(Loss function) 지표로 성능 평가를 실시하여 자동차 A/S 서비스 부품 수요 예측을 위한 최적의 하이퍼파라미터 설정 값을 도출한다.

마지막으로, 각각의 순환신경망 모델 단순RNN, LSTM, GRU 모델과 전통적인 수요 예측 모형인 ARIMA 모델의 예측 성능을 비교분석한다. 그 결과를 바탕으로, 예측 성능이 우수한 자동차 A/S 서비스 부품 수요에 따른 최적의 재고 유지 예측 모델을 구현하는 것을 목적으로 한다.

본 연구는 Lumpy 수요 유형 부품의 수요 이력을 바탕으로 최적 재고 보유 수량을 예측하는 것이다. 해당 수요 유형은 전체 부품 재고의 50% 이상을 차지하고 있지만 수요 기간과 수요량이 매우 불규칙하여 많은 사례 연구에서도 예측의 한계점을 보이고 있다. 따라서 본 연구는 이러한 어려움과 한계를 해결하기 위한 연구를 목적으로 한다. 본 연구를 통하여 특정 산업 분야인 자동차 A/S 서비스 센터 수리 부품에 대한 수요 시계열 데이터 분석 및 재고 보유 수량 예측에 따라 점진적으로 발전할 수 있는 계기

가 될 것이다.

Lumpy 수요에 대한 연구는 공정기계 산업, 자동차 산업, 항공기 유지보수, 통신 시스템 및 섬유 기계 산업 등에서 많이 관찰되고 있다(Amin-Naseri et al., 2008). 그러나 자동차 정비 서비스 산업에서는 Lumpy 수요 유형 보다는 Intermitter 수요(수요 발생 기간이 긴 정비소모품 등)에서 다수의 연구가 있으나 Lumpy 수요에 대한 연구는 희소하여 본 연구를 통해서 발전할 수 있는 기회로 삼고자 한다.

제 2 절 연구의 범위와 구성

1. 연구의 범위

본 연구에서는 월 입고 대수 1,200대 이상 규모의 종합 정비가 가능한 국내 자동차 A/S 서비스 센터의 부품 수요 데이터를 연구 대상으로 선정하였다. 그리고 이와 같이 선정된 부품 수요 데이터를 순환신경망 모델의 학습 및 검증을 통하여 최적의 재고 보유 유지 수량을 예측할 수 있는 예측 모델을 구현한다.

부품 재고 관리 시스템의 부품 수요 데이터 중 장식을 위한 “용품”을 제외한 보수용 순정 부품이 대상이다. 수요발생일자. 이전재고 수량, 구매수량, 판매수량, 일 마감재고 수량에 대한 부품 수요 시계열 데이터를 추출한 후 Syntetos et al(2005)의 평균수요 간격(ADI)과 수요 크기의 변동 계수(CV^2)를 이용하여 자동차 A/S 수리 부품의 수요 유형을 분석하고 분류한다. 수요 유형은 평균수요 간격(ADI)와 변동계수(CV^2)에 값에 따라 4가지로 구분할 수 있다. 수요 기간과 수량이 규칙적인 Smooth 유형, 수요 기간과 수량이 규칙적이지만 0 수요가 간헐적으로 발생하는 Intermittent 유형

그리고 수요 기간과 수량이 불규칙적이면서 0 수요가 긴 Erratic과 Lumpy 유형으로 구분하고 있다.

분류된 수요 유형 중 비교적 예측이 쉬운 정기적이고 규칙적인 수요 유형인 Smooth와 이미 기존 연구자들에 의해 많은 모델이 개발된 Intermittent는 연구 대상에서 제외하였다. 그리고 수요 유형 중 대다수의 수리 부품에 해당되고 수요 기간이나 수량이 불규칙적이면서 고가에 해당하는 Lumpy 수요 유형의 부품을 예측 대상 부품으로 선정하였다. 선정된 Lumpy 수요 유형 부품의 수요 이력을 각각의 순환신경망 모델에 적용 후 학습을 수행한 후 각각의 순환신경망의 예측 모델 성능을 비교 분석함으로써 성능이 우수한 예측 모델을 도출하고자 한다.

분석도구로는 파이선 프로그래밍, 데이터 시각화와 전처리 등 예측 분석에 필요한 기계학습 라이브러리가 패키지화되어 있고 모델 개발 및 배포할 수 있는 아나콘다 네비게이터(Anaconda Navigator)와 주피터 노트북(Jupyter Notebook)을 활용한다.

주피터 노트북은 2014년 Python Project로 시작하여 모든 프로그램에 걸쳐 대화형 데이터 과학과 과학 컴퓨팅까지 지원 가능한 플랫폼이다(https://jupyter.org/, 2022). 주피터 노트북 플랫폼은 오픈 소스 기반의 양방향 웹 개발 프로그램 툴로 파이선 뿐만 아니라 다양한 프로그래밍 언어로 코딩이 가능하다. 그리고 인터넷 브라우저에서 코드를 한 줄씩 입력하여 실행 결과를 바로 확인할 수 있는 대화식 인터프리터(Interpreter)언어의 플랫폼이다. 현재 머신러닝, 인공신경망 모델 개발에 많이 활용되고 있는 범용의 분석 및 개발 툴이다.

주피터 노트북으로 수리 부품 수요 시계열 데이터를 로드하여 데이터 분석 및 시각화로 데이터 특성을 파악한다. 그리고 모델의 예측 성능을 향상시키기 위한 데이터 전처리와 표준화 및 정규화 과정을 거친 후에 순환신

경망 모델과 전통적인 수요 예측 모형인 ARIMA로 예측 학습과 검증을 진행한다. 각각의 순환신경망 모델은 예측 학습을 수행하면서 예측 성능에 영향을 미치는 하이퍼파라미터 값 조절로 예측 성능을 향상시키면서 학습이 진행되었다. ARIMA 모델은 최적의 차분 d를 근단위검증(Unit root tests)로 구한 후 파이썬 함수 auto_arima()를 이용하여 AR(Auto-regressive)의 차수 p와 MA(Moving average)의 차수 q를 도출하여 학습이 진행되었다.

예측 성능 평가는 평균 절대 백분율 오차(Mean Absolute Percentage Error, MAPE), 평균 제곱근 오차(Root Mean Squared Error, RMSE), 평균 제곱근 로그 오차(Root Mean Squared Log Error, RMSLE) 등의 손실 함수로 평가가 이루어진다.

마지막으로, 검증 데이터 셋의 실제값과 예측값을 시각화하여 구현된 모델의 예측 결과를 비교 한다.

2. 연구의 구성

본 연구는 5개의 장으로 구성되어 있으며 내용은 다음과 같다.

제 1 장은 서론 부분으로 연구의 배경과 연구 주제에 대한 문제 제기와 목적 그리고 연구의 범위와 구성에 대하여 설명하였다.

제 2 장은 인공신경망 개념과 분류, 인공신경망의 한 분류인 순환신경망 알고리즘에 대한 학문적인 이론과 구조 그리고 순환신경망 모델인 단순 RNN, LSTM, GRU의 동작원리, 순환신경망의 예측 모델 성능 향상 방안과 평가 지표, 수요 유형 분류의 정의, 수요 예측에 대한 기존 연구자들의 선행 연구 그리고 자동차 정비 서비스의 일반적인 개념과 A/S 수리 부품 수요의 특징을 서술하였다.

제 3 장 연구 방법에서는 연구의 배경과 목적, 이론적 배경을 바탕으로 수리 부품의 수요 예측 모델 프레임 워크를 제시하였다.

자동차 A/S 서비스 센터 수리 부품 수요 데이터를 분석하여 수요 발생 유형을 파악하였다. 그리고 연구 대상이 되는 수요 발생 유형의 부품 수요 데이터를 대상으로 예측 모델에 적용할 수 있는 학습 및 테스트 데이터 셋을 정의한다. 부품 수요 시계열 데이터 셋을 순환신경망 단순RNN, LSTM, GRU 모델에 적용하여 학습 및 검증을 위한 전반적인 연구 과정에 대하여 기술한다.

제 4 장은 각 기간별(일/주/월), 모델별 예측 성능을 실제값과 예측값의 손실(Loss) 또는 오차(Error)의 수치와 시각화를 통하여 그 결과를 살펴본다.

제 5 장에서는 논문의 요약과 결론 부분으로 분석 및 예측 결과를 통해 연구의 의미와 기여도 그리고, 본 연구의 한계점과 향후 연구 방향을 제시한다.

제 2 장 이론적 배경

본 연구의 이론적 근거가 되는 인공신경망 및 시계열 수요 예측을 위한 인공신경망 시퀀스 모델인 순환신경망 이론과 모델에 대한 일반적인 고찰을 살펴본다. 순환신경망의 수요 예측 기법과 개념, 모델 성능 향상에 영향을 미치는 하이퍼파라미터의 종류와 역할을 파악하고자 한다. 그리고 예측 모델의 성능 평가 지표가 되는 각종 손실 함수를 확인하고 순환신경망 수요 예측에 관한 선행 연구를 확인한다. 마지막으로, 순환신경망 예측 연구 대상이 되는 자동차 정비 서비스업의 중요성과 현황 그리고 자동차 A/S 서비스 센터 수리 부품의 수요 특성을 살펴보고자 한다.

제 1 절 인공신경망

1. 인공신경망(ANN, Artificial Neural Network)

인공신경망은 사람의 뇌의 구조를 모방한 머신러닝 방법으로 서로 연결되어 있는 뉴런(Neuron)과 뉴런이 정보를 주고받는 신경계 구조를 기반을 둔 수학적 모형이다(McCulloch and Pitts, 1943). McCulloch and Pitts의 신경망은 입력값과 가중치를 곱한 합이 특정 임계값을 초과하면 1, 아니면 0을 다음 신경망으로 전달하는 인공신경망이다. 1958년 Rosenblatt은 가중치를 계산하는 로직 퍼셉트론(Perceptron) 학습 규칙 개념을 인공신경망 모델을 소개하였다. 이러한 인공신경망의 등장은 인공지능 개발 분야에서 큰 기대와 주목을 받았다(Rosenblatt, F, 1958). 이 후 1969년 Minsly and

Papert는 퍼셉트론이 간단한 XOR과 같이 선형 분류가 불가한 것을 수학적으로 증명됨에 따라 그 한계에 밝혀졌다(Minsly and Papert, 1969). 하지만, 1986년 Rumelhart et al.이 은닉층을 가진 다층 퍼셉트론을 학습할 수 있는 방법으로 역전파 알고리즘(Backpropagation algorithm) 소개함으로써 인공신경망에 대한 다양한 연구와 적용이 발전되어 왔다(Rumelhart et al., 1986; Abraham, 2005; 정성훈·진창하, 2020).

인공신경망은 <그림 2-1>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)로 구성되어 있다.

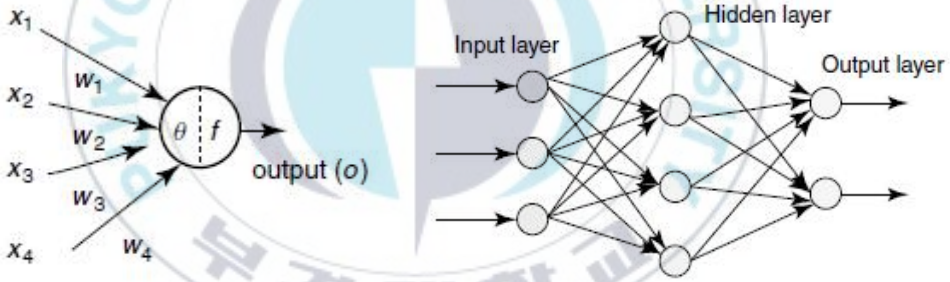

(a) 단층 인공신경망 (b) 다층 인공신경망

<그림 2-1> 단층/다층 인공신경망 구조(Abraham, 2005)

각 층은 입력값을 처리하기 위한 유닛(Unit) 또는 노드(Node)로 이루어져 있으며 각각의 노드들은 활성화 함수를 통해 입력된 값들을 다음 층으로 전달여부를 결정한다(Abraham, 2005; 이재성, 2016). 예를 들어, 입력값 x가 주어졌을 때 은닉층 h를 거쳐 출력값 y가 변환하게 된다.

그 과정에서 수식 (1)과 같이 가중치(w)와 편향(b) 그리고 활성화 함수(Activation Function)으로 출력값(y)가 결정된다.

$$y = actication\,function(xw + b) \qquad (1)$$

출력값(y)에 최대한 가까운 값을 찾기 위해서 가중치(w)와 편향(b)의 값을 변경하면서 값을 찾아가는데 이러한 과정을 인공신경망 모델 학습이라고 한다.

활성화 함수는 사람의 뇌 신경세포의 동작여부를 결정하는 것과 같이 인공신경망의 다음 유닛 또는 노드를 활성화시키고 출력층 및 다음 입력층으로 전달되는 값을 계산한다.

역전파(Backpropagation) 알고리즘은 출력층 결과의 오차(ϵ)를 각 신경망을 따라 역으로 입력층까지 전달하고 새로운 입력층 값(x)의 가중치(w)를 조절하면서 기존의 순방향(Feedforward) 신경망 보다 모델의 최적화가 빠르고 정확해졌다. 역전파 가중치 수정은 수식 (2)와 같이 오차(ϵ)와 가중치 $w(t)$를 미분하여 학습율(α)에 따라 업데이트되고 있다.

$$w(t+1) = w(t) - \alpha\frac{\partial e}{\partial w(t)} \qquad (2)$$

$w(t)$: t단계의 가중치

$w(t+1)$: 업데이트 이후의 가중치

α : 학습률

ϵ : 오차

2. 인공신경망 분류

인공신경망은 일반적으로 뉴런의 연결 방식에 따라 심층 신경망, 합성곱 신경망, 순환신경망 등으로 구분할 수 있다(최희열·민윤홍, 2015).

심층 신경망(Deep Neural Network, DNN)은 <그림 2-2>와 같이 입력층(Input layer)과 출력층(Output layer)사이에 은닉층(Hidden layer)의 개수가 2개 이상으로 인공신경망의 비선형 문제를 효과적으로 인식할 수 있다(Krizhevsky et al., 2017; 이재성, 2016). 기존의 신경망보다 더 복잡한 모델을 사용하여 인식 성능을 향상시킨 결과라고 볼 수 있다(최희열·민윤홍, 2015). 이와 같이 학습을 위해 수십 개, 수백 개의 연속된 층으로 구성되어 있어 심층 신경망을 딥러닝(Deep Learning)이라고도 한다. 딥러닝의 다른 이름으로 층 기반 표현 학습(Layered representations learning)이나 계층적 표현 학습(Hierarchical representations learning)으로 불리오고 있다. 각 층들이 모두 위의 수식 (1), (2)의 기본적인 로직에 따라 훈련 데이터를 학습시킨다(https://tensorflow.blog/)

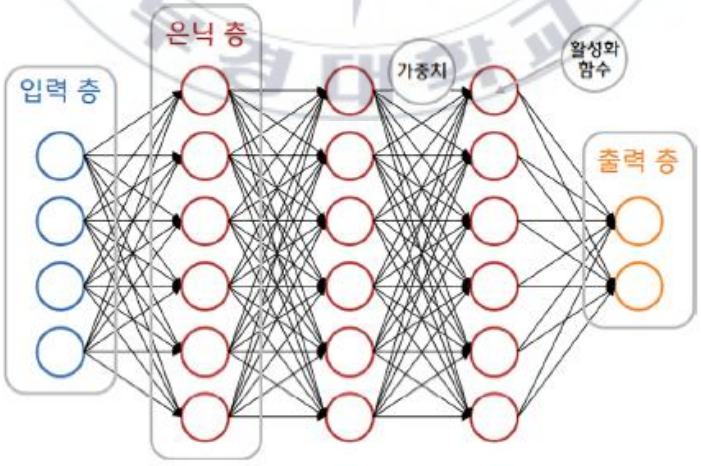

<그림 2-2> 인공신경망의 기본 구조(이재성, 2016)

홍원표 외(2004)은 토질물성, 지형 및 지질 데이터를 신경망 모델 학습으로 산사태 발생 여부를 예측하였고 은닉층이 2개 이상일 때 정확도가 높게 나타났다. 그리고 대규모 음성 데이터와 심층신경망 모델의 결합으로 음성 인식 성능이 크게 향상되었고 많은 음성 응용 분야에서 활용되고 있다(김민식·김형순, 2020). 심층 신경망은 날씨와 기후 변화를 예측하여 농업생태계의 기능에도 이바지하고 있다. 강대균 외(2019)는 기상청에서 제공하는 일별 기상 관측 자료 중 기온과 강수량 자료를 추출하여 일사량 추정 심층 신경망 모델을 제안하였다. 예측된 자료는 작물 생장 모델의 입력 자료로 활용되어 정확한 농업 생산성을 평가할 수 있는 기반이 되었다. 구성관 외(2019)는 안전한 항공 환경 관리를 위해 온도, 기압, 습도, 대기상태변수, 풍속 등의 일반적 기상 현상 자료를 활용하여 풍속을 예측할 수 있는 심층 신경망 모델을 구현하였다. 이외에도 심층 신경망은 해양 생태계의 적조 발생 예측 모델 연구(박수호 외, 2019), 교통카드 이용 이력 데이터를 활용한 환승시간 예측에 따른 대중교통정책 반영 연구(이경제 외 2020), 의사결정 시스템의 부족한 데이터를 보완하기 위한 예측 데이터 생성(이세혁 외 2021) 등 다양한 분야에서 특정 현상의 판별과 예측의 정확도 향상을 위해 활용되고 있다.

합성곱 신경망(Convolutional Neural Network, CNN)은 <그림 2-3>과 같이 주로 이미지를 처리하기 위해 필터링 기법을 인공신경망에 적용한 심층 신경망 기법이다. 행렬로 변환된 이미지의 픽셀을 행렬 연산을 통하여 이미지의 특징을 수치 데이터 처리하여 학습한 후 이미지를 분류한다. 이미지 이외에 오디오와 같은 연속적인 다른 유형의 입력에도 이용된다(Lecun et al., 1996).

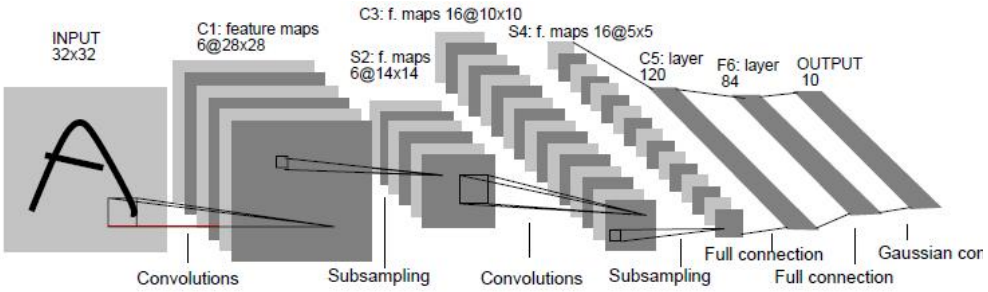

<그림 2-3> 합성곱신경망 기본 구조(Lecun et al., 1996)

<그림 2-4>는 숫자 이미지 분류 모델의 학습 과정으로 층이 점점 깊어질수록 최종 출력에는 더 많은 정보를 가지고 있지만 원본 이미지와는 점점 더 다른 숫자 이미지로 변환이 된다.

각 신경망의 정보가 연속된 층을 통과하면서 변환된 숫자 이미지의 특성을 확률적으로 계산하는 정제과정으로 다단계 특성 정보 추출 학습과정이다(https://tensorflow.blog/).

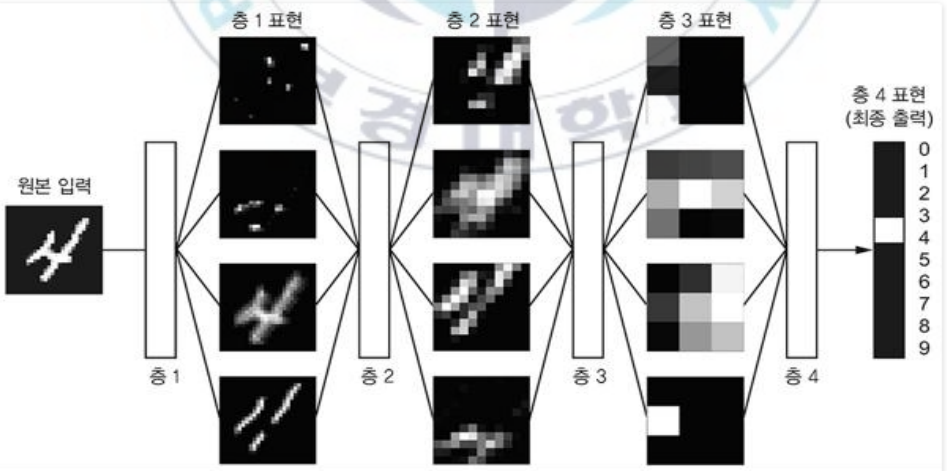

<그림 2-4> 숫자이미지 분류 모델 학습 과정(https://tensorflow.blog/)

이와 같이 합성곱신경망(CNN)은 행렬연산을 이용한 필터링 기법으로 이

미지 인식 및 분류에 특화되어 소개된 인공신경망으로, 영상이나 이미지 인식 및 판별 분야에 주로 활용되고 있다.

예를 들어, 조원호 외(2019)는 지구 표면의 물리적 구성인 토지 피복을 한국을 대상으로 정확한 판별과 분류를 위해 합성곱신경망(CNN)을 활용하였다. 그리고 인터넷 네트워크의 Traffic 부하로 인한 장애를 방지하기 위해 지세현 외(2019)는 사용자 PC와 응용 서버간의 통신 패킷을 캡쳐 한 후 패킷의 숫자를 합성곱신경망(CNN)의 Mnist 숫자 분류 알고리즘을 이용하여 Traffic을 분류함으로써 안정적인 인터넷 네트워크 서비스 및 관리를 위한 모델을 제안하였다. 장훈석(2021)은 초점이 상이한 다 수의 이미지를 합성하는 다 초점 영상 합성기법을 합성곱신경망(CNN) 기반으로 제안하여 기존의 다 초점 영상 합성기법의 문제점을 개선하였다. SNS(Social Network Service)의 포스팅된 이미지를 인지하여 가치 있는 컨텐츠로 활용하기 위해 합성곱신경망(CNN)이 이용되고 있다. 강영옥 외(2021)은 관광분야의 SNS 이미지를 캡쳐하여 분류함으로써 관광마케팅에 활용할 수 있는 구제적인 방안을 제시하였다. 특히, 의료 분야에서도 X-ray 등과 같은 의료 영상 장비의 이미지 분류에도 활용 되고 있는데, 김민정·김정훈(2021)은 흉부 X선 영상에서 정상 심장과 비정상 심장(심장비대)을 분류할 수 있는 합성곱신경망(CNN) 모델을 제안하였고 박현철 외(2018) 또한 대장 내시경 영상 분류 모델의 우수성을 증명하였다. 이외에도 인공신경망의 심층학습 모델은 각종 질환의 진단과 환부 영역 검출과 같은 의료 분야에서 적극적으로 활용되고 있다.

마지막으로, 본 연구의 학습 모델인 순환신경망(Recurrent Neural Network, RNN)은 다음 절에서 상세히 설명하겠지만, 동적인 데이터 즉, 연속적인 시계열 데이터를 학습하는데 우수한 성능의 인공신경망이다. 은닉층에서 은닉층으로 t-1 시간의 은닉값(h_{t-1})이 t 시간의 데이터와 결합

하여 t 시간의 은닉값에 영향을 주는 이유로 기존 인공신경망과 다른 점이 있고 그 구조는 <그림 2-5>와 같다(Elman, 1990; Bod´en, 2002; 정경중·최재식, 2015).

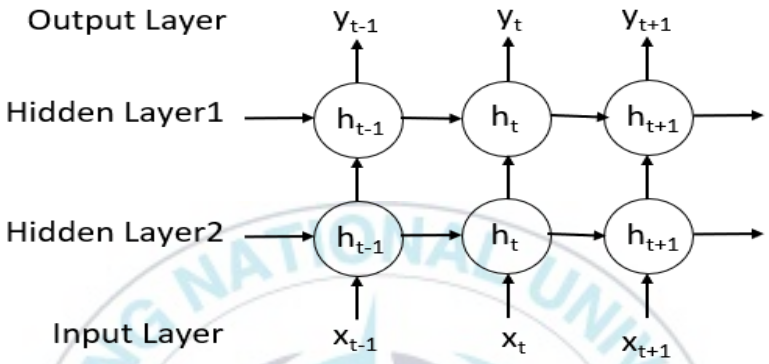

<그림 2-5> 순환신경망의 기본구조(정경중·최재식, 2015)

인공신경망의 은닉층의 갯수가 증가할수록 출력층의 오차가 입력층으로 전달되지 않는 경사 사라짐 문제(Vanishing Gradient)와 반대로 갱신 값이 극단적으로 커지는 경사 폭발 문제(Exploding Gradient)로 학습을 원활히 수행할 수 없는 어려움이 있다(Hochreiter et al., 2001). 이러한 인공신경망 문제를 해결하기 위해 많은 연구자들은 각 층의 노드의 계산 로직을 변경하거나 새롭게 추가하여 신규 신경망 모델을 소개하고 있다. 그리고 가중치 초기화와 정규화, 드랍아웃(Drop-out), 최적화 함수 등의 하이퍼파라미터로 개선을 모색하고 있다. 하이퍼파라미터의 상세한 내용은 제 3 절 순환신경망 모델 성능 및 평가에서 설명하고 있다.

제 2 절 순환신경망

1. 단순 순환신경망 (Recurrent Neural Network, SimpleRNN)

순환신경망은 인공신경망의 특수한 모델로 입력 상태뿐만 아니라 내부에서 이미 처리된 이전 상태 값에 따라 출력 값이 영향을 받는다는 점에서 일반적인 인공신경망과는 근본적인 차이가 있다. 이러한 특징 때문에 연속적인 데이터를 처리할 때 순환신경망을 많이 사용한다(Bod´en, A., 2001; 정경중·최재식, 2015).

인공신경망 모델은 훈련과 테스트 사례의 독립적인 가정에 의존할 뿐만 아니라 해당 데이터가 처리된 후에는 그 상태 값이 해당 신경망에서 사라지게 된다. 이는 각각의 훈련과 검증의 사례들이 독립적인 경우에는 문제가 없겠지만 시간이나 공간적으로 서로 연관이 있는 사례 즉, 비디오 프레임, 오디오 레코드, 문장의 단어 등의 경우는 서로 독립적이지도 않고 가변적인 벡터 길이의 특성으로 인공신경망 모델에서 그 한계가 있다. 이러한 한계를 극복하기 위한 순환신경망은 시간적 또는 순차적인 구조와 다양한 길이의 입력(Input)과 출력(Output)을 처리하기 위한 인공신경망이다. 순차적 데이터를 한 번에 한 단위씩 처리하면서 각 단계에 걸쳐서 선택적으로 상태를 전달할 수 있는 연결주의 모델로 <그림 2-6>의 구조와 같이 순환신경망이 등장하게 되었다(Lipton et al., 2015).

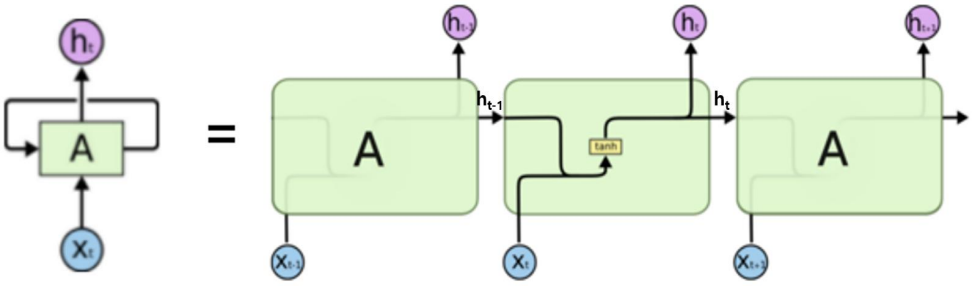

<그림 2-6> 단순RNN 구조의 단일 레이어 순환 모듈(Olah, 2015)

순환신경망은 피드포워드(Feedforward) 신경망을 시퀀스로 자연스럽게 일반화한 것이다. 입력 시퀀스 $x = (x_{1,...,}x_t)$가 주어지면 단순RNN은 아래의 수식 (1)과 (2)를 반복하여 은닉 시퀀스 $h = (h_1,...,h_t)$와 출력 시퀀스 $(y_{1,...,}y_t)$를 계산된다. 그리고 W(Weight)는 가중치(e.g. W_{hx} 은닉-입력층 가중치)이고 b(bias)는 편향(e.g. b_h 은닉측 편향), H는 은닉층 활성화 함수(e.g tanch or Sigmoid 함수)이다(Rumelhart et al., 1986; Werbos, 1990; Sutskever et al., 2014).

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (1)$$

$$y_t = W_{hy}h_t + b_y \quad (2)$$

2. 장단기메모리(Long Short-Term Memory, LSTM)

LSTM(Long Short-Term Memory)은 장단기 메모리 인공신경망 모델로 학습 시간이 장기화되면서 반복적인 역전파(Backpropagation)는 학습시간이 오래 걸리고 에러 신호가 유실(Vanishing gradients, Exploding gradient)되는 순환신경망의 장기의존성 문제(Long-Term

Dependency)를 일으키게 된다. 이러한 문제를 해결하기 위해 경사하강법(Gradient descent) 학습 기반의 순환알고리즘과 연계된 새로운 순환신경망 모델이다(Hochreiter et al., 1997).

모든 순환신경망은 신경망의 반복 순환하는 모듈의 체인 형태로 출력값 y_t는 이전 입력 값 x_{t-1}의 h_{t-1}과 x_t에 대한 활성화 함수 특성 때문에 W(Weight) 값이 특정 값에 수렴하게 된다. 이는 시간이 지남에 따라 훨씬 이전에 입력된 데이터의 영향력이 감소하는 장기의존성 문제가 발생한다(Bengio et al., 1994; Hochreiter et al., 2001).

Hochreiter and Schmidhuber(1997)의 표준 LSTM은 임의의 시간 시차에 걸쳐 정보를 저장하고 오류 신호를 이전 시간으로 전송할 수 있는 장점이 있다. 그러나 특정 시계열의 경우 메모리 블록의 셀 상태가 선형적으로 무제한 증가하면서 출력 셀이 포화 상태가 되고 메모리 셀의 저장 기능이 멈추게 되는 문제가 발생했다. 이를 해결하기 위하여 입력 게이트(input gate, i_t) 앞 단에 망각 게이트(forget gate, f_t)를 추가하여 오래된 메모리 셀에 대하여 리셋 또는 점진적으로 리셋 함으로써 메모리 블록을 재설정한 후 입력 게이트로 전송한다(Gers et al., 2000).

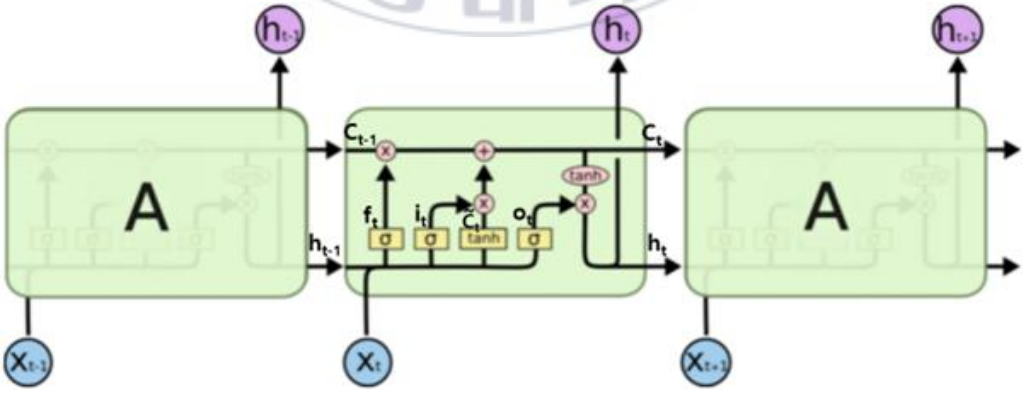

<그림 2-7> LSTM 구조의 4개 레이어 상호 작용 순환 모듈(Olah, 2015)

Hochreiter and Schmidhuber(1997)와 Gers et al.,(2000, 2002)의 이론에 따라 <그림 2-7>과 같은 메모리 블록 내에 망각 게이트(Forget gate, f_t), 입력 게이트(Input gate, i_t), 출력 게이트(Output gate, o_t)와 메모리 셀 상태값 CEC(Constant Error Carousel, c_t)의 로직으로 동작하는 기본적인 LSTM 모델이 등장하게 되었다. 각 게이트와 CEC 동작 로직은 아래의 수식과 같다(Sutskever et al., 2014, 2013; Olah, 2015).

수식(1) 망각 게이트는 이전 히든 상태값(h_{t-1})과 현재의 입력 값(x_t)을 시그모이드(Sigmoid) 함수를 이용하여 이전 CEC(c_{t-1}) 저장 상태(또는 여부)를 결정한다.

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (1)$$

수식(2) 입력 게이트는 이전 히든 상태 값과 신규 입력 값을 시그모이드 함수를 이용하여 업데이트한 값과 수식(3) 이전 히든 상태 값과 신규 입력 값의 하이퍼퍼블릭탄젠트(tanh)로 신규 벡터 값을 계산한 후 수식(2)와 수식(3)을 곱셈하여 저장해야 되는 신규 입력 예상 값을 결정한다.

$$i_t = \sigma(W_{\xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (2)$$

$$\tilde{c} = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3)$$

수식(4) CEC(C_t)는 이전 상태 값(c_{t-1})과 망각 게이트(f_t)를 곱하여 이전 상태 값의 유지 정도 값(0~1, 0 전제 삭제, 1 전체 유지)과 입력 게이트(i_t)와 신규 입력에 대한 벡터 값의 곱을 더하여 현재 상태의 CEC(c_t)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 시그모이드 함수를 이용하여 출력 값을 결정한다. 수식(6)은 현재의 히든 값으로 출력 게이트의 값(o_t)과 현재 CEC(c_t) 하이퍼퍼블릭탄젠트 값의 곱셈으로 결정된다.

$$o_t = W_{xo} x_t + W_{ho} h_{t-1} + W_{co} c_t + b_o) \quad (5)$$

$$h_t = o_t \tanh(c_t) \quad (6)$$

$$y = W_{hy} h_t + b_y \quad (7)$$

요약하면, 순환신경망 모델에 추가된 메모리 블록의 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.

3. 게이트 순환 유닛(Gated Recurrent Unit, GRU)

GRU(Gated Rccurrent Unit)는 LSTM 은닉층의 계산과 구현을 훨씬 더 간소화한 RNN의 새로운 유형의 순환신경망 모델이다. GRU는 별도의 메모리 셀 없이 유닛 내부의 정보흐름을 조절하는 게이트 유닛을 가지고 있다(Cho et al., 2014).

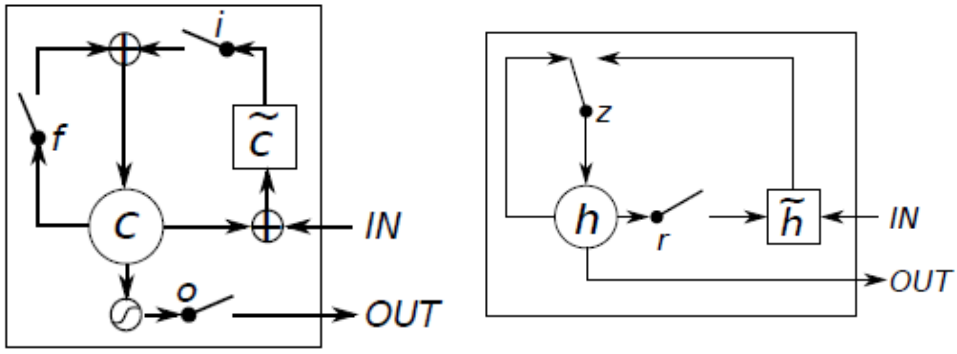

(a) Long Short-Term Memory (b) Gated Recurrent Unit

<그림 2-8> LSTM&GRU 모델 구조(Chung et al., 2014)

<그림 2-8>은 LSTM과 GRU의 모델의 구조로 LSTM의 Forget gate(f), Input gate(i). Output gate(o) 그리고 메모리 셀 상태값($c, \tilde{c}$)에 대하여, GRU는 Update gate(z)가 Forget gate와 Input gate 통합했다. 그리고 은닉 유닛 상태값($h, \tilde{h}$)은 메모리 셀 상태 값과 합친 Reset gate(r)를 추가하여 LSTM의 모델 구조를 간소화하였다(Cho et al., 2014; Chung et al., 2014).

먼저, Reset gate(r_t) 수식(1)을 보면, 새로운 입력값(x)와 이전 시점의 은닉 유닛 정보(h_{t-1}) 그리고 각각의 가중치 W_r과 U_r와 시그모이드 함수(α)를 이용하여 해당 유닛 활성화 정도와 이전 정보를 얼마나 버릴지 결정한다.

$$r_t = \sigma(W_r x_t + U_t h_{t-1}) \quad (1)$$

Update gate(z)는 Reset gate(r_t)와 마찬가지로 수식 (2)와 같이 해당 유닛의 활성화 정도와 이전 정보를 얼마나 업데이트할지 결정한다.

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (2)$$

수식 (3)의 $\tilde{h}$는 LSTM의 메모리 셀과 유사하게 이전 은닉 유닛의 정보를 현재의 은닉 유닛으로 얼마나 많은 정보를 전달할지 결정한다. Reset gate(r_t)가 0에 가까우면 이전 은닉 유닛의 정보를 무시하고 현재 입력 값으로 리셋한다. 이는 은닉 유닛의 정보가 이 후 관련 없는 것으로 확인된 모든 정보를 효과적으로 방지함으로써 더 간결한 처리가 가능하다.

$$\tilde{h_t} = \tanh(Wx_t + U(r_t \odot h_{t-1}) \quad (3)$$

마지막으로, 현재 시점의 정보를 출력하는 h_t는 수식 (4)와 같다. Update gete(z_t)의 출력값 z_t와 이전 시점의 은닉 유닛 정보 h_{t-1}의 곱셈과 1에서 Update gate(z_t)를 뺀 $(1-z_t)$과 수식 (3)의 곱셈에 대한 합으로 계산된다.

$$h_t = z_t h_{t-1} + (1-z_t)\tilde{h}_{t-1} \quad (4)$$

$$y_t = W_{hy} h_t + b_y \quad (5)$$

각각의 은닉 유닛은 분리된 Reset(r_t)과 Update gete(r_t)를 가지고 있고 은닉 유닛은 서로 다른 시간에 따라 의존성(Dependency)을 계산하는 방법으로 학습한다.

단기 의존성을 학습하는 유닛은 자주 활성화되는 Reset gate(r_t)를 갖는 경향이 있고 장기 의존성은 대부분 활성화되는 Update gate(z_t)를 가지게 된다 (Cho et al., 2014).

제 3 절 순환신경망 모델 성능 평가

1. 하이퍼파라미터(Hyperparameters)

일반적으로 효과적인 인공신경망 모델을 구축하는 것은 적절한 알고리즘을 결정하고 하이퍼파라미터를 조정하여 최적의 모델 아키텍처를 얻는 것으로 이는 복잡하고 시간이 많이 걸리는 프로세스이다(Elshawi et al., 2019). 하이퍼파라미터는 머신러닝과 인공신경망 모델 성능 최적화를 위해 많은 연구자나 개발자가 직접 설정하여 변경할 수 있는 매개변수로 신경망의 구조와 학습 시 반영할 수 변수들로 정의된다(Claesen et al., 2015, Diaz et al., 2017). 신경망 구조의 하이퍼파라미터는 은닉층 및 유닛 수량, 드랍아웃, 활성화 함수와 가중치 초기화이다. 그리고 신경망 학습 시 반영할 수 있는 하이퍼파라미터는 학습률, 최적화 함수, 배치 사이즈와 에폭, 정규화가 있다. 각 하이퍼파라미터의 자세한 내용은 아래의 항목에 따라 설명하고 있다.

(1) 은닉층 및 유닛 수량(Number of Hidden Layer and Units)

은닉층은 입력층과 출력층 사이의 계층으로 <그림 2-9>와 같이 은닉층의 갯수와 각 층들의 유닛(또는 Neuron, Node)의 수량이다. 모델의 정확도(Accuracy)향상에 기여하지만 학습 시 과소적합(Underfitting), 과대적합(Overfitting)에 영향을 미친다(Smith, 2018).

- 과대적합(Overfitting): 은닉층 및 유닛의 수량이 학습 데이터 특성보다 많아 과하게 학습된 경우로 새로운 실제 데이터 예측에는 정확도가 떨어

지는 현상이다. 훈련 데이터의 정확도가 너무 높아 모델의 일반화 오류가 증가하는 경우이다.

- 과소적합(Underfitting): 모델이 너무 단순하고 학습 횟수가 너무 적거나 데이터가 부족하여 정확도가 떨어지는 현상으로 학습 또는 훈련 데이터의 오류를 감소시킬 수 없다.

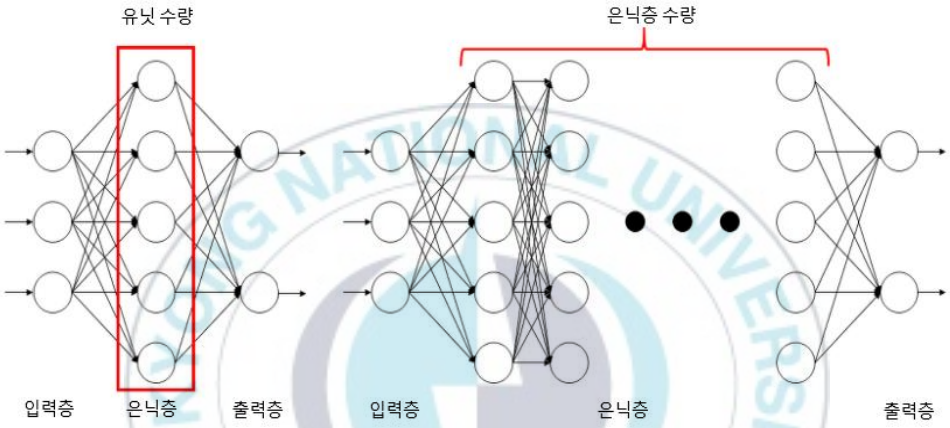

<그림 2-9> 은닉층 및 유닛 수량

(2) 드랍 아웃(Drop-out)

과대적합(Overfitting)을 방지하기 위한 정규화(Regularization) 기법 중의 하나로 <그림 2-10>과 같이 은닉층 유닛으로 유입되고 유출되는 연결을 일시적으로 배제하는 것이다. 특정 값으로 설정되거나 계산된 Drop-out rate에 따라 연관 확률이 낮은 은닉층 유닛들의 배제여부는 수식 (1)과 같이 결정된다(Srivtava, 2014).

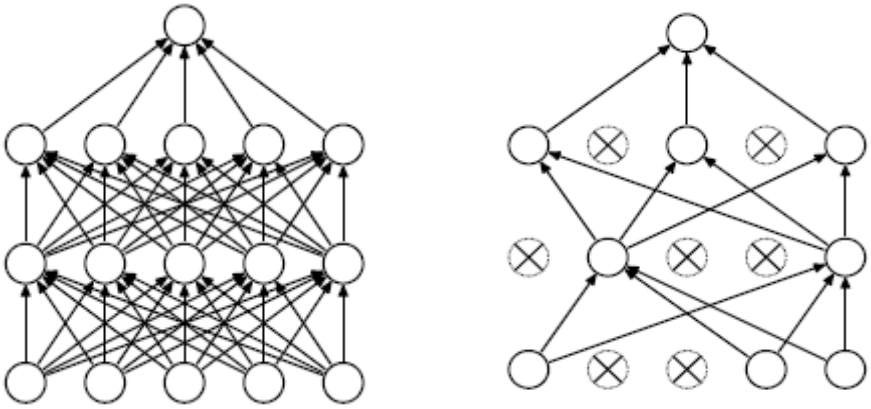

(a) 표준 신경망 (b) 드랍 아웃 적용된 신경망

<그림 2-10> 드랍 아웃 신경망 모델(https://sungjk.github.io/)

$$h_n = \delta(\alpha W_n h_{n-1} + b_n) \quad (1)$$

h_n : 은닉층 노드 상태값

δ : 활성화 함수($e.g\ Sigmoid$)

α : $Drop-out\ rate$

W : 가중치($Weight$)

h_{n-1} : 이전 은닉층 노드 상태값

b : 편향($Bias$)

(3) 활성화 함수(Activation function)와 가중치 초기화(Weight Initialization)

인공신경망에서 활성화 함수와 가중치 초기화 방법은 데이터의 학습과 신경망의 성능에 중요한 역할을 하고 있다. 그리고 주요하게 사용하는 활성화 함수는 sigmoid, tanh, ReLU, LReLU and PReLU 등이 있다. 가중치 초기화 방법으로는 Equal, Random, Xavier, He normal initialization 등이

있다(Nair et al., 2010; Ma et al., 2013; Agostinelli et al., 2014; Sharma et al., 2017; Datta 2020).

전송함수(Transfer actication)로도 알려진 활성화 함수는 전달받은 입력값과 일련의 가중치로 다음 유닛을 활성화시키고 출력층 및 다음 입력층으로 전달되는 값을 계산한다. 따라서 신경망의 예측 정확도는 위에서 언급한 은닉층 및 유닛 수량에 의존하지만 더 중요한 것은 어떤 활성화 함수를 사용하는지에 달려있다(Sharma et al., 2017).

신경망의 활성화 함수는 신경망의 깊이가 큰 경우 역전파 알고리즘(Backpropagation algorism)의 경사하강법(Gradient descent)에 따라 0에 가까운 그레디언트로 가중치의 값이 포화상태가 되거나 업데이트되지 않는 기울기 소실(Vanishing gradient)과 특정 신경망이 활성화되지 않은 Dead Neuron 문제가 발생하게 된다. 그러므로 이러한 활성화 함수 문제를 해결하기 위한 솔루션으로 적절한 활성화 함수를 선택하고 가중치 초기화 기법을 사용해야 한다(Sharma et al., 2017; Datta 2020). 활성화 함수의 종류와 수식은 <표 2-1>와 같다.

<표 2-1> 활성화 함수 종류

Function	Description	Formula
Sigmoid	연속적이고 0~1 범위의 값으로 입력값(x)이 크게 변경되면 출력값이 작게 변경되면 Gradient 값도 작게 변경되어 Vanishing gradient 문제가 있다.	$f(x)=\frac{1}{1+e^{-x}}$
Tanh	Sigmoid의 수정된 버전으로 -1~1 범위의 값을 가진다. Sigmoid와 마찬가지로 0에 가까운 Gradient 값으로 Vanishing gradient 문제가 있다.	$f(x)=\frac{1-e^{-x}}{1+e^{-x}}$
ReLU	정류선형유닛(Recified Liner Unit)으로 수식과 같이 입력값(x)이 0이면 0을, 0보다 크면 x를 출력하는 함수로 0보다 작은 입력에 대한 출력을 0으로 신경망의 많은 부분을 비활성화시키는 Dead Neuron의 문제가 있다.	$f(x)=\max(0,\ x)$
LReLU (Leaky ReLU)	입력값(x)이 0보다 작은 경우 ReLU의 0 대신에 $0.01x$로 출력하는 함수로 Dead Neuron문제를 해결했지만 x가 음수인 경우 0.01은 0에 가깝기 때문에 Vanishing gradient 위험이 있다.	$f(x)=\begin{cases}0.01x & \text{for } x\le 0\\ x & otherwise\end{cases}$
PReLU (Parametric ReLU)	매개변수(a) ReLU로 a가 0이면 ReLU, a가 0.01이면 LReLU, a가 학습에 의해 계산된 경우는 PReLU로 정류선형유닛의 일반화된 함수이다.	$f(x)=\begin{cases}ax & \text{for } x\le 0\\ x & otherwise\end{cases}$

가중치 초기화는 신경망 학습 시작 시점에 가중치의 초기 값을 할당하는 것이다. 처음에는 Rumelhart et al.,(1986)이 모든 같은 값으로 가중치 초기화를 시도하였으나 학습 진행 시 가중치 업데이트가 동일하게 발생되면서 신경망 학습 실패의 원인이 되었다. 이 문제를 해결하기 위해 Rumelhart et al은 Random 가중치 초기화를 제안하였다. Random 초기화 가중치 값은 정규분포 $[-\delta, \delta]$ 범위 내에서 균일하게 가중치가 할당되어 진다(Sodhi and Chandra, 2014).

Glorot et al.,(2010)는 신경망 학습 시 Sigmoid 활성화 함수의 Random 가중치 초기화는 학습 초기 단계에서 경사포화문제(Saturating gradient problem)가 빠르게 진행되는 것을 발견하였다. 즉, Sigmoid의 경사기울기가 0에 가까워지면서 매개변수 업데이트를 위한 역전파 기울기가 발생하지 않아 학습이 느려지거나 중단되는 문제를 확인하게 되었다. 그리고 포화상태의 노드를 적절한 초기값으로 할당함으로써 포화상태에서 벗어날 수 있는 것을 확인하게 되었다. 아래의 수식 (1)은 Glorot et al.,에 의해 개발된 Xavier 초기화 기법이다. 가중치 초기값 할당 범위를 Random 초기화 기법의 고정된 정규분포 범위 대신에 레이어 노드의 전후 수량(n_j, n_{j+1})을 수식 (1)과 같이 표준편차로 하는 Random 균등분포(Uniform distribution, U)로 초기화 하였다. 이는 노드 수에 따라 가중치가 초기화되어 각각의 노드들이 포화상태에 빠지는 것을 방지할 수 있게 되었다.

$$W \sim U[-\frac{\sqrt{6}}{\sqrt{n_j+n_{j+1}}}, \frac{\sqrt{6}}{\sqrt{n_j+n_{j+1}}}] \qquad (1)$$

정류선형유닛(Rectified Liner Unit)의 활성화 함수 ReLu/PRelu를 사용할 경우 He 초기화 기법을 주로 이용한다(He, K. et al., 2015). 수식 (2)는 He

초기화 가중치 할당 범위이다. n_i는 노드 수량, a는 PRelu의 매개변수로 정규분표(Normal distribution, N)을 따른다.

$$W \sim N[-\frac{\sqrt{6}}{\sqrt{n_i \times (1+a^2)}}, \frac{\sqrt{6}}{\sqrt{n_i \times (1+a^2)}}] \qquad (2)$$

He 초기화는 Xavier 초기화와 유사하지만 순전파(Forward propagation) 및 역전파(Backward Propagation) 시 모두 초기화가 조절되면서 Xavier 초기화보다 더 빠르게 오류를 줄일 수 있다. 위와 같이 사용하는 활성화 함수에 따라 가중치 초기화 기법을 다르게 설정할 수 있다.

주로 Sigmoid, tanh 활성화 함수는 Xavier 초기화를, ReLu 활정화 함수는 He 초기화를 사용하지만 활성화 함수에 대한 가중치 초기화 기법은 이외에 많다. 따라서 모델 성능을 향상 시킬 수 있는 활성화 함수와 초기화 기법을 적절히 설정하여 수행함으로써 모델의 예측 성능을 향상 시킬 수 있다.

(4) 학습률(Learning rate)

학습률은 모델 학습 중에 가중치(W)가 업데이트 되는 수치의 각 단계 크기(Step Size)이다(Zeiler, 2012). 학습 시 경사하강법을 사용하는 신경망은 현재 상태에 대한 오차 기울기를 추정한 다음 역전파 시 가중치를 업데이트 하게 된다. 그리고 설정된 학습률에 따라 학습이 얼마나 빠르게 모델에 적응하는지를 제어한다. 학습률이 너무 크면 학습 프로세스는 빨라지지만 로컬 최소값으로 주위를 맴돌게 되어 최소값을 수렴할 수 없게 된다. 반대로, 너무 낮은 학습률은 로컬 최소값을 수렴하겠지만 더 많은 학습 기

간(Epochs)을 요구하면서 학습 시간이 크게 늘어난다. 따라서 너무 크지도 낮지도 않는 학습률이 설정이 되어야 한다(Yang and Shami, 2020).

(5) 최적화 함수(Optimizer)와 손실 함수(Loss Function)

최적화 함수 또는 알고리즘은 신경망 모델의 훈련 속도와 최종 예측성능을 결정한다(Choi et al., 2019). 최적화 함수는 학습 데이터 셋을 모델에 적용하여 학습 시 실제 값과 모델의 예측 값의 차이(Loss)를 찾는 손실함수(Loss function)를 최소화하는 것이다. <표 2-2>는 주요한 최적화 함수를 설명하고 있다(Ruder, 2016).

<표 2-2> 최적화 함수 종류(Ruder, 2016)

Function	Description
BGD	Batch Gradient Descent, 배치 경사 하강법 신경망을 최적화하는 가장 일반적인이고 인기 있는 최적화 알고리즘이다. 손실함수를 최소화하기 위해 경사(기울기)를 이용하는데 경사의 반대방향으로 일정한 크기만큼 반복이동으로 최소화되는 손실함수 값을 찾는 과정이다. 전제 학습 데이터 셋을 사용하고 있어 배치 경사 하강법이라고 한다. 속도가 느리고 메모리 문제가 발생할 수 있다.
SGD	Stochtic Gradient Descent, 확률적 경사 하강법 손실함수 계산 시 전체 학습 데이터 셋을 사용하는 대신에, 랜덤하게 설정된 배치 사이즈만큼 데이터를 추출하여 학습함으로써 속도가 빠르고 메모리도 문제를 해결할 수 있지만 다소 부정확할 수 있다.
Momentum	SGD의 경사 이동 시 가파르게 이동하면서 최소값에 도달하지 못하고 일부분의 최소값(Local minima)에 도달하여 실제 최소값을 찾지 못하는 문제(Oscillations)가 발생한다. 이를 해결하기 위해 이동간격 Momentum과 과거의 이동 방향을 기억할 수 있는 변수를 추가하여 Oscillations 문제를 개선한 함수이다. 그러나 과거의 이동이

	력을 저장 변수로 메모리 사용을 증가시키게 된다.
NAG	Nesterov accelerated gradient, 네스테로프 가속 경사법 Momentum과 같이 이동 간격과 과거의 이동 방향을 계산하여 이동하지만 먼저, Momentum으로 이동한 후 다음 이동할 방향을 계산(예측)한 후 이동하는 방식이다. 이동 방향을 미리 예측하여 너무 빠르게 진행하는 것을 방지하고 응답성을 증가시켜 RNN 성능을 향상시켰다.
Adagrad	Adaptive Gradient 적응 경사법 손실 함수의 변수가 업데이트 될 때마다 학습률을 변경하는 방식으로 자주 업데이트되지 않은 변수는 학습률을 낮게, 빈번하게 변경되는 변수는 학습률을 크게 조절함으로써 손실값을 줄이는 방향으로 이동하는 방식이다. 학습이 길어질수록 학습률이 너무 작아지게 되어 더 이상 계산하지 못하는 문제가 발생하게 된다.
RMSprop	Adagrad의 학습률 문제를 개선한 함수이다. Adagrad의 학습률 조절 변수를 이동 거리 공간의 합과 반비례하는 계산 방식으로 학습률을 조절하였으나 RMSprop는 이동 거리 공간의 합 대신에 지수 이동 평균값으로 대체하였다.
AdaDelta	RMSprop는 학습률과 지수 이동 평균값으로 손실함수 변수를 계산했지만 AdaDelta는 학습률 대신에 학습률 변화값의 제곱을 이용하였다.
Adam	Adaptive Moment Estimation, 적응 모멘트 추정 학습률 조정 방식의 또 다른 최적화 기법으로 손실함수의 변수 계산 시 Momentum의 이동 간격 추정 평균과 RMSprop의 지수 이동 평균의 제곱으로 계산한다.

인공신경망 손실함수의 최적화는 경사 하강법(Gradient Descent) 알고리즘 기반으로 신경망 학습에 가장 많이 사용하는 알고리즘이다(강민재, 2020). <그림 2-11>의 함수 $f(x)$에서 기울기를 따라 여러 번 반복 계산하면서 최적점(최소값)을 찾아가는 것으로 수식 (1)과 같이 계산된다.

경사하강법의 학습률(Learning rate)에 따라 모델의 학습 속도에 영향을 미친다. 학습률이 너무 큰 경우 한 번에 이동하는 거리가 커서 빠르게 수렴하지만 최소값을 수렴하지 못한다. 반대로, 학습률을 너무 작게 설정했을 경우 최적의 값을 계산하는데 많은 시간이 소요되어 학습 속도가 길어지게 된다.

$$x_n = x_{n-1} - \alpha \nabla f(x_{n-1}) \qquad (1)$$

∇ : 학습률

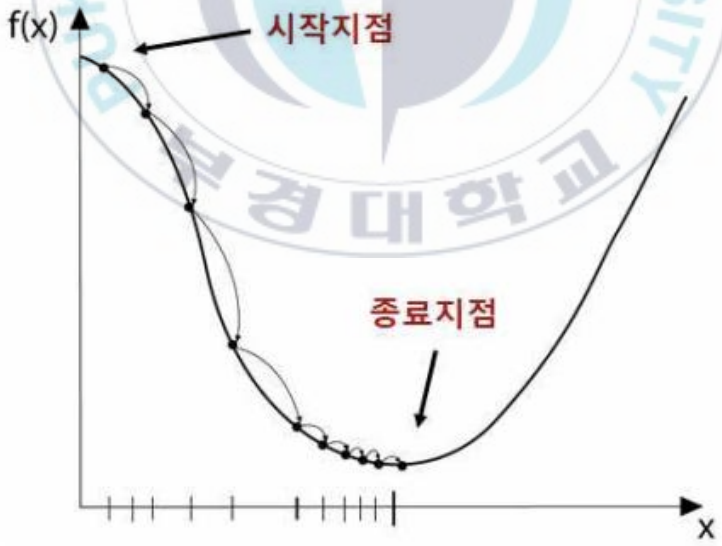

<그림 2-11> 경사하강법(Gradient Descent)
(http://www.kocw.net/)

<표 2-2> 이외에도 다양한 최적화 함수 또는 알고리즘이 있지만 어떤 함수가 가장 좋다고 단정하기는 어렵다. 데이터 셋의 특성이나 신경망 모델에 따라 다양한 실험을 통하여 현재의 상황에 맞는 성능이 우수한 함수를 선택하면 된다.

비용 함수(Cost Function)로도 알려진 손실함수는 신경망 학습이 잘 이루어진 것인지를 확인하는 평가지표로도 이용되고 있다(지상민·박지은, 2021). 이와 관련하여 상세한 내용은 다음의 단원의 2. 모델 성능평가에서 설명하고 있다.

(6) 배치 사이즈(Batch Size)/ 에폭(Epoch)

배치 사이즈는 내부 모델의 파라미터 값을 업데이트하기 전에 처리해야 할 데이터 샘플 수이고 에폭은 학습 알고리즘이 전체 학습 데이터 셋에서 학습을 수행하는 반복횟수를 의미한다(Brownlee, 2018). 즉, 배치 사이즈는 한 번 학습(에폭)마다 처리되는 데이터 샘플의 크기이다.

배치 사이즈는 1이상이고 학습 데이터 셋의 샘플 수보다 작거나 같아야 하고, 에폭 수는 1과 무한대 사이의 정수 값으로 설정될 수 있다. 배치 사이즈가 너무 큰 경우 한 번에 학습해야 되는 데이터 샘플이 너무 커서 학습 속도가 느려지고 메모리 부족 문제로 학습이 중단될 수 있다.

학습이 종료될 때마다 예상 출력 값에 대한 오차를 계산하고 다음 학습 시 모델 개선을 위해 사용이 된다. 학습 회수 경과에 따라 오차가 더 이상 감소하지 않는 경우 학습을 중단할 수 있다.

(7) 정규화(Regularization)

정규화는 학습 중 또는 불완전한 최적화 조건에서 학습하는 경우 보이지 않은 데이터를 일반화 할 수 있는 과적합(Overfitting) 완화 기법이다 (Kukačka et al., 2017).

머신러닝 커뮤니티에서 가장 많이 사용하는 정규화 기법으로 L1과 L2 정규화로 모델의 가중치(Weigh)가 커지는 것을 방지하는 기법이다(Owen, 2007). L1, L2 정규화는 수식 (1)과 같이 손실함수(Loss Function, C)에 L1, L2 정규화 조건을 추가함으로써 가중치를 규제하여 모델의 복잡성을 감소시킬 수 있다.

$$C_{\lambda} = C + \lambda\Omega(W) \quad (1)$$

C_{λ} : 정규화된 손실함수

λ : 학습률

Ω : $L1, L2\ norm$

수식(2)는 L1 정규화로 손실함수에 가중치 절대값을 취하고, 수식(2) L2 정규화로 가중치의 제곱을 더하여 가중치가 커지는 않도록 학습하게 된다.

$$\Omega(W) = \frac{1}{2}|W| \quad (2)$$

$$\Omega(W) = \frac{1}{2}|W|^2 \quad (3)$$

이외에 일반적으로 사용하는 정규화 기법으로 드랍아웃(Drop-out)이 있고 관련 내용은 위의 페이지 27의 (2)항에서 설명하고 있다.

2. 모델 성능 평가지표

순환신경망 모델의 평가 측정 지표로 표준통계지표 중 근접성 측정 기준이 되는 절대평균오차(Mean absolute error, MAE), 평균백분율오차(Mean percentage error, MPE), 평균제곱오차(Mean squared error, MSE), 평균절대백분율오차(Mean absolute percentage error, MAPE), 평균제곱근오차(Root mean squared error, RMSE), 평균제곱근로그오차(Root mean squared log error, RMSLE) 등을 사용하고 있다.(Harrou et al., 2020; Adekoya et al., 2021; Khan et al., 2021; 김재성 외, 2020).

본 연구에서는 기간에 따른 수치 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 통계지표이다. 실제값과 예측값의 오차(잔차)의 절대값 평균을 기간으로 나누어 백분율로 계산 한 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 오차의 제곱 평균 MSE(Mean Squared Error)의 제곱근으로 MSE 보다 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 제곱근 오차 RMSE(Root Mean Squared Error)의 로그를 취한 값이다. RMSE보다 이상치에 강하고 실제값과 예측값의 상대적 오차를 측정하는 지표이다.

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

MAPE(%)는 위에서 언급한 것과 같이 백분율 값으로 MAPE(%)가 3이면 예측 값이 실제 값과 평균적으로 3%차이를 의미한다. RMSE는 실제값과 예측값의 차이가 직관적이다. 따라서 RMSE가 3이라면 평균적으로 3 정도의 값이 실제값을 잘못 예측되었다. RMSLE는 실제값의 상대적 오차로 오차는 같지만 실제값과 예측값의 수치 크기가 다른 경우 예측 모델의 성능을 비교할 수 있는 지표이다.

제 4 절 순환신경망 수요 예측 사례

1. 수요 예측(Demand Forecasting)

수요예측(Demand Forecasting)은 소비자들이 구매하고자 하는 재화나 서비스의 판매 가능성을 과거의 정보나 자료를 이용하여 추정하는 과정이다. 산업 측면에서 볼 때 산업 전체의 수요가 질적, 양적으로 어떤 경향을 나타내고 어떤 상태에 있는가를 과거 및 현재의 자료를 기초하여 예측하는 것이다(김종배 외, 2021).

수요 패턴에 따라 수요 예측 방법이 달라 질수 있는데, 수요 패턴은 크게 규칙성과 불규칙성으로 나누어진다. 규칙적인 패턴은 주문이 정기적이고 주문량이 일정한 경우로 주로 회귀모형이나 시계열 모형을 통해서 수요를 예측하는 방법들이 사용된다. 그러나 수요 기간이 불규칙적이고 주문량의 변동 폭이 큰 수요 유형은 기존의 방식으로는 수요 예측의 오류 발생 가능성이 높다(유병철·박영태, 2021).

시계열 데이터의 전통적인 수요 예측 모형으로는 Box Jenkins의 자기회귀누적이동평균(Auto-regressive Integrated Moving Average, ARIMA)이다(Box et al., 1995). 규칙적인 패턴 수요의 주기적인 관측 값에 대한 추세와 경향에 적합한 ARIMA 모형은 불규칙적이고 간헐적인 시계열 데이터에는 적용할 수 없다(박진욱· 박상현, 2017).

가격 예측을 포함하여 향후 일어날 현상에 대한 예측의 기존 도구들은 수학 및 통계 공식을 바탕으로, 전체 모집단 중 현상을 설명할 수 있는 샘플 집단의 데이터를 활용하여 예측하였다. 그러나 인공신경망 기반의 회귀분석이나 시계열 분석은 인간의 인지 및 사고방식과 유사한 형태로 학습되

어진 모델을 통해서 현상을 예측한다(신성호 외, 2018).

본 연구의 수요 예측 대상인 자동차의 수리 부품은 판매 후 서비스(after-sales service) 부품으로 그 종류가 매우 다양하고 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 패턴은 전통적인 ARIMA 모형으로는 한계를 보이고 있다(박진욱·박상현, 2017; 오병훈·김현철, 2017; 김재성 외, 2020).

2. 수요유형(Demand Type)

Syntetos et al(2005)의 평균수요 간격(ADI, Average Demand Interval)과 수요 크기의 변동계수(CV^2, Coefficient of Variation) 값에 따라 <표 2-3>와 같이 수요 발생 유형을 구분하고 있다.

(1) 평균수요 간격(ADI, Average Demand Interval)

평균수요 간격(ADI)은 0이 아닌 두 수요 사이의 평균 간격으로 수식(1)과 같다. ADI가 1.9이면 평균적으로 1.9 시간 주기마다 0이 아닌 수요가 발생한다고 할 수 있다.

$$\text{평균수요간격}(ADI) = \frac{\text{대상기간}}{\text{0수요가아닌기간의수}} \qquad (1)$$

(2) 수요 변동계수(CV^2, Cofficient of Variantion)

변동 계수(CV^2)는 데이터의 흩어진 정도이며 시계열 변동성을 나타내는 척도로 관련 수식 (2)와 같다.

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

<표 2-3> 수요발생 유형 구분(오병훈·김현철, 2017)

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

수요 유형별 수요 기간에 따른 수량을 나타내는 <그림 2-12>를 보면, Smooth 유형은 수요기간의 변동에 따라 매우 규칙적인 수요로 예측이 쉽고 낮은 예측 오차 수준이다.

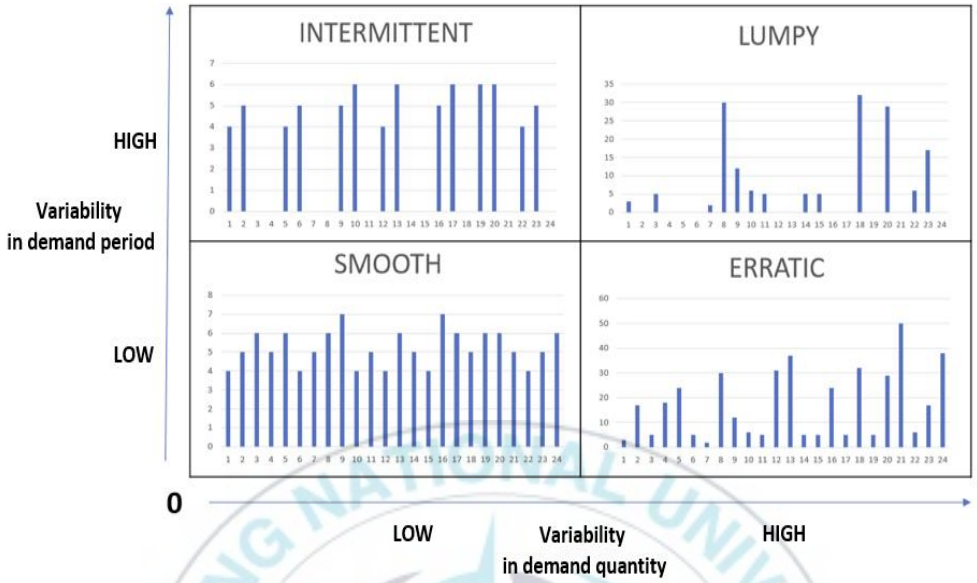

<그림 2-12> 수요유형별 수요기간 vs 수량 그래프(https://frepple.com/)

Intermittent 유형의 경우는 수요의 수량 변동은 거의 없지만 두 수요 사이의 기간에 변동이 크게 발생하고 예측 오차 법위가 상당이 높다. 수량의 변동성이 크지만 수요의 기간에 따라 정기적으로 발생하는 Erratic수요는 Smooth 유형과 비교했을 때 예측의 정확도는 여전이 불안정하다. 수량 및 수요 기간의 변동성이 매우 큰 Lumpy 유형은 다른 수요 유형에 비하여 일반적인 예측 모형으로는 불가능할 정도이다(Rožanec et al., 2022).

3. 연구사례

(1) 자동차 부품 수요 예측 연구

자동차 부품 수요 예측 요인으로 생산지, 고장률, 순정품 여부, 수리비, 신차 또는 중고차 여부, 판매 위치, 수리 또는 교체, 부품의 중요도 순으로 영향을 미치고 있다. 그러나 내외부적인 사회, 경제, 정치적 요소들도 많은 문헌에서 수요 예측 요인으로 소개되고 있다(Alalawin et al, 2020).

홍정식 외(2001)는 특정 모델의 자동차가 단종된 시점 이후에 발생되는 부품의 총수요량을 예측하는 모형을 제시하였다. 단종 차량의 연 판매량, 등록대수, 부품 수요량의 관계식에 등장하는 파라미터 추정방법으로 부품 수요의 낙관적/비관적 수요 예측치를 확인할 수 있다.

이민예 외(2021)는 자동차 A/S 예비 부품의 부족한 수요 데이터에 대하여 대용량 데이터가 있는 다른 분야의 훈련된 모델을 재사용하는 전이학습(Transfer learning)기반 순환신경망 수요 예측 모델을 제안하였다. 전이학습을 위해 예측하고자 하는 부품과 유사한 타 부품의 추세 성분을 학습했다. 그리고 학습된 파라미터를 예측모델로 전이하고 피어슨 상관계수를 사용하여 부품 간 유사성을 검증하였다. 각 시점의 수요량은 차량의 고장 건수를 시계열 데이터 셋을 구성한 후 전이학습이 완료된 모델로 수요 예측을 수행하였다. 그 결과 전이학습 전의 예측모델보다 다소 우수한 성능을 발휘하였다.

Chandriah and Naraganahalli(2021)는 순환 신경망 단순RNN, LSTM 모델과 다년간의 월별 부품 수요 시계열 데이터를 이용하여 수요 예측을 진행하였다. 학습 시 예측값과 실제값의 차이를 계산하는 최적화 함수 Adam

을 수정하고 특성 변수로써 차량 판매 대수가 추가되었다. 결과적으로, 예측 오차는 감소하였고 실무적으로 백오더(차량 수리 중 발생한 부품 주문)와 재고 수량이 감소하는 효과가 있었다.

기존의 자동차 부품 수요 예측 연구는 서비스 부품의 수요 특징과 수요의 유형에 따른 최적화된 모델을 제시하지 못하는 한계를 보이고 있다. 그러나 본 연구는 자동차 A/S 서비스 센터의 실제 수요 시계열 데이터를 활용하여 수요의 특징을 분석하고 수요 유형에 따른 최적화된 순환신경망 모델을 제시하고자 한다.

(2) 순환신경망 수요 예측 연구

인공신경망의 한 분류인 순환신경망을 이용한 수요 예측은 다양한 산업 분야에서 과거의 축적된 시계열 데이터를 순환신경망 모델의 학습 및 예측을 통하여 기업 경영 계획 수립 및 주요 의사결정에 활용하고 있다. 예를 들어, 이영찬·서창갑(2001)은 순환신경망과 시계열 모델을 이용하여 항공기 기내식 수요예측에 대한 예측력 개선 방안을 제시하였다. 기내식의 수요를 예측함으로써, 낭비를 줄이고 정시 출발 및 비용 절감으로 가격 경쟁력 향상과 고품질의 고객 서비스에 기여하였다. 공동석 등 (2010)은 도시계획단계에서 활용할 수 있는 에너지수요예측 기법을 순환신경망을 기반으로 수요예측 시뮬레이션을 구현함으로써 에너지 사용량 프로파일 분석 및 수요에 기반한 도시차원의 에너지 사용계획 가능성을 제시하였다.

주기성과 자기 상관성이 존재하지 않는 일별 야구 관중 수 예측은 ARIMA 분석 절차를 적용할 수 없는 한계가 있다. 그러나 순환신경망 모형을 활용함으로써 자기 상관이 존재하지 않은 시계열 자료의 예측을 가능케 하였다(박진욱·박상현, 2017). 오병훈·김현철 (2017)은 육군 장비정비정

보체계의 궤도 특정장비의 품목별 소요실적 자료를 평균수요 간격(ADI)과 변동계수(CV^2)로 수요유형을 구분하였다. 그리고 ARIMA, 지수평활, Croston, TSB 순환신경망을 적용하여 수요 예측 실험 결과, 순환신경망 기법이 가장 오차가 적은 우수한 결과를 도출하였다. 이는 극단적인 수요 변동에 대해 유연하게 대응함으로써 간헐적 수리부속의 수요예측 연구의 계기가 되었다.

최정기·최진영 (2021)은 간헐적 수요를 갖는 철도 차량 유지보수 부품의 수요 예측 문제를 개선하기 위해 기계학습 기반 수요 예측 모델을 제안하였다. 부품을 수요의 평균수요 간격(ADI)과 수요량의 변동성을 나타내는 변동 계수(CV^2)를 기준으로 유사한 특징을 나타내는 부품들로 군집화하였다. 그리고 의사결정나무트리, 랜덤 포레스트, 순환신경망 알고리즘을 활용하여 수요 예측을 실시한 결과 군집 수가 7개인경우 순환신경망 알고리즘이 가장 우수한 성능을 보였다.

이와 같이 순환신경망 기법을 이용한 시계열 데이터에 대한 수요 예측 연구가 활발히 진행 중에 있다. 그러나 학습 시간이 장기화될 경우 에러 신호가 유실되는 장기의존성 문제가 나타나게 되었다. 이를 극복하기 위해 새로운 인공신경망 모델인 장단기메모리(LSTM)가 출현하였고 다음과 같이 수요 예측을 위한 LSTM 모델 연구도 꾸준히 증가하고 있다.

신성호 외(2018)은 자연 재해로부터 받을 수 있는 여러 영향 중 농산물 가격 변화에 대한 효과적인 대응 방안을 수립하기 위해 LSTM 모델을 이용한 농산물 가격 예측 모델을 제안하였다. 그 결과, 약 93%의 높은 정확도 예측력을 검증함으로써 농산물 수급을 위한 정부 정책 수립 및 일반 소비자들에게도 유용한 정보로 활용될 수 있을 것으로 기대된다.

지능화 및 고도화된 고품질 전력 서비스인 스마트 그리드 구축을 위해서는 전력 데이터를 이용한 전력 수요 예측이 가장 중요한 선행 연구이다.

이에 조영기·이현수(2020)는 LSTM을 이용한 전력 수요 예측 모델을 제안하였다. 해당 연구에 따르면, 시계열 적용과 회귀분석을 이용한 기존 예측보다 신경망을 통한 전력 수요 예측이 데이터의 평균이나 오차가 아닌 신경망 학습에 초점을 맞춘 LSTM이 우수하였다. 그리고 LSTM 모형에 Attention Mechanism을 결합한 MA-LSTM은 적은 시계열 데이터 보유 시 예측 연구 등에 대한 적용 가능성을 제시하였다.

정종진과 김지연(2020)은 미국의 대표적인 글로벌 회사들에 대한 주가 데이터를 바탕으로 순환신경망 모델인 LSTM을 이용한 주가 예측 모델을 구현하고 적용하였다. 주식과 같은 금융 분야에도 예외 없이 효과를 보고 있으며, LSTM 모델은 시계열 데이터에 대한 예측 모델로서 검증되었다.

이현상·오세훈(2020)은 KOSPI, KOSDAQ, KONEX에 속하는 비금융업 2,362개 기업의 대상으로 최근 18년 동안의 재무적, 비재무적 데이터를 활용하여 기업신용 등급을 예측할 수 있는 LSTM 기반 순환신경망 모델을 구현하였다. 기업 신용 위험 예측에 있어서 단기적 관점에서의 예측뿐만 아니라 장기적 관점에서의 예측 또한 가능해졌다.

가구 부자재를 생산하고 있는 제조업체에서는 생산, 자재 및 물류 등의 계획과 관리 그리고 고객의 니즈와 트랜드 변화에 따라 정확한 수요 예측이 중요하다. 김재성 외(2020)는 통계적 예측 기법인 ARIMA, 인공지능분석기법인 단변량 LSTM, 다변량 LSTM, 1D-CNN으로 가구 부자재 수요 예측을 진행하였다. 그 결과 추세를 반영할 수 있는 다변량 LSTM의 예측 성능이 가장 우수하였다(김재성 외, 2020).

민소아·정윤서(2021)는 공공자전거의 일별 대여 이력을 바탕으로 공공자전거 수요 예측을 위한 모형들을 비교 분석하였다. 순환신경망 기반의 LSTM 모형이 벡터 자기회귀 모형(VAR), 서포트 벡터 회귀 모형(SVR) 보다 예측 성능이 높게 평가되었다. 인공신경망 기반 수요 예측 기존 연구

의 신경망 모델 및 평가 지표는 <표 2-4>과 같다.

Cho et al.(2014)에 의해 개발된 GRU 모델은 LSTM 각 계층 유닛의 계산 과정을 간소화하면서 순환신경망의 장기 의존성 문제의 해결책도 유지하고 있다. 그리고 단순화된 구조에 의해 학습 속도를 향상시키면서 최근 많은 연구자들에 의해 예측 모델로써 많은 관심을 보이고 있다.

<표 2-4> 인공신경망 수요 예측 사례에 따른 ANN 모델 및 평가 지표

연구자	연구내용	ANN 모델	평가 지표
이영찬과 서창갑(2001)	순환신경망과 시계열 모델을 이용하여 항공기 기내식 수요예측의 예측력 개선 방안을 제시.	Hyper-Hybrid ANN	NMSE, MAE, MSE
공동석 외 (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 상관이 존재하지 않은 시계열 자료의 예측 가능성 제시.	Feed Forward ANN	RMSE, MAPE
오병훈과 김현철(2017)	특정장비 소요실적 자료를 ADI과 CV^2 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
신성호 외 (2018)	농산물 가격 변화(수요)에 대한 효과적인 대응 방안을 수립하기 위한 LSTM 기반 농산물 가격 예측 모델을 제안.	LSTM	RMSE
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
조영기과 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 외(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
정종진과 김지연(2020)	주식과 같은 금융 분야의 시계열 데이터에 대한 예측모델을 검증하였으며 모델 성능향상을 위한 하이퍼라메터 설정과 적용 함수에 대한 실증적인 실험 연구.	LSTM	RMSE
민소아과 정윤서(2021)	공공자전거 일별 대여 시계열 데이터를 이용하여 시계열 군집분석, 머신러닝과 인공신경망 모델을 활용한 예측 성능 비교 연구.	LSTM	RMSE, MAE
최정기과 최진영(2021)	철도 차량 유지보수 부품을 ADI)와 CV^2로 수용의 특성을 추출(군집화)하여 수요가 일정하지 않는 부품에 대한 예측모델 제안.	ANN	MSE, MAE

PUKYONG NATIONAL UNIVERSITY 부경대학교

위의 연구 사례와 같이 기존 순환신경망 기반 수요 예측 연구는 시계열 데이터 특성과 예측에 적합한 모델 선정 보다는 성능 향상에 대한 연구였다(이영찬, 서창갑, 2001, 공동석 외, 2010, 박진욱, 박상현. 2017, 오병훈, 김현철, 2017). 그리고 최근 시계열 데이터 수요 예측 성능이 우수한 순환신경망 모델 연구에서도 수요 기간과 수량이 매우 불규칙적인 수요에 대한 이상치(Outlier)를 극복할 수 있는 다양한 평가 지표들이 고려되지 않았다(신성호 외, 2018; 조형기·이현수, 2020; 정종진·김지연, 2020; 이현상·오세훈, 2020; 민소아·정윤서, 2021).

이러한 연구들과는 달리 본 연구는 자동차 A/S 서비스 센터 수리 부품의 실제 수요 시계열 데이터의 수요 유형을 구분하고 수요의 특징을 파악한다. 수요 유형 중 전통적인 통계적 수요 예측 방법이나 순환신경망으로 예측이 어려운 Lumpy 수요 유형을 대상으로 순환신경망 예측 모델을 구현하고자 한다. 그리고 예측 모델 평가 지표는 이상치에 덜 민감하고 강건한 평균백분율오차(MAPE), 평균제곱근오차(RMSE), 평균제곱근로그오차(RMSLE)를 이용하여 모델 성능 평가를 수행하여 자동차 A/S 수리 부품의 수요 예측 모델을 제안하고자 한다.

제 5 절 자동차 정비 서비스 및 A/S 수리 부품

1. 자동차 정비 서비스

자동차 정비 서비스는 고객의 생명과 재산을 보호하는 기능과 자연 환경 보호의 역할과 함께 자동차 수명 연장과 연료소모 방지 등의 경제 지향적 측면의 중요한 역할을 담당하고 있다. 자동차 고장의 사전정비와 예방점검은 자동차의 수명연장은 물론 연료소모를 방지해줌으로써 국가경제에도 이바지한다(여주대학 산업기술연구소, 2001).

자동차 정비 서비스를 전문적으로 수행하는 자동차 정비업은 자동차를 점검하고 정비하여, 자동차의 구조 및 장치의 변경작업을 업으로 하는 것을 의미한다. 자동차 정비 서비스는 차량 성능 유지와 수리 그리고 차량 고장에 따른 문제 해결 등과 같은 판매 후 유지 보수를 위한 관리 요소로 작용한다. 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).

자동차관리법 시행규칙에 의하면, 자동차 정비업은 정비작업 범위에 따라 총 4개의 등급으로 나누어진다.

모든 종류의 자동차에 대한 점검·정비 및 튜닝작업이 가능한 자동차 종합정비업(1급 자동차 정비소(공업사)), 승용자동차·경형 및 소형의 승합·화물·특수자동차에 대한 점검·정비 및 튜닝작업을 할 수 있는 소형자동차종합정비업(2급 자동차 정비소(공업사))가 있다. 다음으로, 소형자동차정비업(3급 자동차 정비소)는 일반적으로 알고 있는 카센터, 부분정비소, 경정비업소이다. 수리 가능한 부분은 엔진 정비, ABS(Anti-lock Brake System,

브레이브 잠김 방지 시스템), 판금 등의 큰 규모의 정비는 불가능하다. 마지막으로, 원동기전문정비업은 자동차원동기의 재생정비 및 튜닝만 가능하다(https://www.law.go.kr/, https://namu.wiki/).

자동차 관리 사업은 자동차 관리법에 따라 자동차 매매업, 자동차 정비업, 자동차 해체재활용업으로 구분된다. <표 2-5>은 2021년 12월 국내 자동차관리사업 현황으로 연도별 정비업 현황을 보면, 매년 점진적으로 증가하고 있다.

<표 2-5> 자동차관리사업 현황(2021년 12월 기준 사업체수)

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

자동차 등록 대수 또한 <표 2-6> 자동차 등록 현황에 나타난 것과 같이 매년 2% 이상 증가 추세를 보이고 있다. 정비 서비스 센터의 입고 대수도 매년 증가하면서, 차량 입고 시 부품 부족으로 인한 수리 지연을 최소화하고 안전재고를 유지하여 고객 정비 서비스 품질 향상에도 기여하기 위해서는 자동차 A/S수리 부품에 대한 수요 예측이 중요한 요소로 부각될 것으로 보인다.

<표 2-6> 자동차 등록현황

	2012	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(https://www.index.go.kr), 자동차 등록 현황

2. 자동차 A/S 부품 분류 및 수요의 특징

(1) 자동차 A/S 서비스 센터 부품 분류

자동차 A/S용 부품은 판매된 차량의 본원적 기능을 유지하기 위해 소요되는 부품을 가리킨다. 기능적으로 필요한 기능 부품을 “보수용 부품”이라고 부르고 “기능 부품”과 “소모성 부품”으로 나눌 수 있다. 반드시 필요하지 않으나 편의성 향상이나 장식 목적으로 사용되는 부품을 “용품”이라고 부른다(오재건·신현승, 2005).

자동차 부품은 유통과정에 따라 3가지 형태로 분류된다. 완성차 제작 시 적용된 동일한 부품으로 완성차업체 또는 완성차업체로부터 위임받은 자가 책임을 지고 공급하는 부품으로 순정부품이라고 한다. 순정부품은 완성차

업체에 납품하는 동일한 부품으로 품질검사를 통하여 완성차업체의 보증과 책임 하에 판매된다. 그리고 순정부품을 제외한 모든 부품이 비순정부품에 해당한다. 예를 들어, 자체 판매 목적의 완성차 협력업체 시판품, 순정부품을 모방한 일반 시중업체 판매부품, 폐차장에서 수집된 중고재생 재활용 부품이 있다. 중고 재생 재활용 부품 중 안전상 중요 장치는 재활용이 금지되어 있다. 이와 같이 국내 수리용 부품 시장은 완성차업체의해 공급되는 순정부품과 일반 부품제조업체들이 공급되는 비순정부품이 시장에 혼재되어 있다(주오진 외, 2004, 박진호 외, 2013).

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 하기 때문에 물류센터의 부품 수는 점점 증가하는 추세이다. 부품 물류센터의 전체적인 상품의 구성은 크게 휀더, 커버, 범퍼, 해드램프, 후드, 브레이크 라이닝, 사이드 판넬, 기타 소모품 등 다양하다(박병준·여기태, 2021).

(2) 자동차 A/S 센터 부품 수요의 특징

자동차의 수리 부품은 내연 기관차가 약 3만여개, 전기차는 1만 5천여개로 수요 예측에 필요한 부품의 종류가 다른 서비스 부품에 비하여 그 수량이 많다(자동차 연구원, https://www.katech.re.kr).

자동차 정비는 유지 보수, 사고나 고장 등 필요한 경우에만 수요가 발생하고 있어 수요가 없는 기간이 빈번이 나타나고 있다. 또한 수요 수량의 변동성이 매우 불규칙적인 Lumpy 또는 Intermittent 수요 유형을 가진다(Boylan & Syntetos, 2010). 따라서 고장 차량이 빠르게 운행이 가능할 수 있도록 신속한 대처가 이루어져야 한다(이민예 외, 2021).

자동차 수리 부품 수요에 영향을 미치는 요인은 매우 다양하다. 해당 부품의 자동차 판매 대수, 현재 운행대수, 생명주기, 대체부품여부, 도로환경, 운전자의 운전습관 등이 수요에 영향을 주고 있다. 또한 모제품 차량의 수명에 영향을 받아 진부화 재고(Dead stock)의 위험성이 매우 높다.(Sherbrooke, 2006). 이와 같이 자동차 A/S용 부품 수요 패턴을 보면, 불규칙적인 고장율과 예측할 수 없는 자동차 사고 등으로 그 수요와 공급이 일정하지 않다. 그리고 모든 차종 부품을 보유하는 것은 보관 창고 공간이나 관리 비용 등의 문제로 일부 한정된 소량의 부품만 보관하고 있다. 그러므로 해당 부품의 수리 발생 시마다 항상 긴박하게 부품 공급 주문이 이루어지고 있다.

본 연구 대상 서비스 A/S 센터의 부품실무자는 업무 일마감(Daily Closing)으로 구매, 판매 및 재고 수량을 확인한 후 주문 계획서를 작성하고 있다. 그리고 차량 입고 현황과 주문 계획에 따라 주문 유형(월, 주, 긴급주문)을 결정한 후 실제 주문이 이루어지고 있다. 그러나 소규모 서비스 센터는 매일 부품 주문이 발생하지 않겠지만 월 입고 대수 1,000이상 규모의 서비스 센터는 부족한 재고 수량을 매일 확인하여 부품 주문이 이루어지고 있다.

과거 수요 예측과 부품 주문은 미리 정의된 부품의 수요 카테고리에 따라 부품실무자는 전체 부품의 재고수불부를 확인하여 부족한 부품을 보충하였다. 수요 카테고리는 구매 및 판매 수량 범위, 원가의 범위에 따라 Fast moving, Medium moving, Slow moving로 정의하고 각 부품의 수요에 따라 부품 별로 업데이트된다. 부품실무자는 재고수불부에 정의되어 있는 각 부품별 수요 카테고리와 수리 차량 입고현황, 경험에 따른 주관적인 판단으로 부품 주문이 이루어지면서 장기 재고와 Dead Stock의 위험이 항상 존재하고 있었다. 그리고 장기 재고를 처리하기 위해 사고 크게 발생한 차량 수리 시 불필요한 장기 재고 부품을 수리부품으로 추가하는 등 불법

적인이고 과다청구의 문제가 있었다. 현재는 지속적인 부품 재고 관리 시스템의 개선으로 단순 수요 카테고리에 따른 수요 예측과 부품 주문이 아닌 수요 시계열 데이터를 통계적으로 분석하여 수요 예측을 제공하고 있지만 Lumpy 유형의 수요 예측은 불안정한 상황이다.

부품실무자에 따르면, 언제든지 판매되고 소비될 수 있는 정비 점검 소모품들의 수요 예측은 정확하지 않더라도 마모나 고장, 사고 등으로 발생하는 Lumpy 수요와 같은 부품들의 수요 예측의 중요성을 강조하고 있다. 그리고 12개월 이상된 부품은 장기 악성재고의 전환률이 높아 고객이나 소규모 서비스 센터를 대상으로 할인판매 부품 대상으로 분류된다. 그러나 현실적으로는 수리 부품에 대한 할인판매는 이루이지 않고 장기 악성 재고 전환되어 폐기 처분이 된다. 특히, 수요 기간이 긴 Lumpy 유형의 많은 부품들이 장기재고와 Dead Stock 전환의 위험을 항상 안고 있다. 매년 이러한 장기 악성 재고의 폐기는 서비스 센터의 상당한 손실을 초래하고 있다 자동차 A/S 서비스 센터의 수리 부품 재고는 입고 후 수리를 위해 출고되지 않은 기간을 산정하여 오래된 부품에 따라 기간별로 부품 재고 자산 폐기 비용(Inventory Provision)을 산정하여 회계 장부에 반영하게 된다.

1년~2년 부품은 폐기 비용으로 원가의 25%, 2년 이상된 부품은 100%로 폐기 비용을 반영하고 연중에는 할인판매를 실시하고 연말에는 폐기처리를 하고 있다. Lumpy 수요 유형 부품 중 1년 이상 부품이 약 10%를 차지하고 있고 다른 유형에 비하여 고가인 점을 고려하면 매년 상당한 손실이 발생하고 있다. 따라서 Lumpy 유형 부품의 최적의 재고 유지 보유 수량을 예측함으로써 비생산적으로 발생하는 이러한 비용을 절감할 수 있는 효과가 있다.

본 연구 대상으로 선정한 해당 서비스 센터의 경우 2021년 월 평균 1,200대를 입고하여 수리를 진행하지만, 보유 부품은 약 35,200개로, 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 낮다. 다음으로 주별, 월별 주문 순으로 할인율이 높아진다. 따라서 본 연구의 부품 재고 예측 모델은 부품 수요를 미리 예측하고 선 주문 및 재고를 보유함으로써 저 원가 구매로 인한 부품 이윤의 극대화에 기여하고자 한다. 또한 부품 부족으로 인한 수리 지연을 미연에 방지함으로써 고객 정비 서비스 품질 향상 및 자동차 A/S 서비스 센터의 생산성과 효율성 향상에 기여할 것으로 기대된다.

PUKYONG NATIONAL UNIVERSITY
부경대학교

제 3 장 연구방법

제 1 절 연구개요 및 개략 프레임워크

1. 연구개요

월 입고 대수 1,200대 규모의 소형 정비업(2급정비업체)이상 종합 정비가 가능한 자동차 서비스 센터의 부품 중 장식을 위한 “용품”을 제외한 보수용 부품 중에서 자동차 제조사나 그 회사에 부품을 공급하는 자회사의 인증 신규 부품인 “순정 부품”을 수요 예측 대상으로 한정하였다.

제조사의 공식서비스 센터는 제조사에서 제공하는 부품 재고관리 시스템을 이용하여 주문, 발주, 입고에 따른 부품 재고관리와 수리에 대한 업무 프로세스로 관리하고 있다. 이와 같이 부품 재고관리 시스템의 축적된 부품 수요 시계열 데이터를 추출하여 각 부품의 수요 유형을 파악한 후 연구 대상 부품들을 선정하였다. 본 연구의 수요 예측 대상 부품은 수요 기간과 수량이 매우 불규칙적인 Syntetos et al.,(2005)의 수요 유형 중 Lumpy 수요 유형이다. 과거의 수요 유형에 대한 예측 연구는 Intermittent에 대한 연구가 다양한 산업 분야에서 많이 이루어지고 있다(박진수 외, 2014; 허정훈 외, 2015; 오병훈·김현철, 2017; 유병철·박영태, 2021, 최정기·최진영, 2021; Willemain et al., 2004; Kourentzes, 2013; Lolli et al., 2019). 그러나 자동차 AS 수리 부품에 대한 Lumpy 수요 예측 연구는 거의 찾아볼 수 없다. 기존의 수요 예측 비교 연구에서도 Lumpy 수요 유형은 예측 성능 매우 불안정하고 저조하였다(Hill et al., 1996; 정원희 외, 2020).

본 연구에서는 Lumpy 수요 유형의 부품 시계열 데이터를 기간별 수요 유형으로 파악하기 위하여 각각 일별, 주별, 월별 수요 데이터 셋을 구성하

였다. 수요 예측 데이터 셋은 학습 및 검증으로 분리하여 예측이 진행되었다. 예측을 위한 특성 변수는 구매, 판매, 이전 재고수량이고 예측 대상이 되는 목표 변수 마감재고 수량으로 구성되었다. 그리고 분석 쥬피터 노트북으로 각 수요 데이터 셋을 로드하여 데이터 분석과 이상치와 결측치 등을 제거하는 데이터 전처리 작업을 수행하였다. 마지막으로 순환신경망 단순RNN, LSTM, GRU 모델과 시계열 데이터의 전통적인 수요 예측 모형인 ARIMA 모델에 적용하여 재고 수요 예측 성능을 비교·검증 하였다.

2. 연구 프레임워크

순환신경망 모델을 활용한 부품 시계열 데이터의 재고 수요 예측 모델 개발은 수요 시계열 데이터 추출, 분석 대상 선정, 데이터 전처리, 모델 성능 향상과 최적화를 위한 하이퍼파라미터 정의, 모델 학습과 평가로 이루어지게 된다.

<그림 3-1>은 본 연구의 수요 예측 모델 구현을 위한 전반적인 수행 프로세스이다. 먼저, 서비스 센터의 부품 재고 관리 시스템에 축적되어 있는 부품 수요 시계열 데이터를 일괄 추출한 후 분석 소프트웨어 주피터 노트북로 데이터 셋을 로드하여 분석을 진행하였다.

부품 수요 유형을 파악하기 위해 모든 연구 대상 부품에 대하여 Syntetos et al(2005)의 평균수요 간격(ADI)과 변동계수(CV^2)를 계산 후 각 수요 유형별로 분류과정을 진행하였다. 분류 된 부품 중 연구 대상이 되는 Lumpy 수요 시계열 데이터 셋을 선정하였다. Lumpy 수요 데이터 셋에 대하여 모델 학습 및 예측이 원활이 진행 될 수 있도록 데이터 전처리를 진행하였다. 데이터 전처리는 유저의 실수나 시스템 오류 등으로 발생되는 이상치나 결측치를 제거 또는 대체하는 과정으로 델 학습 성능 저

하를 방지하기위한 필수 진행 절차이다.

데이터 전처리는 데이터 셋 표준화(Standardization)와 정규화(Normalization)로 이루어진다. 모든 데이터 셋의 변수 값을 크기가 일정한 범위의 값으로 변경(Ex, 0~1)하여 이상치를 제거하는 과정으로 모델의 학습 성능 향상 및 학습 속도에 영향을 미치게 된다. 이와 같이 데이터 전처리가 완료되면 본격적으로 순환신경망과 ARIMA 모델에 적용하여 학습과 검증을 통하여 예측 모델의 성능을 평가할 수 있다.

본 연구에서 전체 데이터 셋에 대하여 학습과 검증 데이터 셋을 각각 70%와 30%로 구분하였다. 각 신경망 모델 성능향상을 위한 활성화 및 최적화 함수, 학습률, 배치사이즈, 드랍아웃 등과 같은 하이퍼파라미터는 각각의 순환신경망 예측 모델에 따라 변경, 조절하면서 학습과 검증이 진행되었다. ARIMA 모델은 근단위검증(Unit root tests)로 차분(Difference) d를 구한 후 auto_arima() 함수를 이용하여 AR(Auto-regressive)의 차수 p와 MA(Moving Average) q를 구한 후 학습과 검증이 진행되었다.

모델들의 성능 비교와 검증은 예측값과 실제값의 차이를 측정하는 손실(Loss) 함수 지표인 평균절대백분율(MAPE), 평균제곱근오차(RMSE), 평균제곱근로그오차(RMSLE) 지표 값으로 비교·검증하는 절차로 진행되었다.

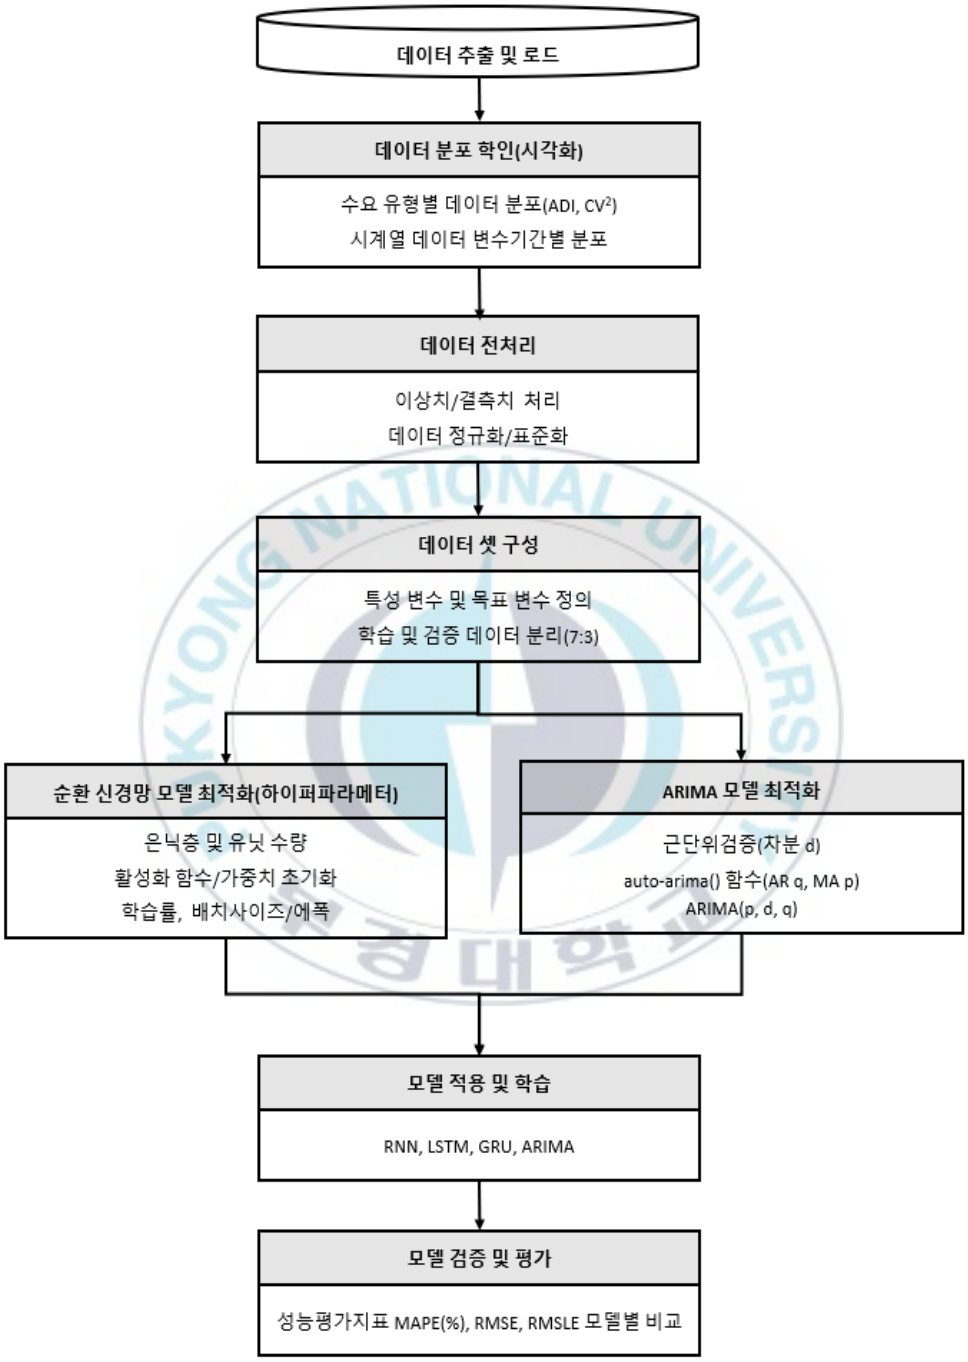

<그림 3-1> 연구의 프레임워크

제 2 절 상세 프레임워크

1. 분석 데이터 선정

본 연구는 종합 정비 수리업을 하고 있는 국내 자동차 A/S 서비스 센터의 전체 부품 35,200 품목의 월별 수요 데이터를 부품 재고관리 시스템으로부터 추출하였다.

연구 대상 수리 부품들의 수요 유형을 파악하기 위하여 Syntetos et al(2005)의 평균수요 간격(ADI, Average demand interval)과 수요 크기의 변동계수(CV^2, coefficient of variation)를 계산하여 수요 발생 유형을 구분하고 분석 데이터를 선정하였다.

수요 대상기간을 각각 2년과 3년으로 평균수요 간격(ADI) 및 변동 계수(CV^2)를 측정하기 위한 수요 데이터 셋은 <표 3-1>과 같다. M-1은 현재월 기준 이전 달이고 M-36은 36개월 전의 월 수요이다.

<표 3-1> 부품별 3년간 월수요 데이터 셋

기간	Parts_01	Parts_02	Parts_…	Parts_35199	Parts_35200
M-1	15	36		6	2
M-2	32	38		10	3
M-3	19	36		6	3
M-4	15	26		2	0
M-5	18	13		0	0
M-6	17	18		5	1
M-7	14	4		5	0
M-8	22	12		7	2
M-9	23	12		3	2
M-10	23	10		12	4
M-11	25	16		1	0
M-12	12	7		6	1
M-13	18	6		6	2
M-14	17	14		2	1
M-15	15	18		5	0
M-16	16	11		1	3
M-17	12	18		4	1
M-18	8	16	…	1	0
M-19	20	14		1	3
M-20	17	2		4	0
M-21	12	8		2	2
M-22	15	22		4	0
M-23	26	38		4	1
M-24	17	15		3	0
M-25	11	8		5	5
M-26	21	17		6	1
M-27	13	38		1	2
M-28	14	16		2	2
M-29	7	3		0	3
M-30	8	20		1	3
M-31	9	2		2	3
M-32	7	27		4	7
M-33	13	14		4	5
M-34	12	18		2	2
M-35	12	24		4	3
M-36	15	22		2	2

연구 대상 서비스 센터의 전체 부품 품목 32,500 중 2년과 3년의 월별 수요(판매) 데이터로 4가지 수요 유형으로 분류 한 결과 <표 3-2>와 같이 유효하게 분류된 품목이 2년, 3년 각각 16,883개, 19,812개이고 분류되지 않은 장기 재고 품목은 각각 18,317개, 15,388개로 2년과 3년 동안 수요가 발생하지 않은 부품이다. 분류된 부품 중 Lumpy 유형은 각각 16,295(96.3%), 19,271(97.3%)를 차지하고 있다.

<표 3-2> 수리 부품 수요유형

Demand Type	2 Years (전체비중 %)	3 Years (전체비중 %)	Classification criteria
Smooth	334(2.0%)	296(1.5%)	ADI < 1.32 and CV^2<0.49
Intermittent	253(1.5%)	245(1.2%)	ADI < 1.32 and CV^2>=0.49
Erratic	1(0.0%)	-(0.0%)	ADI >= 1.32 and CV^2<0.49
Lumpy	16,295(96.5%)	19,271(97.3%)	ADI >= 1.32 and CV^2>=0.49
Total	**16,883**	**19,812**	

<표 3-3>은 장기재고를 포함한 2년 간 전체 재고 수요 유형 분류로 Lumpy 유형이 품목 대비 46%, 재고 대비 30%를 차지하고 있다.

<표 3-3> 2년 간 총 재고 대비 수요 유형

수요 유형	품목 수	품목 수(%)	총 재고	재고(%)
Smooth	334	0.9%	39,209	56.8%
intermittent	253	0.7%	5,040	7.3%
Erratic	1	0.0%	2,055	3.0%
Lumpy	16,295	46.3%	21,125	30.6%
장기 재고	18,317	52.0%	1,640	2.4%
합계	**35,200**	**100.0%**	**9,069**	**100.0%**

원가 및 부품 매출별 수요 유형 <표 3-4>을 보면, 원가와 매출이 각각 59.9%, 58.6%로 전체 부품 매출의 절반 이상을 차지하고 있다.

<표 3-4> 2년간 원가 및 부품 매출별 수요 유형

수요 유형	원가 (천원)	원가 (%)	2021부품 매출(천원)	2021부품 매출(%)
Smooth	657,567	23.0%	5,849,073	31.8%
intermittent	217,786	7.6%	1,345,722	7.3%
Erratic	11,921	0.4%	431,743	2.3%
Lumpy	1,710,648	59.9%	10,790,472	58.6%
장기 재고	259,018	9.1%	1,067	0.0%
합계	**2,856,940**	**100.0%**	**18,418,076**	**100.0%**

수요 대상 기간 2년과 3년 동안의 월별 부품 수요 데이터를 평균수요 간격(ADI)와 변동계수(CV^2)로 구분된 유형별 분포는 <그림 3-2> (a), (b)와 같다.

연구 대상 A/S 서비스 센터의 수리 부품 중 무더기 수요 Lumpy가 2년, 3년 기간 동안의 수요가 각각 96.5%, 97.3%로 대부분을 차지하고 있다. 규칙적인 수요 Smooth는 각각 2.0%, 1.5%와 Intermittent도 각각 1.5%와 1.2% 그리고 Erratic는 거의 발생하지 않았다.

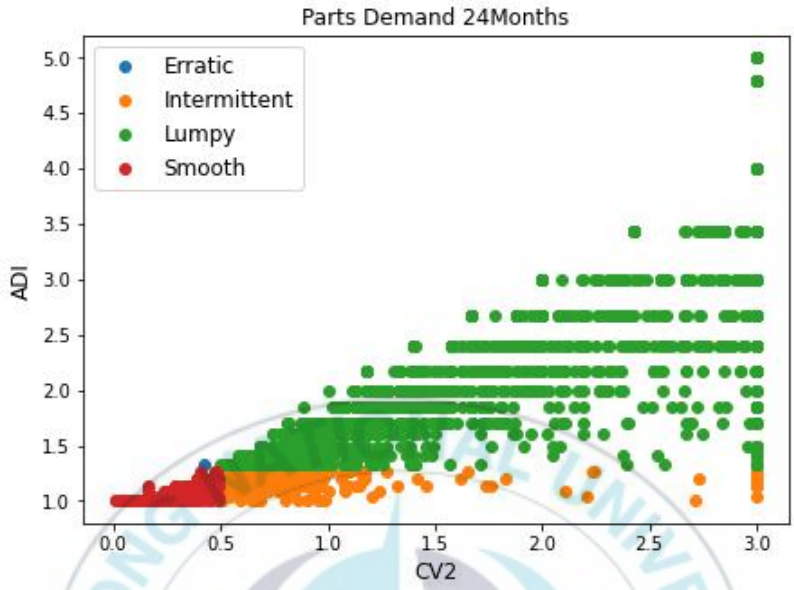

(a) 부품 유형별 분포(2년)

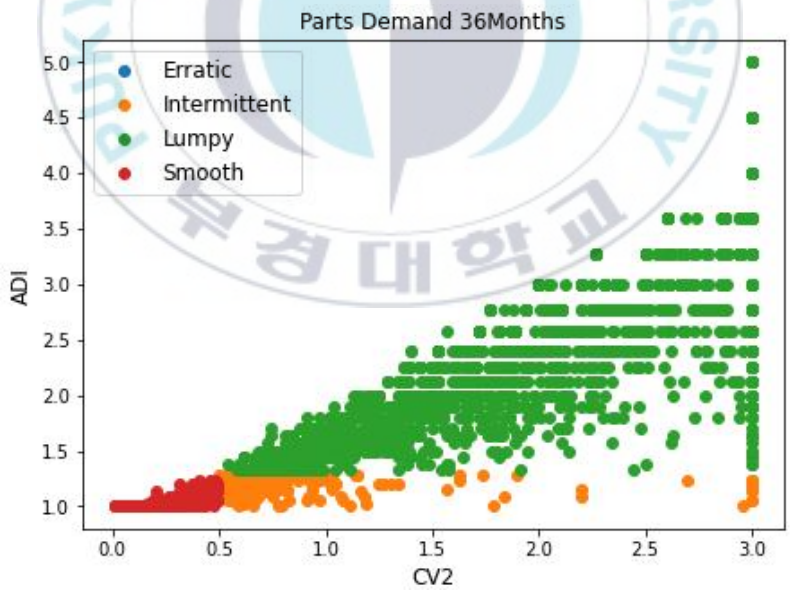

(b) 부품 유형별 분포(3년)

<그림 3-2> 부품 유형별 분포

수요 발생 기간이 짧고 수요가 많은 Smooth 수요 부품은 <표 3-5>과 같이 오일 또는 에어 필터로 정기적으로 교체가 필요한 정비·점검 소모성 부품으로 수요 예측이 비교적 원활하다.

<표 3-5> Smooth 수요 유형 샘플

Parts No.	Parts Description	ADI	CV^2	Demand type
MA275 180 00 09	FILTER	1.00	0.24	Smooth
MA276 906 05 01	IGNITION COIL	1.09	0.47	Smooth
MA622 180 00 00	OIL FILTER	1.04	0.33	Smooth
MA725 270 37 07	OIL SUMP & FILTER	1.14	0.46	Smooth
MA273 094 04 04	AIR FILTER INSERT	1.04	0.36	Smooth

Smooth 수요 유형 부품 <그림 3-3>을 보면, 수요 발생 기간과 수량이 비교적 규칙적으로 발생하고 있다.

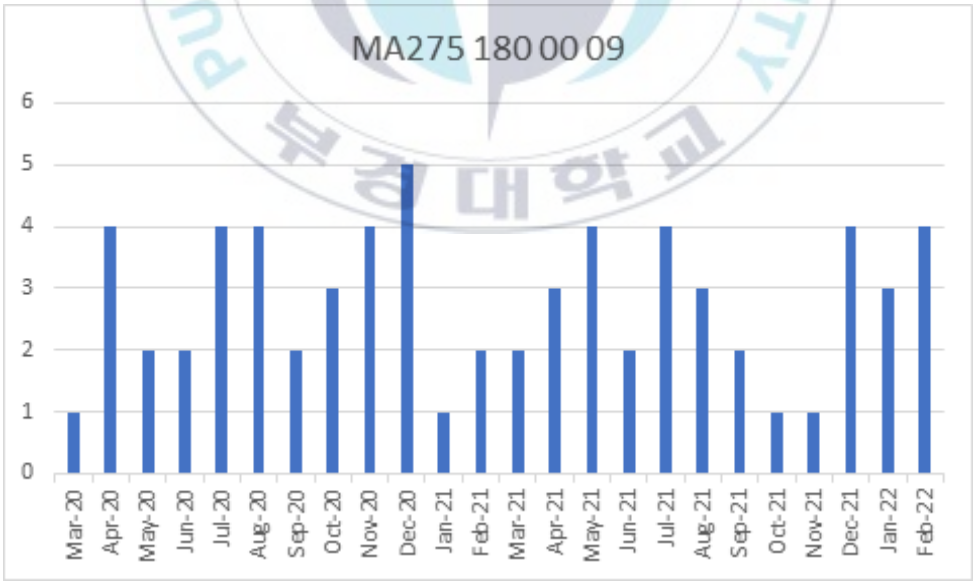

<그림 3-3> Smooth 수요 유형 부품

Interitternt 수요 유형도 Smooth 수요처럼 <표 3-6>와 같이 정기적인 소모성 부품으로 확인되고 있다. 그러나 <그림 3-4>를 보면, 수요 발생 기간이 불규칙적이고 0 수요가 빈번이 발생하고 있다.

<표 3-6> Intermittent 수요 유형 샘플

Parts No.	Parts Description	ADI	CV^2	Demand type
MA210 671 03 97	PAD	1.14	0.55	Intermittent
MA007 420 95 20	BRAKE PAD	1.09	0.72	Intermittent
MA000 420 56 02	TS DISK BRAKE PAD	1.09	0.50	Intermittent
MA213 905 13 00	ACCELERATION SENSOR	1.20	0.63	Intermittent
MA002 989 06 03/09	ATF-OIL	1.20	0.67	Intermittent

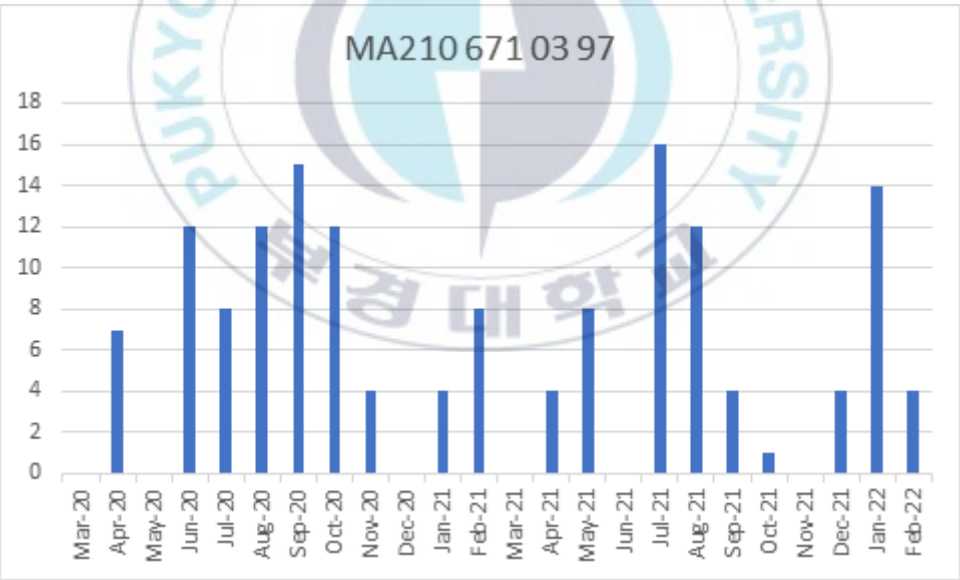

<그림 3-4> Intermittent 수요 유형 부품 샘플

<표 3-7>와 같이 정비 소모품을 제외한 운행 중 마모, 고장, 사고 등으로 수요가 발행하는 Lumpy 수요는 <그림 3-5>에서 나타난 것과 같이 매우 불규칙적인 수요를 보이고 있다.

<표 3-7> Lumpy 수요 유형 샘플

Parts No.	Parts Description	ADI	CV2	Demand type
MA222 610 35 00	CROSS MEMBER	1.50	0.90	Lumpy
MA000 906 28 10/64	GEAR MOTOR_R	1.41	0.64	Lumpy
MA000 991 83 32	BLIND RIVET W CSK. HEAD	1.41	1.37	Lumpy
MA004 159 58 03	SPARK PLUG	1.71	1.27	Lumpy
MA222 610 35 00	CROSS MEMBER	1.50	0.90	Lumpy

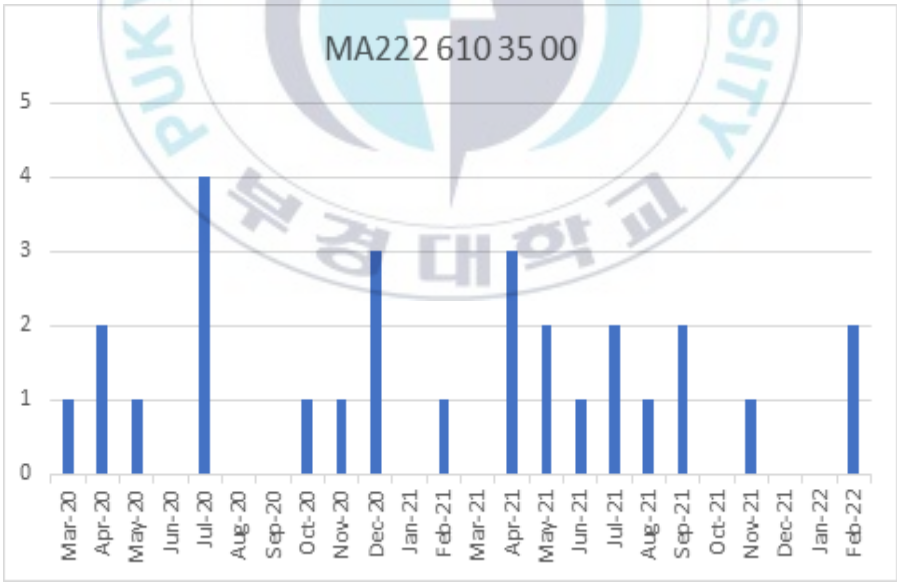

<그림 3-5> Lumpy 수요 유형 부품 샘플

정원희 외(2020)의 수요 패턴 별 머신러닝 수요 예측 시 모든 모델에서 Smooth 수요가 다른 수요 유형보다 높은 예측 성능을 발휘하였다. 그러나 Lumpy 수요는 대부분의 모델에서 정확도 50%미만으로 평가되어 예측이 매우 불안정하였다. 0이 아닌 수요 발생 기간이 길고 변동성이 큰 Lumpy는 수요는 불규칙적이고 비선형적 형태로 전통적 시계열 예측 기법으로 예측하는 데는 제한이 있다(Hill et al., 1996).

Intermittent 수요에 대한 예측 모델 연구는 아래의 <표 3-8>와 같이 다수 연구자들에 의해 다양한 모델로 이루어지고 있다.

<표 3-8> Intermittent 수요 예측 연구

연구자	내용	모델
Willemain et al., (2004)	9개 산업군의 서비스 부품 중 간헐적 수요 유형에 대한 예측 비교 연구	Exposmooth Croston bootstrap
Kourentzes (2013)	자동차 예비 부품의 간헐적 수요 시계열 데이터의 인공신경망 예측모델 연구	ANN
박진수 외 (2014)	간헐적 수요예측을 위한 부트스트랩 방법론의 응용을 통해 과거 수요 데이터의 상관구조를 재현하고 수요의 분포를 추정하는 방법론을 제안	Markov -bootstrap
허정훈 외 (2015)	Croston의 변형 모델 Modified Croston with Exponential Weight(MCEW)의 간헐적 수요 예측 방안 제안	MCEW
Lolli et al., (2019)	머신러닝과 심층신경망을 이용한 간헐적 수요 데이터 예측 연구	SVM DNN
유병철과 박영태 (2021)	항공화물의 수요를 품목과 노선에 따른 간헐적 수요 예측 연구	Crostorn, Holts

그러나 A/S 서비스 센터 부품 수요 유형의 대다수를 차지하고 수요의 불균형이 큰 Lumpy 수요 연구는 찾아보기 힘들다.

<표 3-9>은 연구 대상 A/S 서비스 센터의 수요 유형별 부품 수량, 총 재고량, 평균 판매가이다. Lumpy 수요의 경우 다른 수요 유형 대비 부품 수량이나 평균 판매가의 차이가 크게 나타나고 있다.

<표 3-9> 부품 수요 유형별 수량 및 평균 판매가(원)

수요 유형	부품 수량	총 재고량	평균 판매가(원)
Smooth	334	39,209	90,162
Intermittent	253	5,040	181,236
Erratic	-	-	-
Lumpy	16,295	21,125	359,478

본 연구는 수요는 크게 발생하지 않지만 A/S 센터의 부품 재고의 상당 부분을 차지하고 있는 Lumpy 수요 유형을 예측 대상 부품으로 선정하여 수요 예측 데이터 셋으로 구성하였다.

2. 데이터 셋 구성

2017년 1월부터 2021년 12월 기간 동안 판매 및 구매 수요가 있는 Lumpy 부품을 대상으로 수요 데이터를 부품 재고 관리 시스템으로부터 추출하였다. 그리고 <표 3-10>과 같이 특성변수 및 목표변수로 구성된 데이터 셋을 구성하였다. 수요 발생일(Demand Date)은 수집된 데이터의 전체 일자로 학습 대상 기간을 모두 포함하고 있다. 이전 재고 수량(Previous_Stock)은 실 구매 또는 판매 후 남은 재고 수량이고 마감재고 수량(Closing_Stock)은 기간별 마감 후 남은 재고 수량으로 본 연구에서 예측하고자 하는 목표 변수이다.

<표 3-10> 부품 수요 시계열 데이터 셋 정의

No	Variant	Description	Feature	Target
1	Demand Date	수요 발생일(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		●

<표 3-11>은 추출된 Lumpy 부품 유형의 시계열 데이터의 샘플로 구매 및 판매 수요가 불규칙적이고 샘플 데이터 중 특정월 2017년 11월, 2018년 2월에 다수 발생하고 있다.

<표 3-11> Lumpy 부품 유형 시계열 데이터 샘플

Demand Date	Previous Stock	Purchases Qty	Sales Qty	Closing Stock
2017-01-02	3	0	1	2
2017-01-09	2	0	1	1
2017-01-16	1	1	0	2
2017-02-14	2	0	1	1
2017-02-15	1	1	0	2
2017-03-06	2	0	1	1
2017-06-17	0	2	0	2
2017-07-24	2	0	1	1
2017-08-05	1	1	0	2
2017-09-27	2	0	1	1
2017-10-11	1	1	1	1
2017-10-18	1	1	0	2
2017-10-19	2	0	1	1
2017-11-06	**1**	**0**	**1**	**0**
2017-11-08	**0**	**1**	**1**	**0**
2017-11-10	**0**	**0**	**0**	**0**
2017-11-14	**0**	**1**	**1**	**0**
2017-11-18	**0**	**1**	**0**	**1**
2017-11-27	**1**	**0**	**1**	**0**
2017-12-07	0	2	1	1
2017-12-15	1	1	0	2
2017-12-20	2	1	1	2
2017-12-27	2	1	0	3
2018-01-08	3	0	1	2
2018-01-18	2	0	1	1
2018-01-26	1	1	0	2
2018-02-01	**2**	**0**	**1**	**1**
2018-02-06	**1**	**1**	**0**	**2**
2018-02-19	**2**	**0**	**1**	**1**
2018-02-21	**1**	**0**	**1**	**0**
2018-02-24	**0**	**1**	**1**	**0**
2018-02-27	**0**	**1**	**1**	**0**
2018-03-03	0	1	0	1
2018-03-07	1	1	0	2

<표 3-11>의 전체 데이터 셋을 일별, 주별, 월별 수요 그래프로 보면 <그림 3-6>과 같다. 각 수요 기간별 수리 부품 구매 및 판매 수요 경향을 보더라도 특정 기간에 다수의 수요가 발생하는 Lumpy 수요의 특징을 보이고 있다. 수리 부품 구매는 자동차 제조사 또는 제조사로부터 위탁받은 부품 업체로부터 순정 부품을 구매하고 있다. 그리고 차량 유지보수나 수리를 위해 고객 방문 시 부품 판매가 이루어지진다.

PUKYONG NATIONAL UNIVERSITY 부경대학교

기간	구매 수량	판매 수량
일별 수요	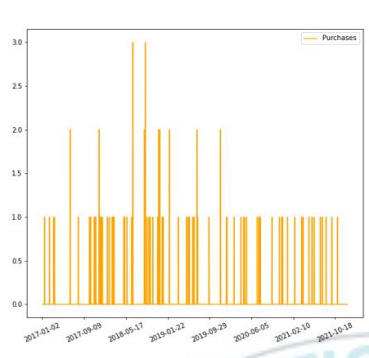	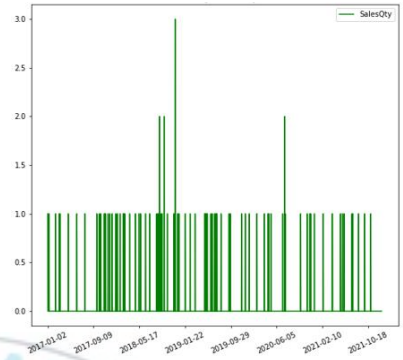
주별 수요	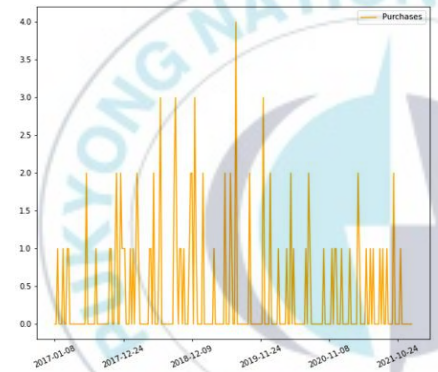	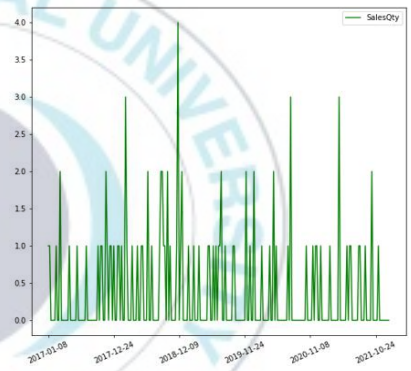
월별 수요		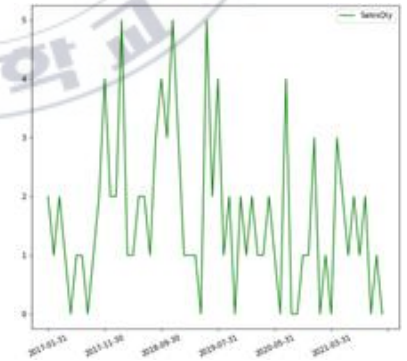

<그림 3-6> 일별, 주별, 월별 판매 및 구매 수요

3. 데이터 전처리

본 연구의 데이터 전처리는 일별, 주별, 월별 시계열 데이터 셋의 각 변수(Variant)의 수치에 대하여 -1~1 또는 0~1의 일정한 범위의 값으로 표준화(Standardization)한 후 이상치 발견 및 제거를 위해 정규화(Normalization)과정이 진행되었다. 표준화와 정규화는 입력 데이터 셋 값의 크기를 동일한 값으로 변경하는 과정이다. 정확한 학습 및 테스트와 예측 모델 성능향상을 위한 필수 과정이라 할 수 있다.

파이선 라이브러리 scikit-learn는 데이터의 표준화와 정규화를 지원하는 오픈 소스이다. 본 연구의 데이터 셋은 scikit-learn의 MinMaxScaler 표준화 방식으로 진행되었으며, scikit-learn 표준화 객체는 <표 3-12>과 같이 주로 4가지로 구성되어 있다.

<표 3-12> scikit-learn 표준화 방식

표준화 방식	설명
StandardScaler	모든 변수 데이터 값이 평균이 0, 분산이 1인 정규분포로 표준화 from sklearn.preprocessing import StandardScaler standardScaler = StandardScaler()
MinMaxScaler	모든 변수 데이터 값을 최대/최소가 1과 0이 되도록 표준화 from sklearn.preprocessing import MinMaxScaler minMaxScaler = MinMaxScaler()
MaxAbsScaler	모든 변수 데이터 값의 절대값이 0과 1 사이 값으로 표준화 from sklearn.preprocessing import MaxAbsScaler maxAbsScaler = MaxAbsScaler()
RobustScaler	모든 변수 데이터 값을 중간값과 사분위값으로 표준화 from sklearn.preprocessing import RobustScaler robustScaler = RobustScaler()

위와 같이 데이터 값의 크기를 동일한 범위로 표준화를 진행하더라고 이상치 문제는 예측 모델 성능 저하의 원인이 된다. 따라서 표준화된 데이터 셋을 다시 정규화 과정을 통하여 이상치 확인 및 제거를 진행해야 한다.

정규화 방식은 이상치 문제를 효과적으로 해결할 수 있는 Z-점수 정규화(Z-Score Normalization)를 이용하였다.

입력값 X가 평균과 같으면 0, 크면 양수, 작으면 음수 값을 구한 후 표준편차로 나누어서 특정 값 이상(-2 또는 2)으로 큰 경우 이상치로 제거되었다.

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

4. 모델 최적화 및 모델 적용

순환신경망 모델의 성능을 최적화하기 위한 방안 중 하이퍼파라미터의 설정이 중요한 요소이다. <표 3-13>은 각각의 기간별 수요 시계열 데이터를 신경망 모델에 적용 및 학습을 실행하여 도출된 최적화된 하이퍼파라미터 설정 값이다.

<표 3-13> 각 시계열 데이터의 하이퍼파라미터 설정 값

하이퍼파라미터	일별	주별	월별
Activation	relu/tanh	relu/tanh	relu/tanh
Optimizer	Adam	sgd	sgd
Learning rate	0.01, 0.001, 0.0001, 0.00001		
Epochs	200	200	200
Early Stop(Patience)	10	10	10
Batch Size	5, 10, 20, 30		

각 레이어의 Output에 대하여 다음 레이어의 전달 여부를 결정하는 활성화(Activation)함수는 relu/tanh로 적용하고 손실함수의 최소값 학습을 위한 최적화(Optimizer)함수로 일별 데이터는 Adam, 주별과 월별은 sgd로 설정하였다. 훈련횟수(Epochs)은 200으로 적용하였으나 Early Stop(Patience)을 설정하여 과적합(Overfitting)을 방지하였다. Early Stop의 속성 중 Patience는 모델의 성능이 더 이상 향상되지 않는 Epoch을 몇 회 허용할 것인지를 설정하는 것이다. 연구 모델은 Patience를 10으로 설정하여 10 epoch 동안 성능이 향상되지 않는 경우 학습을 중지시켰다. 학습률(Learning rate)은 0.01, 0.001, 0.0001, 0.0001, 배치 사이즈(Batch size)는 5, 10, 20, 30으로 변경하면서 순환신경망 단순RNN, LSTM, GRU 모델에 적용하여 수요 예측을 수행하였다.

ARIMA 모델의 최적 모델은 단위근검정(Unit root tests)으로 추정할 수 있는 차분(Difference) 차수를 구한 후 파이썬 pmdarima() 패키지의 auto_arima()함수를 이용하여 AR(Auto-regression) 차수 p와 MA(Moving average) 차수 q를 <표 3-14>과 같이 도출하여 학습이 수행되었다.

<표 3-14> 기간별 ARIMA 최적모델

기간	AR(q)	Diff(d)	MA(q)	Model
일별	2	1	2	ARIMA(2,1,2)
주별	1	1	3	ARIMA(1,1,3)
월별	3	1	1	ARIMA(3,1,1)

제 4 장 연구 결과

제 1 절 예측 데이터 셋 분석

본 연구에서 자동차 A/S 서비스 센터 수리 부품 중 매우 불규칙적이고 일정 기간에 다수의 수요가 발행하는 Lumpy 수요 유형을 대상으로 예측 데이터 셋을 구성하였다.

Lumpy 수요 유형의 부품 중 최근까지 수요가 발생하고 있는 부품의 5년 수요 시계열 데이터 셋 원본 샘플은 <표 4-1>과 같다.

수요 기간을 일별, 주별, 월별 구분 한 후 각 수요 기간별로 데이터 분석이 진행되었다. 주별 데이터는 일별 데이터를 기반으로 해당 주에 대한 각 변수들의 합계를, 월별 데이터는 해당 월의 각 변수들의 합계로 구성되었다. 각 해당 기간에 수요가 없는 경우 바로 전 일/주/월 데이터로 결측치를 보강하였다.

<표 4-1> 원본 수요 데이터 샘플

기간	시계열 데이터				
일별	DemandDate	PreviousStock	PurchaseQty	SalesQty	ClosingStock
	2017-01-02	3	0	1	2
	2017-01-03	2	0	0	2
	2017-01-04	2	0	0	2
	2017-01-05	2	0	0	2
	2017-01-06	2	0	0	2
	2017-01-07	2	0	0	2
	2017-01-08	2	0	0	2
	2017-01-09	2	0	1	1
	2017-01-10	1	0	0	1
	2017-01-11	1	0	0	1
주별	DemandDate	PreviousStock	PurchaseQty	SalesQty	ClosingStock
	2017-01-08	15	0	1	14
	2017-01-15	8	0	1	7
	2017-01-22	13	1	0	14
	2017-01-29	14	0	0	14
	2017-02-05	14	0	0	14
	2017-02-12	14	0	0	14
	2017-02-19	13	1	1	13
	2017-02-26	14	0	0	14
	2017-03-05	14	0	0	14
	2017-03-12	7	1	2	6
월별	DemandDate	PreviousStock	PurchaseQty	SalesQty	ClosingStock
	2017-01-31	54	1	2	53
	2017-02-28	55	1	1	55
	2017-03-31	50	2	2	50
	2017-04-30	54	0	1	53
	2017-05-31	31	0	0	31
	2017-06-30	36	2	1	37
	2017-07-31	55	0	1	54
	2017-08-31	57	1	0	58
	2017-09-30	57	0	1	56
	2017-10-31	32	2	2	32

그리고 각 기간별 수요 데이터에 대한 정규분포는 <그림 4-1>과 같이 나타났다. 구매(PurchaseQty)와 판매(SalesQty) 수요는 최소 1개에서 최대 3개가 발생하고 재고 보유 수량은 최대 4개까지 보유하고 있는 것으로 나타나고 있다.

기간	정규분포 그래프
일별	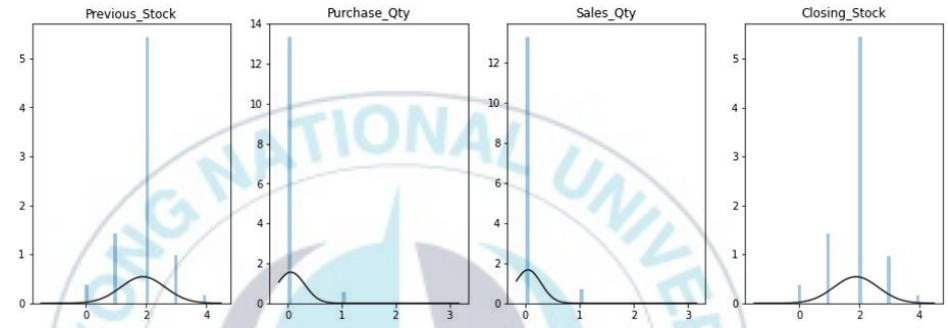
주별	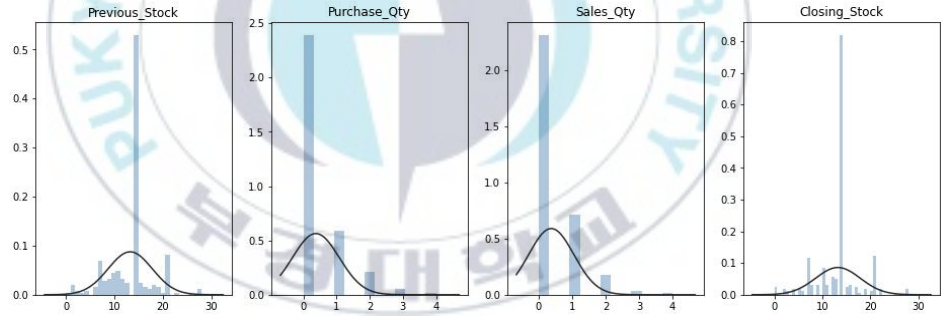
월별	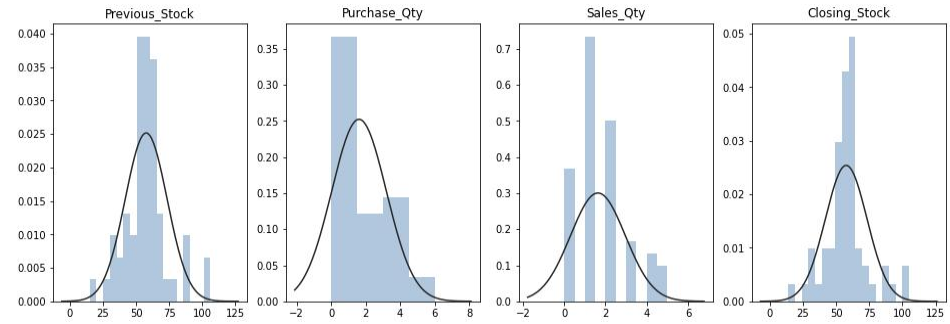

<그림 4-1> 각 기간별 수요 데이터 정규분포(X: 표본 수, Y:수량)

모델 학습이 원활이 진행될 수 있도록 <표 4-1>의 원본 수요 데이터에 대하여 데이터 전처리 과정을 진행하였다. 데이터 전처리는 표준화 및 정규화 과정으로 실 데이터 값을 -1~1 또는 0~1로 변환하는 것으로 본 연구는 최대/최소 값을 1과 0 으로 표준화 할 수 있는 MinMaxScaler 방식으로 진행하였다.

<표 4-2>는 본 연구 대상 데이터 셋의 표준화 전후의 평균과 분산으로 표준화 이후에는 데이터 값이 0~1로 변경 되었다.

<표 4-2> 기간별 표준화(Standardization) 평균과 분산

기간	특성 변수	Before		After	
		평균	분산	평균	분산
일별	Previous_Stock	1.89425	0.54309	0.57885	0.02172
	Purchase_Qty	0.05315	0.06570	0.01772	0.00730
	Sales_Qty	0.05370	0.05742	0.01790	0.00638
	Closing_Stock	1.89369	0.54242	0.57874	0.02169
주별	Previous_Stock	1.95402	0.52096	0.48851	0.03256
	Purchase_Qty	0.36399	0.50162	0.09100	0.03135
	Sales_Qty	0.36399	0.44008	0.09100	0.02751
	Closing_Stock	1.95402	0.51326	0.48850	0.03207
월별	Previous_Stock	1.85000	0.84153	0.46250	0.05260
	Purchase_Qty	1.61667	2.54548	0.26944	0.07071
	Sales_Qty	1.63333	1.79548	0.32667	0.07182
	Closing_Stock	1.83333	0.81920	0.45833	0.05120

<그림 4-2>은 원본 수요 데이터의 표준화 이후의 정규 분포로 Y 축의 특성 변수 및 목표 변수 값이 모두 0과 1사이의 값으로 변경되었다.

기간	정규분포 그래프
일별	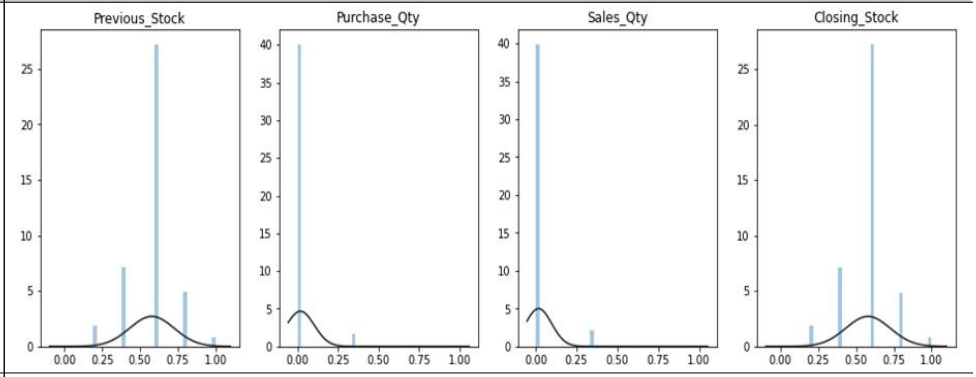
주별	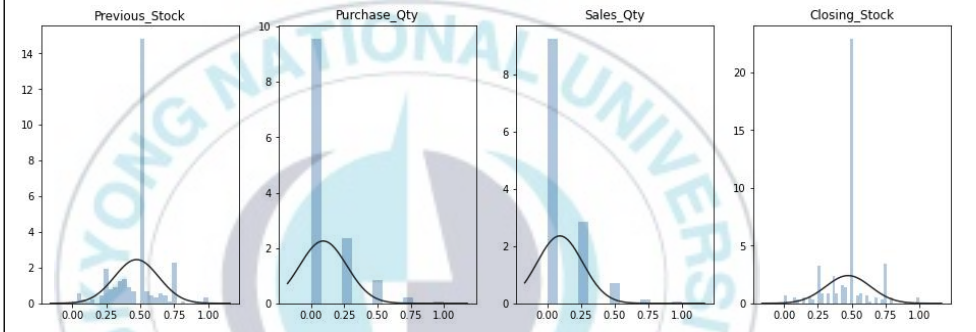
월별	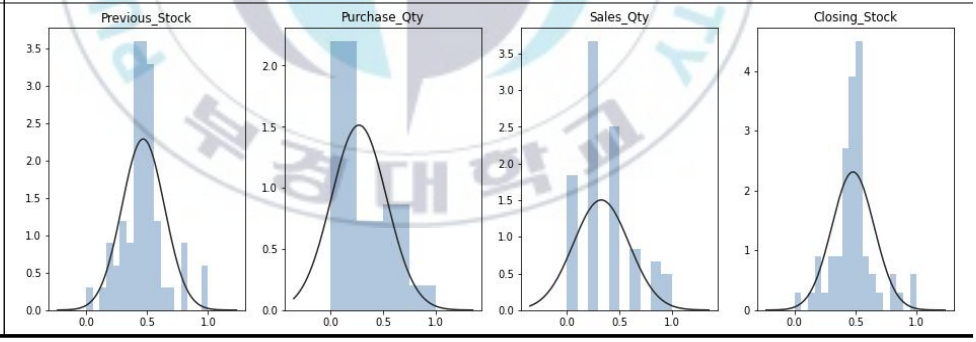

<그림 4-2> 표준화 된 각 기간별 수요 데이터 정규분포(X: 표본 수, Y:수량)

위와 같이 표준화 이후 이상치 확인 및 제거를 위해 Z-Score 정규화가 진행된 후 정규분포를 보면 <그림 4-3>과 같이 나타나고 있다.

기간	정규분포 그래프
일별	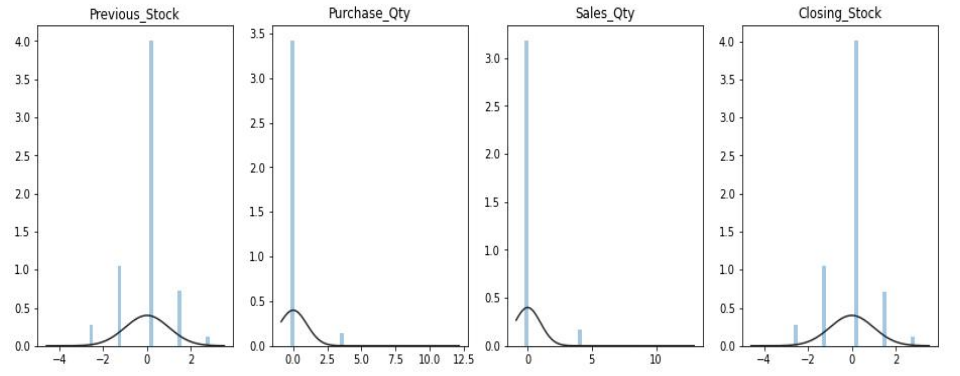
주별	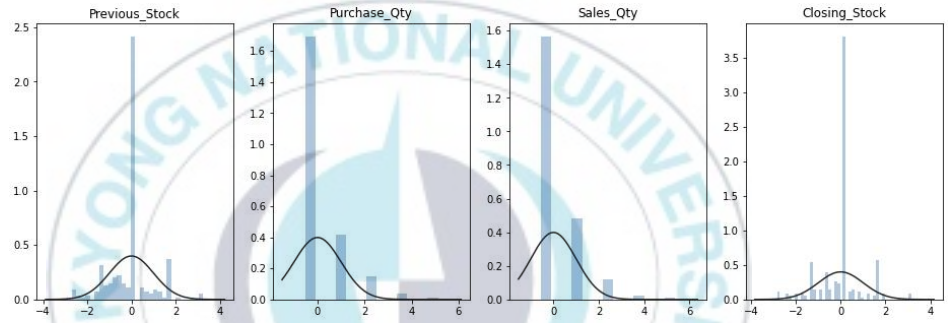
월별	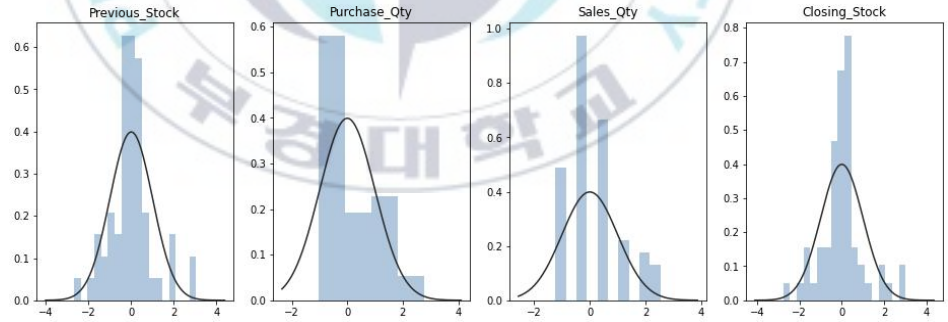

<그림 4-3> Z-Score 정규화된 기간별 수요 데이터 정규분포(X: 표본 수, Y:수량)

기간별 수요 데이터 중 주로 일별과 주별의 구매(Purchase_Qty)와 판매(Sales_Qty) 수량에서 정규분포의 오른 쪽 꼬리가 길어지면서 이상치가 다수 발생되는 것으로 확인 되고 있다. 그리고 Lumpy 수요의 특성과 같이 수요가 없는 0 구간에 다수의 데이터가 있고 특정기간에 한 번에 수요가 발생하는 것을 알 수 있다.

파이선 scikit-learn 라이브러리의 Z-Score 함수를 이용하여 각 기간별 수요 데이터의 이상치를 제거한 후 최종적으로 예측 모델 적용할 수 있는 표준화된 시계열 데이터 셋을 구성하였다.

본 연구의 수요 시계열 데이터 예측은 마감재고(ClosingStock)을 예측하기 위한 목표 변수에 대한 특성 변수를 이전재고 수량(PreviousStock), 구매수량(PurchaseQty), 판매수량(SalesQty)으로 사용하였다.

학습을 위한 데이터 셋은 <그림 4-4>와 같이 Window Size를 정의하여 특성 변수의 시계열 데이터를 Window Size 크기에 맞게 특성 변수 입력 데이터와 목표 변수 데이터를 생성하였다.

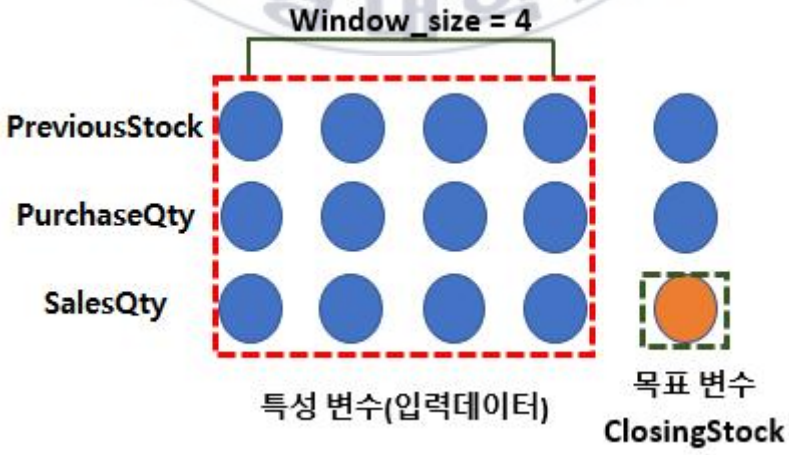

<그림 4-4> 학습 데이터 Window Size 예시

그리고 Widow_Size로 특성변수의 슬라이싱(Slicing)을 이용하여 훈련을 진행하였다. 슬라이싱은 목표 변수 값을 예측하기 위한 특성 변수의 데이터 셋의 범위를 결정한 후 순차적으로 훈련하는 방식이다.

각 기간별 수요 데이터의 이상치 제거 후 각 기간별 데이터 셋의 Widow_size를 각각 일별 6, 주별 4, 월별 2로 정의 한 후 학습 및 테스트를 위한 순차 데이터 셋이 <표 4-3>과 같이 생성 되었다.

일별 데이터 셋은 총 1,807개에 대하여 1회 학습(1 epoch) 시 30개의 데이터 셋(Batch size)이 입력된다. 그리고 6개의 특성 변수 입력 데이터 셋(Window_size)으로 목표 변수 6번째의 값을 정답으로 학습이 진행이 된다. 주별 데이터 셋은 총 248개에 대하여 1회 학습(1 epoch) 시 10개의 데이터 셋(Batch size)이 입력된다. 그리고 4개의 특성 변수 입력 데이터 셋(Window_size)으로 목표 변수 4번째의 값을 정답으로 학습이 진행이 된다. 월별 데이터 셋은 총 41개에 대하여 1회 학습(1 epoch) 시 5개의 데이터 셋(Batch size)이 입력된다. 그리고 2개의 특성 변수 입력 데이터 셋(Window_size)으로 목표 변수 2번째의 값을 정답으로 학습이 진행이 된다. 이와 같이 각각의 기간별 수요 데이터가 순차적으로 일별은 6개, 주별은 4개, 월별은 2개의 데이터 셋으로 위에서 아래와 각각 정답을 찾아가는 슬라이딩 방식으로 반복학습이 이루어진다.

<표 4-3> 특성 및 목표 데이터 셋 생성

기간	순차 데이터 셋 샘플	설명
일별	(1807, 6, 3) (1807, 1) [[0.8 0. 0.33333333] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.]] [0.6] [[0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.] [0.6 0. 0.]] [0.6]	(1807, 6, 3) 데이터 수량: 1,807개 Window Size: 6 특성변수 수: 3 특성변수 3개를 6개의 데이터 셋으로 목표 변수 6번째의 값을 정답으로 학습
주별	(248, 4, 3) (248, 1) [[0.75 0. 0.25] [0.5 0. 0.25] [0.25 0.25 0.] [0.5 0. 0.]] [0.5] [[0.5 0. 0.] [0.5 0. 0.] [0.5 0. 0.] [0.5 0. 0.]] [0.5]	(248, 4, 3) 데이터 수량: 248 Window Size: 4 특성변수 수:3 특성변수 3개를 4개의 데이터 셋으로 목표 변수 4번째의 값을 정답으로 학습
월별	(41, 2, 3) (41, 1) [[0.75 0.16666667 0.4] [0.5 0.16666667 0.2]] [0.5] [[0.5 0. 0.] [0.5 0.16666667 0.2]] [0.5]	(41, 2, 3) 데이터 수량: 41 Window Size: 2 특성변수 수:3 특성변수 3개를 2 개의 데이터 셋으로 목표 변수 2번째의 값을 정답으로 학습

<표 4-3>과 같이 생성된 순차 데이터 셋에 대하여 학습 데이터 셋과 테스트 데이터 셋을 각각 70%와 30%로 구분하였다.

학습 데이터 셋은 예측 모델의 훈련을 위한 데이터 셋이고 테스트 데이터 셋은 훈련이 완료된 예측 모델에 대하여 테스트 데이터 셋으로 검증 과정을 진행하였다.

각각의 순환신경망 단순RNN, LSTM, GRU의 예측 모델을 학습 데이터 셋을 적용하여 학습이 진행되었다.

각 예측 모델별, 기간별 학습과정은 단순RNN은 <그림 4-5>, LSTM은 <그림 4-6>, GRU는 <그림 4-7>과 같이 나타나고 있다. 학습 과정은 실제 값과 예측 값의 차이인 손실함수(Loss Function) 값을 시각화한 것이다. 학습 시 손실(Training loss)과 테스트 시 손실(Validation loss)이 학습이 진행(Epochs)될수록 점점 손실(Loss)이 줄어드는 것을 확인할 수 있다.

각 예측 모델의 일별 Training loss와 Validation loss 곡선이 학습이 진행되면서 그 간격이 점점 줄어드는 반면에, 주별과 월별은 일정 간격으로 더 이상 줄어들지 않고 있다. 이는 일별 데이터 셋의 학습과 테스트가 잘 적합(Fitting)되고 있지만 주별과 월별은 과소적합(Underfitting)되는 경향을 보이고 있다. <표 4-4>, <표 4-5>, <표 4-6>은 각각 일별, 주별, 월별 예측 모델별 평가로 최적화 함수, 학습률, 배치 사이즈에 따라 학습이 진행되었다. 일별 시계열 데이터는 최적화 함수는 Adma, 학습률 0.0001, 배치 사이즈 10의 GRU 모델, 주별 시계열 데이터는 각각 SGD, 0.001, 30의 단순RNN, 월별 시계열 데이터는 모든 신경망 모델의 성능이 비슷하였으나 GRU 모델이 다소 평가 지표가 우수하였다. 모델별 최적화 함수의 경우 데이터 셋이 일별보다 작은 주별과 월별 시계열 데이터는 모든 데이터 셋을 비교하는 SGD함수가 성능이 좋았고 일별 시계열 데이터는 Adam 함수가 최적화 되었다.

기간	단순RNN 손실함수 그래프
일별	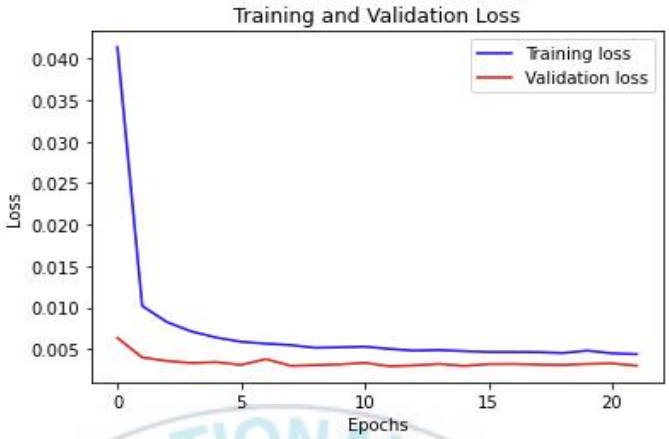
주별	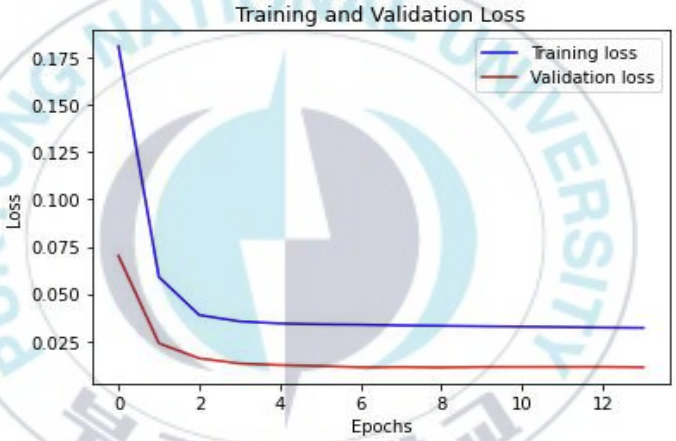
월별	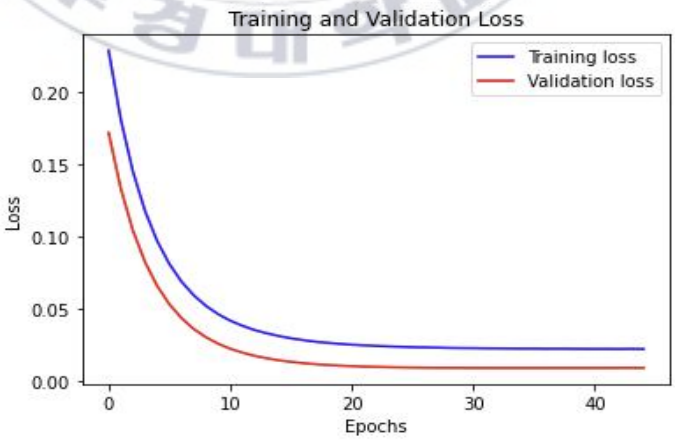

<그림 4-5> 단순RNN 훈련과정 시각화

기간	LSTM 손실함수 그래프
일별	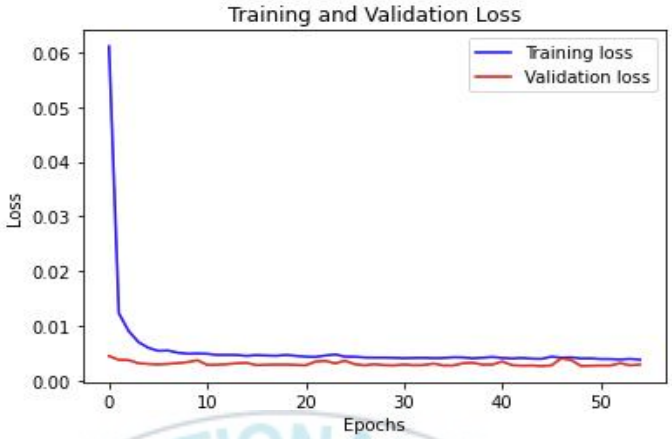
주별	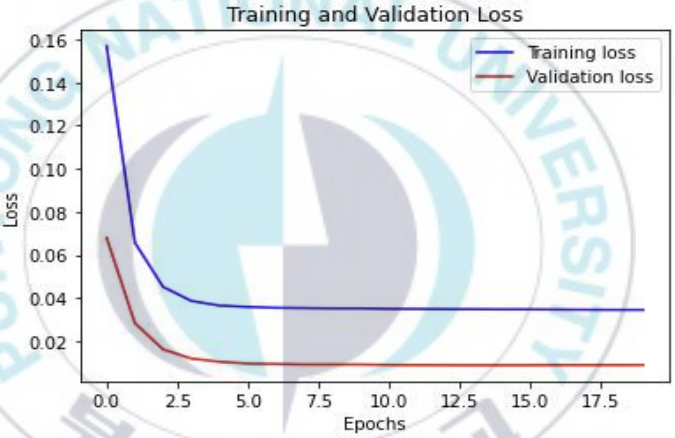
월별	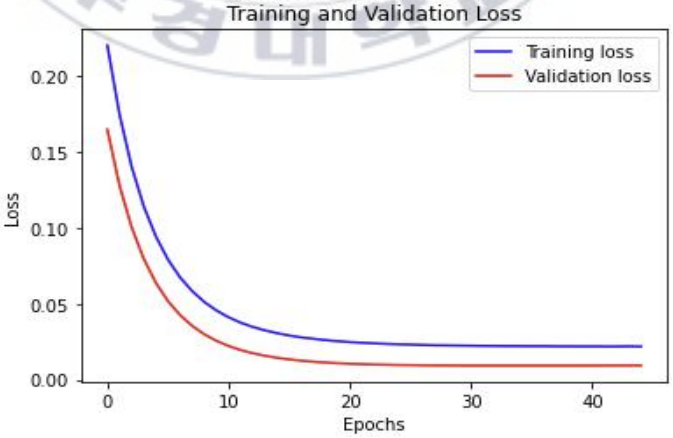

<그림 4-6> LSTM 훈련과정 시각화

기간	GRU 손실함수 그래프
일별	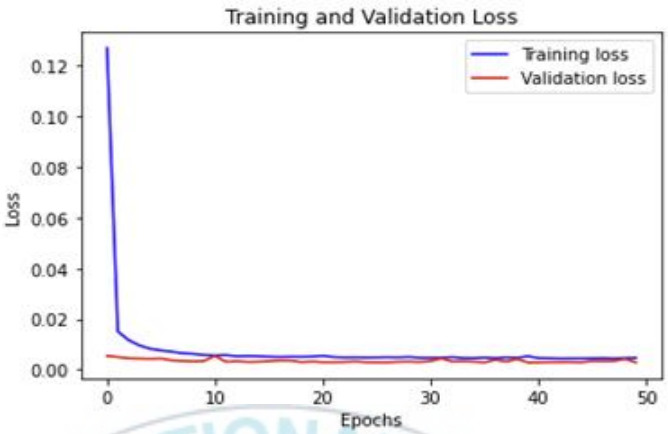
주별	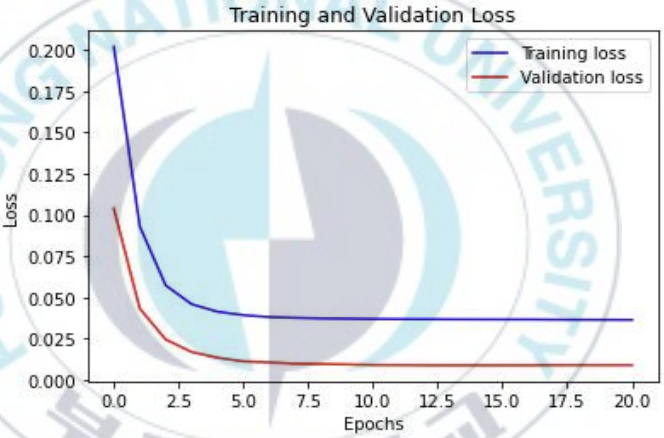
월별	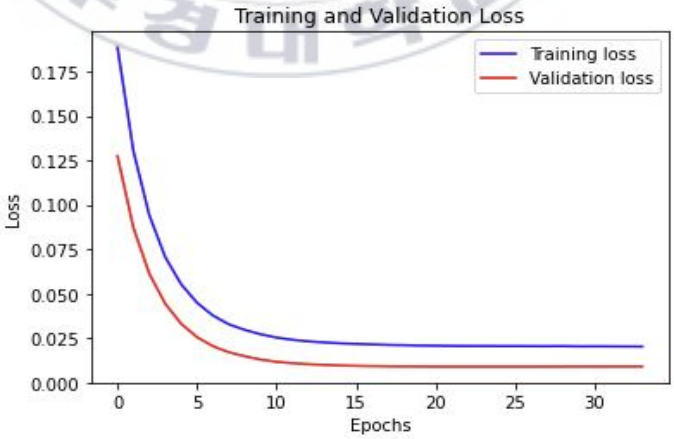

<그림 4-7> GRU 훈련과정 시각화

<표 4-4> 일별 순환신경망 예측 모델 평가

하이퍼파라미터			단순RNN			LSTM			GRU		
최적화 함수	학습률	배치 사이즈	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE
SGD	0.01	5	3.85	0.0534	0.0346	5.33	0.0581	0.0373	4.33	0.0538	0.0348
		10	4.32	0.0553	0.0359	5.04	0.0614	0.0393	4.38	0.0553	0.0356
		20	4.68	0.0558	0.0360	5.43	0.0662	0.0423	5.12	0.0583	0.0375
		30	4.29	0.0545	0.0351	5.56	0.0660	0.0423	5.23	0.0621	0.0398
	0.001	5	5.23	0.0560	0.0365	5.14	0.0574	0.0368	4.14	0.0538	0.0348
		10	4.73	0.0557	0.0360	5.19	0.0610	0.0392	4.05	0.0550	0.0354
		20	4.58	0.0585	0.0374	5.50	0.0668	0.0427	5.13	0.0593	0.0381
		30	5.43	0.0578	0.0373	5.49	0.0662	0.0424	5.18	0.0609	0.0390
	0.0001	5	3.80	0.0536	0.0346	5.31	0.0575	0.0369	4.08	0.0535	0.0346
		10	4.43	0.0548	0.0355	5.56	0.0672	0.0430	4.67	0.0552	0.0356
		20	4.77	0.0557	0.0358	5.51	0.0670	0.0429	4.74	0.0590	0.0378
		30	4.03	0.0547	0.0352	5.66	0.0660	0.0422	5.19	0.0612	0.0392
	0.00001	5	4.18	0.0553	0.0358	4.65	0.0565	0.0364	4.33	0.0539	0.0349
		10	3.98	0.0544	0.0351	5.75	0.0665	0.0426	4.45	0.0548	0.0353
		20	3.98	0.0534	0.0346	5.81	0.0676	0.0432	5.29	0.0585	0.0376
		30	4.44	0.0577	0.0370	5.73	0.0682	0.0432	5.12	0.0614	0.0393
Adam	0.01	5	3.94	0.0543	0.0356	3.36	0.0529	0.0342	5.30	0.0552	0.0359
		10	3.44	0.0531	0.0347	5.43	0.0550	0.0357	3.55	0.0538	0.0352
		20	5.13	0.0558	0.0361	3.73	0.0531	0.0346	3.51	0.0529	0.0346
		30	4.00	0.0532	0.0346	5.15	0.0551	0.0357	4.34	0.0531	0.0347
	0.001	5	3.42	0.0547	0.0359	3.31	0.0514	0.0334	4.20	0.0542	0.0354
		10	3.83	0.0535	0.0348	4.24	0.0534	0.0347	3.51	0.0534	0.0348
		20	4.52	0.0538	0.0350	4.75	0.0538	0.0350	3.41	0.0541	0.0354
		30	4.34	0.0555	0.0363	3.76	0.0541	0.0352	3.36	0.0539	0.0353
	0.0001	5	4.13	0.0547	0.0357	4.16	0.0524	0.0341	4.86	0.0548	0.0358
		10	5.08	0.0551	0.0357	4.50	0.0545	0.0356	4.57	0.0550	0.0360
		20	4.81	0.0543	0.0353	4.75	0.0548	0.0358	3.92	0.0540	0.0351
		30	4.56	0.0532	0.0344	3.39	0.0533	0.0348	3.82	0.0529	0.0345
	0.00001	5	3.64	0.0556	0.0362	3.88	0.0518	0.0336	3.51	0.0542	0.0355
		10	5.06	0.0554	0.0362	5.16	0.0543	0.0354	3.18	0.0537	0.0352
		20	3.89	0.0537	0.0348	3.90	0.0537	0.0349	3.23	0.0525	0.0343
		30	4.23	0.0548	0.0354	4.24	0.0535	0.0349	4.83	0.0540	0.0351

<표 4-5> 주별 순환신경망 예측 모델 평가

하이퍼파라미터			단순RNN			LSTM			GRU		
최적화 함수	학습률	배치 사이즈	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE
SGD	0.01	5	10.55	0.0695	0.0469	8.72	0.0649	0.0438	8.96	0.0648	0.0437
		10	9.41	0.0673	0.0454	8.95	0.0650	0.0438	8.85	0.0646	0.0436
		20	9.36	0.0645	0.0435	8.64	0.0646	0.0436	8.53	0.0639	0.0432
		30	10.03	0.0708	0.0479	8.88	0.0645	0.0435	8.48	0.0638	0.0431
	0.001	5	11.49	0.0738	0.0495	9.18	0.0657	0.0443	9.18	0.0657	0.0443
		10	11.08	0.0724	0.0487	8.63	0.0642	0.0433	8.72	0.0645	0.0435
		20	10.49	0.0719	0.0485	8.77	0.0644	0.0435	8.48	0.0634	0.0428
		30	8.32	0.0625	0.0423	8.72	0.0651	0.0440	8.63	0.0642	0.0434
	0.0001	5	9.85	0.0661	0.0445	8.42	0.0634	0.0428	8.63	0.0642	0.0433
		10	9.17	0.0672	0.0454	8.74	0.0646	0.0436	8.81	0.0649	0.0438
		20	9.52	0.0665	0.0448	8.69	0.0640	0.0432	8.73	0.0648	0.0437
		30	9.92	0.0701	0.0473	8.85	0.0649	0.0438	8.50	0.0639	0.0432
	0.00001	5	11.44	0.0749	0.0504	8.73	0.0645	0.0436	8.84	0.0648	0.0437
		10	11.29	0.0734	0.0494	8.67	0.0644	0.0435	8.83	0.0650	0.0439
		20	10.58	0.0693	0.0466	8.77	0.0646	0.0436	8.58	0.0642	0.0433
		30	9.88	0.0655	0.0441	8.85	0.0648	0.0437	9.10	0.0655	0.0442
Adam	0.01	5	11.77	0.0743	0.0499	12.28	0.0787	0.0529	10.88	0.0754	0.0507
		10	11.17	0.0752	0.0505	11.27	0.0752	0.0505	11.61	0.0751	0.0505
		20	11.31	0.0740	0.0498	11.15	0.0752	0.0506	11.74	0.0760	0.0510
		30	12.95	0.0796	0.0534	11.16	0.0742	0.0499	11.18	0.0741	0.0498
	0.001	5	10.71	0.0709	0.0477	11.34	0.0774	0.0517	11.69	0.0750	0.0504
		10	10.29	0.0703	0.0473	11.98	0.0769	0.0517	12.02	0.0763	0.0513
		20	10.28	0.0690	0.0464	10.60	0.0731	0.0492	10.47	0.0715	0.0482
		30	12.70	0.0780	0.0524	11.10	0.0751	0.0505	10.29	0.0713	0.0481
	0.0001	5	11.05	0.0753	0.0504	11.91	0.0796	0.0534	10.97	0.0753	0.0504
		10	12.02	0.0761	0.0510	13.04	0.0822	0.0553	10.82	0.0739	0.0497
		20	10.87	0.0728	0.0488	11.25	0.0756	0.0508	11.30	0.0744	0.0500
		30	10.35	0.0706	0.0475	11.92	0.0784	0.0527	11.40	0.0747	0.0503
	0.00001	5	10.63	0.0734	0.0492	11.48	0.0752	0.0506	10.68	0.0737	0.0495
		10	12.70	0.0780	0.0524	11.72	0.0770	0.0517	11.85	0.0762	0.0513
		20	11.11	0.0731	0.0491	11.34	0.0756	0.0508	11.03	0.0729	0.0491
		30	12.70	0.0780	0.0524	11.24	0.0754	0.0508	10.70	0.0733	0.0493

<표 4-6> 월별 순환신경망 예측 모델 평가

하이퍼파라미터			단순RNN			LSTM			GRU		
최적화 함수	학습률	배치 사이즈	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE	MAPE (%)	RMSE	RMSLE
SGD	0.01	5	8.80	0.0498	0.0332	8.94	0.0503	0.0335	9.09	0.0495	0.0331
		10	8.83	0.0496	0.0331	8.66	0.0502	0.0335	8.81	0.0486	0.0324
		20	8.68	0.0505	0.0337	8.85	0.0502	0.0335	9.02	0.0491	0.0328
		30	8.73	0.0500	0.0333	9.27	0.0536	0.0357	8.96	0.0491	0.0328
	0.001	5	9.08	0.0509	0.0339	8.81	0.0503	0.0335	8.95	0.0486	0.0325
		10	8.68	0.0493	0.0329	8.86	0.0501	0.0334	8.96	0.0496	0.0331
		20	8.94	0.0499	0.0333	8.83	0.0508	0.0338	9.01	0.0489	0.0327
		30	8.78	0.0493	0.0329	9.21	0.0538	0.0358	8.85	0.0481	0.0321
	0.0001	5	8.63	0.0493	0.0329	8.76	0.0495	0.0330	9.07	0.0497	0.0332
		10	8.68	0.0496	0.0331	8.83	0.0503	0.0335	9.19	0.0501	0.0335
		20	8.86	0.0499	0.0333	8.68	0.0509	0.0339	9.09	0.0499	0.0333
		30	9.01	0.0530	0.0353	8.84	0.0503	0.0335	9.05	0.0495	0.0331
	0.00001	5	8.99	0.0507	0.0338	8.81	0.0491	0.0328	9.15	0.0501	0.0335
		10	8.78	0.0498	0.0332	8.83	0.0505	0.0337	8.98	0.0494	0.0330
		20	8.88	0.0500	0.0333	8.65	0.0502	0.0335	9.05	0.0494	0.0330
		30	8.99	0.0506	0.0337	9.22	0.0525	0.0350	9.30	0.0515	0.0344
Adam	0.01	5	10.45	0.0654	0.0443	9.80	0.0596	0.0403	9.92	0.0626	0.0421
		10	9.89	0.0620	0.0420	9.87	0.0592	0.0400	10.03	0.0657	0.0444
		20	9.79	0.0602	0.0407	10.21	0.0644	0.0436	11.27	0.0721	0.0490
		30	10.86	0.0696	0.0472	10.47	0.0680	0.0461	11.18	0.0676	0.0451
	0.001	5	10.36	0.0651	0.0442	10.87	0.0700	0.0476	10.58	0.0687	0.0467
		10	9.77	0.0607	0.0410	10.25	0.0655	0.0444	10.30	0.0673	0.0456
		20	10.20	0.0647	0.0438	10.35	0.0663	0.0449	10.58	0.0689	0.0468
		30	11.91	0.0748	0.0507	12.38	0.0777	0.0529	11.30	0.0693	0.0461
	0.0001	5	9.76	0.0599	0.0405	10.22	0.0653	0.0443	10.75	0.0681	0.0463
		10	9.92	0.0620	0.0420	9.75	0.0597	0.0404	10.75	0.0692	0.0469
		20	10.31	0.0651	0.0441	9.85	0.0614	0.0415	9.99	0.0619	0.0413
		30	11.04	0.0705	0.0478	11.72	0.0736	0.0499	10.22	0.0628	0.0419
	0.00001	5	10.49	0.0678	0.0460	10.40	0.0675	0.0458	10.10	0.0618	0.0419
		10	10.19	0.0631	0.0428	9.84	0.0607	0.0411	10.30	0.0674	0.0456
		20	10.15	0.0642	0.0434	10.26	0.0654	0.0443	9.75	0.0590	0.0395
		30	11.70	0.0739	0.0502	12.25	0.0765	0.0519	10.25	0.0661	0.0447

제 2 절 예측 결과

<표 4-7>은 각 모델별·수요 데이터에 대한 각 순환신경망 모델과 ARIMA의 평가지표이다. 모든 모델에서 일별 시계열 데이터가 다른 시계열 데이터 보다 우수하게 예측되었다. 순환신경망 모델의 경우 각 모델의 평가지표가 크게 차이가 나지 않았으나 ARIMA 모델의 경우 모든 기간과 평가지표 순환신경망에 비하여 평가지표인 실제값과 예측값의 오차가 높게 나타나면서 비교적 낮은 예측 성능을 보이고 있다. 순환신경망 모델 중에서도 비교적 성능이 우수한 GRU를 보면, MAPE(%)가 3.18, RMSE 0.0537, RMSLE는 0.0352로 측정되었다. MAPE(%)는 오차의 절대값 평균을 기간으로 나눈 백분율 값으로 실제값과 예측값의 평균 오차가 3.18%이다. 그리고 RMSE는 실제값과 예측값의 차이를 직관적으로 확인할 수 있은 평균 오차로 표준화된 일별 데이터의 ClosingStock의 평균 값이 0.60으로 RMSE 0.0537을 빼면 평균 예측값은 0.54가 된다. 마지막으로, RMSLE는 RMSE의 로그 값으로 데이터 셋의 이상치 있는 경우 RMSE와 비교했을 때 RMSLE는 미미하게 증가한다. 따라서 데이터 전처리 과정을 통하여 이상치를 제거했지만 RMSLE 평가지표를 추가하여 이상치로 인한 모델 성능을 비교할 수 있다.

<그림 4-8>은 각 모델별·기간별 평가 지표 비교 그래프로, ARIMA 모델이 순환신경망 모델에 비하여 손실 오차가 모든 기간별 시계열 데이터에 높게 나타나고 있다.

<표 4-7> 모델별·시계열 데이터별 성능 비교

기간	단순RNN			LSTM			GRU			ARIMA		
	MAPE(%)	RMSE	RMSLE	MAPE(%)	RMSE	RMSLE	MAPE(%)	RMSE	RMSLE	MAPE(%)	RMSE	RMSLE
일별	3.42	0.0547	0.0359	3.31	0.0514	0.0334	3.18	0.0537	0.0352	4.64	0.0665	0.0454
주별	8.32	0.0625	0.0423	8.42	0.0634	0.0428	8.48	0.0634	0.0428	12.17	0.0824	0.0577
월벌	8.63	0.0493	0.0329	8.81	0.0491	0.0328	8.81	0.0486	0.0324	10.28	0.0579	0.0386

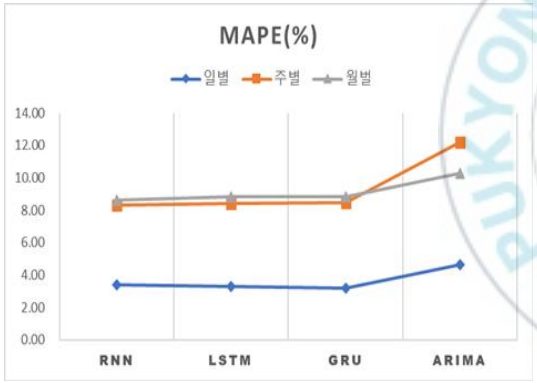

(a) 모델별 기간별 MAPE(%)

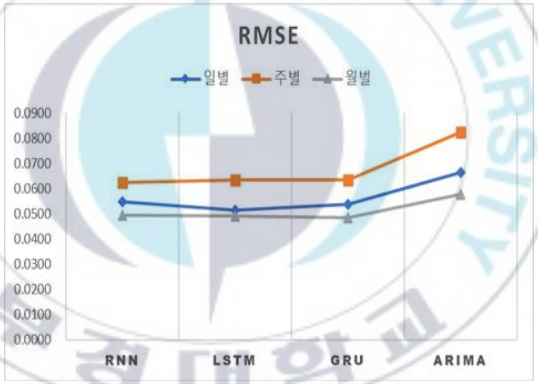

b) 모델별 기간별 RMSE

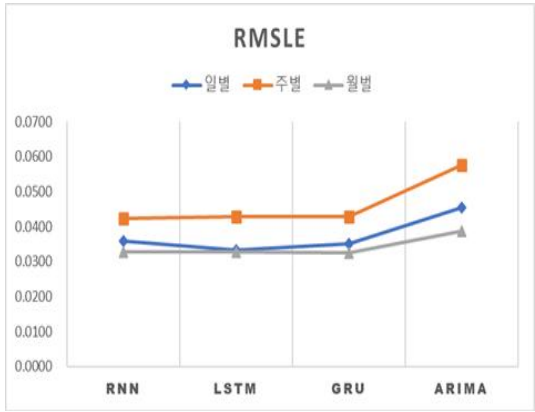

(c) 모델별 기간별 RMSLE

<그림 4-8> 각 예측 모델별, 기간별 평가지표 비교

<그림 4-9>는 Z-Score로 정규화된 일별 시계열 데이터에 대한 순환신경망 예측 모델의 실제 값과 예측 값 비교 그래프로 예측 값이 비교적 실제 값을 잘 추종하고 있다. 해당 수리 부품의 일 마감 실재고 수량은 5년 동안 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 1개~2개가 발생되고 있다.

각 모델의 수요 예측이 실재고 수량을 잘 반영하고 있지만 수요가 가파르게 상승하고 하락하는 구간에서는 차이를 보이고 있다. 그러나 전반적으로는 평가지표의 오차 값과 같이 실제 수요와 예측 수요는 근소한 차이를 보이고 있다.

본 연구의 순환신경망 모델의 시계열 데이터 예측은 데이터 셋 크기에 따라 영향이 큰 것으로 나타났다. 수집된 데이터 셋에 대하여 데이터 전처리 과정을 거친 후에 일별 수요 데이터 셋은 1,807개, 주별과 월별은 각각 248와 42개로 줄어들면서 훈련 데이터가 충분하지 않은 주별, 월별 시계열 데이터의 성능이 급격히 저하되었다.

예측 성능 향상을 위해 데이터 셋의 수집 기간을 늘리게 되면 수리 부품의 단종이나 대체 부품에 따른 수요가 발생하지 않아 성능 저하의 원인이 될 수 있다. 따라서 예측 모델 학습에 필요한 충분한 데이터 셋도 중요하겠지만 Lumpy 수요와 같이 수요 발생 기간이 길고 소량의 수요가 발생하는 수요 유형은 단종이나 대체 부품에 따른 수요의 종료 시점도 중요한 요인이 될 것이다.

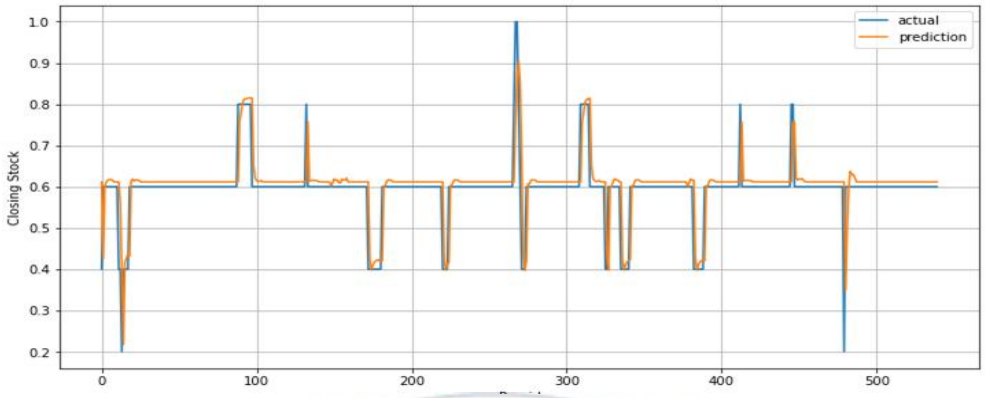

(a) ,단순RNN 모델 실제값과 계측값

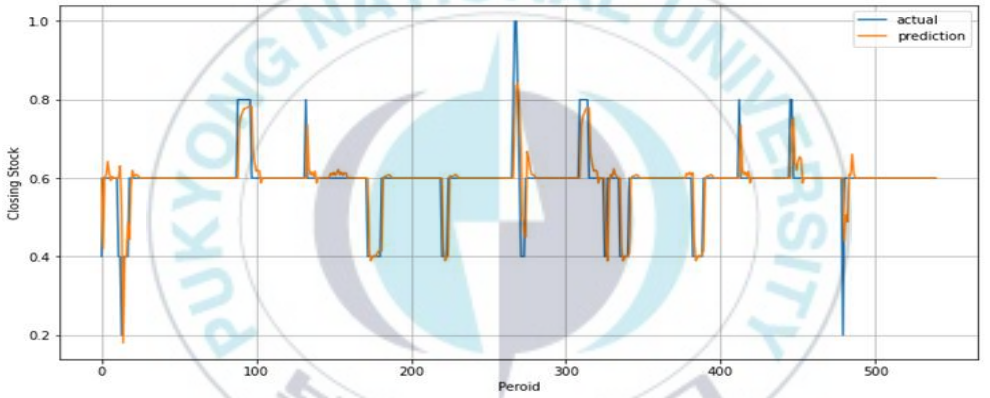

(b) LSTM 모델 실제값 vs 예측값

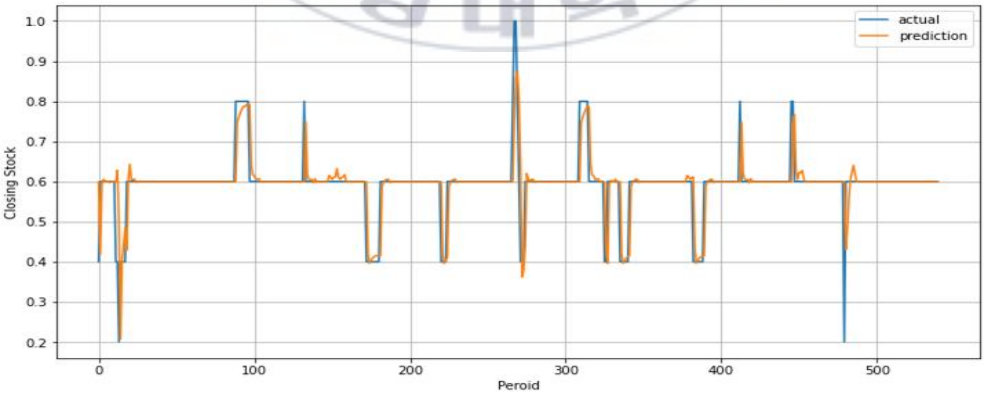

(c) GRU 모델 실제값 vs 예측값

<그림 4-9> 모델별 일별 시계열 데이터 실제값 vs 예측값

각 모델 성능 결과를 바탕으로 본 연구 대상 A/S 서비스 센터의 부품 중 Lumpy 유형에 대한 2021년 월별 백 오더, 주문 유형별 부품 수량과 원가 금액, 서비스 센터 매출을 활용하여 시뮬레이션을 진행하였다. 모델 평가지표 중 오차가 가장 낮게 측정된 일별 결과 값 중 실제값과 예측값의 평균 백분율 오차 MAPE(%)를 2021년 월별 각 실 데이터에 반영하여 각 모델별 개선 효과를 비교하였다.

고객 방문 시 부품이 부족하거나 없는 경우, 주문하게 되는 백 오더(Back Order, B-Order)와 부족한 부품을 예상하여 선 주문하는 재고오더(Stock Order, S-Order)에 대한 각 예측 모델 비교는 <표 4-8>과 같다. 백 오더 수량이 많은 경우 부품 부족에 따른 수리지연이 발생된다. 따라서 정확한 수요 예측으로 재고 오더를 늘리고 백 오더를 감소시킴으로써 부품 부족으로 인한 수리 지연을 방지할 수 있다. 각 예측 모델의 수요 예측 결과를 보면, 예측 모델을 반영하지 않은 No Model의 1년 합계 백 오더는 37,997이지만 각각의 예측 모델이 반영되었을 시 순환신경망 모델인 단순 단순RNN 3,067, LSTM 2,968, GRU 2,851로 감소하였으며 ARIMA 모델은 4,160로 가장 낮게 감소하였다.

부품 재고 원가는 주문 유형에 따라 원가 차이가 있다. 일반적으로 월 단위 재고주문은 판매가의 30%, 주 단위는 20%, 긴급주문은 10%의 할인 금액으로 공급 받는다. <표 4-9>는 2021년 월별 주문 유형별 부품 수량에 대한 예측 모델 결과를 비교한 것으로 긴급과 주 단위 주문이 감소하면서 월 단위 재고 주문이 증가하는 것을 알 수 있다. 각 예측 모델 반영 전 No Model 월 단위 재고량 합계가 42,142였으나 순환신경망 모델인 단순RNN, LSTM, GRU의 경우 합계가 각각 50,163, 50,220, 50,287으로 증가하였고 ARIMA 모델은 49,529로 가장 낮게 감소하였다. <표 4-10>은 <표 4-9>의 2021년 월별 주문 유형별 부품 수량을 구매 원가 금액으로 환산한 비교

결과이다. 순환신경망 모델인 단순RNN -13.5%, LSTM -13.3%, GRU -13.7로 감소하였고 ARIMA 모델은 -12.5%로 감소하였다. 감소폭이 가장 큰 GRU 모델 적용 시 년간 10억원원 상당의 부품 구매 비용을 절감할 수 있다.

마지막으로, 위와 같이 부품 구매 원가 절감에 따른 A/S 서비스 센터 매출 증대 효과를 비교하면 <표 4-11>과 같다. 서비스 센터 매출은 정비사의 공임과 부품 매출이다. 부품 구매 원가 비용 절감에 따른 각 모델별 매출 상승을 보면, 순환신경망 단순RNN 17.3%, LSTM 17.4%, GRU 18.0%으로 증가하였지만 ARIMA모델이 16.3%로 가장 낮게 증가하였다.

전반적으로, 부품 재고 수요 예측을 위한 순환신경망 모델과 ARIMA 모델을 적용 시 순환신경망 모델이 전통적인 수요 예측 모델인 ARIMA 모델보에 예측성능이 우수하였다. 순환신경망 모델 중에서는 GRU 모델이 다른 신경망 모델에 비하여 다소 높은 예측 성능을 보이고 있다.

<표 4-8> 2021년 월별 백오더(B-Order) & 재고오더(S-Order) 수량

Model	B/S Order	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	합계
No Model	B-Order	2,038	3,283	2,379	3,552	3,079	3,482	2,368	3,016	3,645	3,905	3,886	3,363	37,997
	S-Order	3,068	3,979	3,746	5,805	4,826	4,522	3,573	4,603	3,930	5,121	3,215	5,279	51,667
	Total	5,106	7,262	6,125	9,357	7,905	8,004	5,941	7,619	7,575	9,026	7,101	8,642	89,664
단순 RNN	B-Order	175	248	209	320	270	274	203	261	259	309	243	296	3,067
	S-Order	4,931	7,013	5,916	9,037	7,635	7,731	5,738	7,358	7,316	8,718	6,858	8,346	86,597
	차이	1,863	3,034	2,170	3,232	2,809	3,209	2,165	2,755	3,386	3,597	3,643	3,067	34,930
	차이(%)	60.7%	76.3%	57.9%	55.7%	58.2%	71.0%	60.6%	59.9%	86.2%	70.2%	113.3%	58.1%	67.6%
	Total	5,106	7,262	6,125	9,357	7,905	8,004	5,941	7,619	7,575	9,026	7,101	8,642	89,664
LSTM	B-Order	169	240	203	310	262	265	197	252	251	299	235	286	2,968
	S-Order	4,937	7,021	5,922	9,047	7,644	7,739	5,744	7,367	7,324	8,728	6,866	8,356	86,696
	차이	1,869	3,042	2,176	3,242	2,818	3,217	2,171	2,764	3,394	3,607	3,651	3,077	35,029
	차이(%)	60.9%	76.5%	58.1%	55.8%	58.4%	71.2%	60.8%	60.0%	86.4%	70.4%	113.6%	58.3%	67.8%
	Total	5,106	7,262	6,125	9,357	7,905	8,004	5,941	7,619	7,575	9,026	7,101	8,642	89,664
GRU	B-Order	162	231	195	298	251	255	189	242	241	287	226	275	2,851
	S-Order	4,944	7,031	5,930	9,059	7,654	7,750	5,752	7,377	7,334	8,739	6,875	8,367	86,813
	차이	1,876	3,052	2,184	3,254	2,828	3,228	2,179	2,774	3,404	3,618	3,660	3,088	35,146
	차이(%)	61.1%	76.7%	58.3%	56.1%	58.6%	71.4%	61.0%	60.3%	86.6%	70.7%	113.8%	58.5%	68.0%
	Total	5,106	7,262	6,125	9,357	7,905	8,004	5,941	7,619	7,575	9,026	7,101	8,642	89,664
ARIMA	B-Order	237	337	284	434	367	371	276	354	351	419	329	401	4,160
	S-Order	4,869	6,925	5,841	8,923	7,538	7,633	5,665	7,265	7,224	8,608	6,772	8,241	85,503
	차이	1,801	2,946	2,095	3,118	2,712	3,111	2,092	2,662	3,294	3,487	3,557	2,962	33,836
	차이(%)	58.7%	74.0%	55.9%	53.7%	56.2%	68.8%	58.6%	57.8%	83.8%	68.1%	110.6%	56.1%	65.5%
	Total	5,106	7,262	6,125	9,357	7,905	8,004	5,941	7,619	7,575	9,026	7,101	8,642	89,664

<표 4-9> 2021년 월별 주문 유형별 부품 수량 비교

Model	주문휴형	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	합계
No Model	긴급	12	18	33	32	31	42	52	41	35	30	48	42	416
	주단위	727	528	735	793	713	790	1,724	529	811	602	779	650	9,381
	월단위	4,477	3,143	3,958	3,246	3,682	4,180	3,611	3,321	4,262	2,765	4,209	1,288	42,142
	Total	5,216	3,689	4,726	4,071	4,426	5,012	5,387	3,891	5,108	3,397	5,036	1,980	51,939
단순 RNN	긴급	3	4	7	5	6	9	5	10	7	6	10	4	76
	주단위	175	122	155	134	145	163	179	124	167	111	162	64	1,700
	월단위	5,038	3,563	4,564	3,932	4,275	4,841	5,203	3,758	4,933	3,281	4,864	1,912	50,163
	Total	5,216	3,689	4,726	4,071	4,426	5,012	5,387	3,891	5,108	3,397	5,036	1,980	51,939
LSTM	긴급	3	4	7	5	6	8	5	9	7	5	10	4	74
	주단위	170	118	150	130	140	158	173	120	162	107	157	62	1,645
	월단위	5,043	3,567	4,570	3,936	4,279	4,846	5,209	3,762	4,939	3,285	4,869	1,914	50,220
	Total	5,216	3,689	4,726	4,071	4,426	5,012	5,387	3,891	5,108	3,397	5,036	1,980	51,939
GRU	긴급	3	4	6	5	6	8	5	9	7	5	9	4	71
	주단위	163	113	144	124	135	151	166	115	156	103	151	59	1,581
	월단위	5,050	3,572	4,576	3,942	4,285	4,853	5,216	3,767	4,946	3,289	4,876	1,917	50,287
	Total	5,216	3,689	4,726	4,071	4,426	5,012	5,387	3,891	5,108	3,397	5,036	1,980	51,939
ARIMA	긴급	4	6	9	7	9	12	7	13	10	7	14	6	103
	주단위	238	166	210	182	197	221	243	168	227	150	220	86	2,307
	월단위	4,974	3,518	4,507	3,882	4,221	4,779	5,137	3,710	4,871	3,239	4,802	1,888	49,529
	Total	5,216	3,689	4,726	4,071	4,426	5,012	5,387	3,891	5,108	3,397	5,036	1,980	51,939

<표 4-10> 2021 월별 주문 유형별 부품 원가 금액(단위: 천원) 비교

Model	주문유형	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	합계
No Model	긴급	9,210	4,704	16,458	33,603	13,633	16,205	48,183	24,487	13,871	9,641	16,172	7,643	213,811
	주 단위	163,038	91,672	173,786	132,157	204,701	185,373	363,478	173,966	303,157	184,930	150,386	86,230	2,212,876
	월 단위	488,176	367,519	401,659	358,281	500,121	468,378	480,457	448,132	492,433	471,272	463,723	152,521	5,092,672
	Total	660,425	463,895	591,903	524,041	718,456	669,956	892,118	646,586	809,461	665,843	630,281	246,395	7,519,358
단순 RNN	긴급	2,223	1,087	3,464	5,671	2,774	3,339	4,998	5,717	2,864	1,772	3,368	748	39,152
	주 단위	39,356	21,183	36,574	22,303	41,647	38,191	37,706	40,614	62,600	33,995	31,319	8,438	401,044
	월 단위	549,306	416,611	463,194	433,973	580,618	542,398	692,247	507,091	569,996	559,190	535,862	226,447	6,061,936
	Total	590,885	438,881	503,231	461,947	625,038	583,928	734,951	553,422	635,460	594,957	570,549	235,633	6,502,132
	차이	-69,540	-25,014	-88,671	-62,093	-93,417	-86,028	-157,167	-93,164	-174,000	-70,886	-59,732	-10,762	-1,017,226
	차이(%)	-10.5%	-5.4%	-15.0%	-11.8%	-13.0%	-12.8%	-17.6%	-14.4%	-21.5%	-10.6%	-9.5%	-4.4%	-13.5%
LSTM	긴급	2,152	1,052	3,352	5,489	2,684	3,231	4,838	5,533	2,772	1,715	3,260	724	36,801
	주 단위	38,090	20,501	35,398	21,586	40,308	36,963	36,493	39,308	60,586	32,901	30,312	8,167	400,612
	월 단위	549,932	417,086	463,721	434,468	581,279	543,016	693,035	507,668	570,646	559,827	536,472	226,705	6,083,854
	Total	590,173	438,639	502,471	461,542	624,271	583,210	734,366	552,509	634,004	594,443	570,044	235,595	6,521,268
	차이	-70,251	-25,256	-89,432	-62,499	-94,185	-86,746	-157,752	-94,077	-175,457	-71,400	-60,237	-10,800	-998,091
	차이(%)	-10.6%	-5.4%	-15.1%	-11.9%	-13.1%	-12.9%	-17.7%	-14.5%	-21.7%	-10.7%	-9.6%	-4.4%	-13.3%
GRU	긴급	2,067	1,011	3,221	5,273	2,579	3,104	4,648	5,316	2,663	1,648	3,132	695	36,404
	주 단위	36,594	19,696	34,007	20,738	38,725	35,511	35,060	37,764	58,207	31,609	29,122	7,846	372,901
	월 단위	550,671	417,647	464,345	435,052	582,060	543,746	693,967	508,351	571,413	560,580	537,193	227,009	6,077,000
	Total	589,332	438,353	501,573	461,063	623,364	582,361	733,674	551,431	632,283	593,837	569,447	235,551	6,486,305
	차이	-71,092	-25,541	-90,330	-62,978	-95,092	-87,595	-158,444	-95,155	-177,178	-72,007	-60,835	-10,844	-1,033,053
	차이(%)	-10.8%	-5.5%	-15.3%	-12.0%	-13.2%	-13.1%	-17.8%	-14.7%	-21.9%	-10.8%	-9.7%	-4.4%	-13.7%
ARIMA	긴급	3,016	1,475	4,699	7,694	3,763	4,529	6,781	7,756	3,886	2,404	4,569	1,015	53,118
	주 단위	53,395	28,739	49,621	30,259	56,504	51,815	51,156	55,102	84,931	46,122	42,492	11,448	544,106
	월 단위	542,367	411,349	457,343	428,491	573,283	535,547	683,502	500,685	562,796	552,126	529,093	223,586	5,985,362
	Total	598,779	441,562	511,663	466,444	633,550	591,891	741,440	563,544	651,613	600,652	576,154	236,049	6,582,587
	차이	-61,646	-22,333	-80,240	-57,596	-84,906	-78,065	-150,678	-83,042	-157,848	-65,191	-54,127	-10,346	-936,772
	차이(%)	-9.3%	-4.8%	-13.6%	-11.0%	-11.8%	-11.7%	-16.9%	-12.8%	-19.5%	-9.8%	-8.6%	-4.2%	-12.5%

<표 4-11> 2021 월별 서비스 센터 매출 금액(단위: 천원) 비교

Model	기간	1월	2월	3월	4월	5월	6월	7월	8월	9월	10월	11월	12월	Total
No Model	부품 원가	660,425	463,895	591,903	524,041	718,456	669,956	892,118	646,586	809,461	665,843	630,281	246,395	7,519,358
	부품 판매가	725,137	721,055	836,601	709,574	850,382	898,527	985,732	963,816	874,847	1,152,267	1,047,933	919,936	10,685,808
	부품마진	64,712	257,160	244,699	185,533	131,927	228,571	93,614	317,230	65,386	486,424	417,652	673,541	3,166,449
	공임	192,424	183,410	216,450	183,338	186,878	217,513	217,764	197,545	179,780	261,592	272,945	237,752	2,547,392
	매출	257,136	440,570	461,149	368,871	318,805	446,084	311,378	514,775	245,166	748,016	690,597	911,293	5,713,841
단순 RNN	부품 원가	590,885	438,881	503,231	461,947	625,038	583,928	734,951	553,422	635,460	594,957	570,549	235,633	6,528,883
	부품 판매가	725,137	721,055	836,601	709,574	850,382	898,527	985,732	963,816	874,847	1,152,267	1,047,933	919,936	10,685,808
	부품마진	134,252	282,174	333,370	247,627	225,344	314,599	250,781	410,394	239,387	557,310	477,384	684,303	4,156,925
	공임	192,424	183,410	216,450	183,338	186,878	217,513	217,764	197,545	179,780	261,592	272,945	237,752	2,547,392
	매출	326,676	465,584	549,820	430,965	412,222	532,112	468,545	607,939	419,166	818,902	750,329	922,056	6,704,317
	차이	69,540	25,014	88,671	62,093	93,417	86,028	157,167	93,164	174,000	70,886	59,732	10,762	990,476
	차이(%)	27.04%	5.68%	19.23%	16.83%	29.30%	19.29%	50.47%	18.10%	70.97%	9.48%	8.65%	1.18%	17.33%
LSTM	부품 원가	590,173	438,639	502,471	461,542	624,271	583,210	734,366	552,509	634,004	594,443	570,044	235,595	6,521,268
	부품 판매가	725,137	721,055	836,601	709,574	850,382	898,527	985,732	963,816	874,847	1,152,267	1,047,933	919,936	10,685,808
	부품마진	134,963	282,416	334,130	248,032	226,111	315,317	251,367	411,307	240,843	557,823	477,890	684,341	4,164,540
	공임	192,424	183,410	216,450	183,338	186,878	217,513	217,764	197,545	179,780	261,592	272,945	237,752	2,547,392
	매출	327,388	465,826	550,580	431,370	412,989	532,830	469,130	608,852	420,623	819,415	750,835	922,093	6,711,932
	차이	70,251	25,256	89,432	62,499	94,185	86,746	157,752	94,077	175,457	71,400	60,237	10,800	998,091
	차이(%)	27.32%	5.73%	19.39%	16.94%	29.54%	19.45%	50.66%	18.28%	71.57%	9.55%	8.72%	1.19%	17.47%
GRU	부품 원가	589,332	438,353	501,573	461,063	623,364	582,361	733,674	551,431	632,283	593,837	569,447	235,551	6,486,305
	부품 판매가	725,137	721,055	836,601	709,574	850,382	898,527	985,732	963,816	874,847	1,152,267	1,047,933	919,936	10,685,808
	부품마진	135,805	282,701	335,029	248,511	227,018	316,166	252,058	412,385	242,564	558,430	478,487	684,385	4,199,503
	공임	192,424	183,410	216,450	183,338	186,878	217,513	217,764	197,545	179,780	261,592	272,945	237,752	2,547,392
	매출	328,229	466,112	551,479	431,849	413,896	533,679	469,822	609,930	422,344	820,022	751,432	922,137	6,746,894
	차이	71,092	25,541	90,330	62,978	95,092	87,595	158,444	95,155	177,178	72,007	60,835	10,844	1,033,053
	차이(%)	27.65%	5.80%	19.59%	17.07%	29.83%	19.64%	50.88%	18.48%	72.27%	9.63%	8.81%	1.19%	18.08%
ARIMA	부품 원가	598,779	441,562	511,663	466,444	633,550	591,891	741,440	563,544	651,613	600,652	576,154	236,049	6,582,587
	부품 판매가	725,137	721,055	836,601	709,574	850,382	898,527	985,732	963,816	874,847	1,152,267	1,047,933	919,936	10,685,808

부품 마진	126,358	279,493	324,939	243,129	216,832	306,636	244,292	400,272	223,234	551,615	471,779	683,887	4,103,221
공임	192,424	183,410	216,450	183,338	186,878	217,513	217,764	197,545	179,780	261,592	272,945	237,752	2,547,392
매출	318,782	462,903	541,389	426,468	403,710	524,149	462,056	597,817	403,014	813,207	744,724	921,639	6,650,613
차이	61,646	22,333	80,240	57,596	84,906	78,065	150,678	83,042	157,848	65,191	54,127	10,346	936,772
차이(%)	23.97%	5.07%	17.40%	15.61%	26.63%	17.50%	48.39%	16.13%	64.38%	8.72%	7.84%	1.14%	16.39%

PUKYONG NATIONAL UNIVERSITY 부경대학교

제 5 장 결론

제 1 절 연구결과의 요약

본 연구는 자동차 A/S 서비스 센터의 수리 부품 중 특정 기간에 불규칙적으로 수요가 발생하는 Lumpy 수요 유형에 대하여 일별, 주별, 월별 수요 데이터를 순환신경망 단순RNN, LSTM, GRU 모델과 ARIMA 모델을 활용하여 최적의 재고 수요 예측 모델을 구현하였다.

해당 연구 대상 자동차 A/S 서비스 센터의 35,200개 부품을 각각 24개월과 36개월의 수요 데이터를 평균수요 간격(AD)I와 변동계수(CV^2)를 이용하여 4가지 수요 발생 유형으로 구분하였다. 유효하게 분류된 부품은 각각 24개월 기준 16,295개, 36개월 기준 19,812개로 확인이 되었다. 반면에, 유효하게 분류되지 않은 부품은 최근 24개월 또는 36개월 기간에 수요가 발생하지 않은 부품이다. 즉, 이전에는 수요가 발생하였으나 최근 몇 개월 동안 수요가 없는 단종이나 대체 부품으로 볼 수 있다. 24개월 기준의 16,295개, 36개월 기준 19,812개 수리 부품 중 96% 이상이 수요가 불규칙적이고 특정 기간에 수요가 발생하는 Lumpy 수요 유형의 특징을 가지고 있었다. Lumpy 수요 유형은 다른 수요 유형보다 수요 발생 기간이 길고 수량은 작지만 평균 판매가가 다른 수요 유형에 비하여 상당이 높은 수요 유형이다.

본 연구는 Lumpy 수요 유형의 수리 부품을 대상으로 최근까지 수요가 발생하고 있는 부품을 선정하여 2017년 1월부터 2021년 12월까지 5년 동안의 부품 구매, 판매 그리고 재고수량의 수요 이력 데이터를 일별, 주별, 월별로 데이터 셋을 구성하였다. 이상치 및 결측치에 대한 데이터 전처리를

마친 후에 대표적인 3개의 순환신경망 단순RNN, LSTM, GRU 모델과 ARIMA 모델에 적용하여 예측 학습 및 비교·검증이 진행되었다.

데이터 전처리 과정은 먼저, 수리 부품의 데이터 특성을 파악하기 위한 기간별 수요 그래프로 시각화를 진행하였다. 확인 결과 평소에는 수요가 발생하지 않다가 특정 기간에 수요가 발생하는 Lumpy 수요의 특징을 확인하였다. 다음으로, 특성 변수인 이전 재고수량(PreviousSotck), 구매수량(PurchaseQty), 판매수량(SalesQty)과 목표 변수인 마감 재고수량(ClosingStock)의 데이터 값을 동일한 범위의 수치로 변환하는 표준화(Standardization)를 수행하였다. 표준화 방식은 최대값과 최소값을 각각 0과 1을 기준으로 변환하는 MinMax 표준화 방식을 사용하였다. 표준화 이후 이상치 여부를 파악하고 제거하기 위해 데이터 셋 정규화(Normalization)가 진행되었다. 정규화 방식은 이상치 문제를 효과적으로 해결할 수 있는 Z-Score 정규화로 입력값 X가 평균과 같은 0, 크면 양수, 작으면 음수 값을 구한 후 표준편차로 나누어 특정 범위 보다 큰 경우 이상치로 제거되었다. 제거되어야 할 이상치 범위는 표준화된 데이터 셋의 정규분포를 확인하여 각 기간별 데이터의 이상치 법위를 설정 후 제거되었다.

데이터 전처리가 완료된 데이터 셋은 학습 데이터 70%, 테스트(검증) 데이터 30%로 분리하였다. 학습 데이터 셋의 Window_size는 기간별로 일별 6, 주별 4, 월별 2로 생성하였다. Window_size는 신경망 1회 학습 시 특성 변수들의 입력 데이터 범위로, 예를 들어 Window_size가 4인 경우 특성 변수들의 입력 데이터(x) 4개를 학습한 후 4번째 목표 변수(y)의 값을 정답으로 학습을 한다.

데이터 전처리와 학습 데이터 셋 구성이 완료되면, 각 순환신경망의 예측 모델에 적용 전에 학습 성능에 영향을 미치는 최적화된 하이퍼파라미터 설정이 진행되어야 된다.

본 연구의 주요 하이퍼파라미터 설정 값으로, 활성화 함수(Activation function)는 relu와 tanh를 적용하였으며, 최적화 함수(Optimizer function)는 Adam과 sgd를 사용하였다. 학습률(Learning rate)은 0.01, 0.001, 0.0001, 0.0001, 학습 반복횟수(Epochs)는 200으로 설정하였으나 Early Stop의 Patience를 10으로 설정하여 더 이상 손실함수가 줄어들지 않은 경우 학습을 중지시켰다. 1 Epoch 당 모델 학습 시 처리해야 되는 데이터 샘플 수 Batch Size는 일별, 주별, 월별 각각 5, 10, 20, 30로 설정하였다.

ARIMA 모델은 차분 d, AR차수 p, MA차수 q에 따라 모델의 성능이 결정된다. 차분 d는 근단위검증(Unit root tests)로 최적 값을 구하고 auto_arima() 함수를 이용하여 AR차수 p, MA차수 q를 도출하였다. 일별은 ARIMA(2,1,2), 주별은 ARIMA(1,1,3), 월별은 ARIMA(3,1,1) 모델로 설정되었다.

학습 데이터 셋과 검증 데이터 셋을 각 순환신경망 단순RNN, LSTM, GRU 모델과 ARIMA모델에 적용하여 예측 모델 학습 및 검증이 진행되었다. 학습 및 검증과정을 각각 학습 및 검증 손실 값으로 시각화하여 확인 결과 <그림 5-1>과 같이 모든 예측 모델에서 일별 수요 데이터 셋이 학습 및 검증 손실이 가장 낮아지면서 학습과 검증이 일치하게 나타났다. 학습 모델 중에서는 각각 GRU, LSTM, 단순RNN, ARIMA 순서로 실제값과 예측값의 손실이 낮게 나타났다.

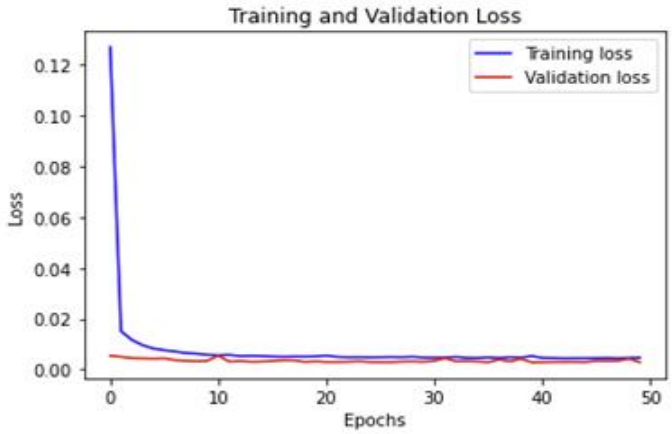

<그림 5-1> 일별 GRU 손실 함수 시각화

각 예측 모델의 성능 평가는 MAPE(%), RMSE, RMSLE의 오차(손실)로 측정이 되었다. MAPE(%)는 평균 절대 백분율로 실제값과 예측값의 오차의 절대값 평균을 기간으로 나눈 것으로 직관적으로 평균값과의 차이를 백분율로 확인할 수 있다. RMSE는 오차의 제곱 평균에 다시 제곱근한 값으로 이상치에 덜 민감하게 평가 가능한 지표이다. 마찬가지로 RMSLE의 경우도 이상치에 강하고 실제값과 예측값의 상대적 오차를 측정하는 지표 RMSE의 로그로 계산된다. 따라서 RMSLE는 수요 데이터 수치 크기가 다른 일별, 주별, 월별 수요 데이터의 예측 모델 성능을 평가·비교하는데 적합하다고 할 수 있다.

평가지표에 따른 모델별 성능을 보면, 학습 데이터 셋과 검증 데이터 셋의 손실 함수 그래프에서 나타난 것과 같이 GRU, LSTM, 단순RNN, ARIMA 순으로 예측 성능이 우수하게 평가되었다. 그리고 기간별 수요 데이터 중에서는 일별 수요 데이터가 각 모델별로 예측이 원활히 진행이 되었다. 그러나 주별과 월별은 학습이 과소적합(Underfitting)되면서 모델의 예측 성능을 발휘하지 못하였다. 이러한 결과는 주별, 월별의 데이터 셋이 줄어든 원인이라 할 수 있다. 이를 해결하기 위해 데이터 셋 수집 기간을

늘릴 경우 차량 단종에 따른 수리 부품의 단종이나 대체 순정 부품 사용으로 더 이상 수요가 발생하지 않는 데이터 셋으로 인하여 예측 성능저하의 원인이 될 수 있다. 그러므로 예측 모델 학습에 필요한 충분한 데이터 셋도 중요하겠지만 외부영향에 따른 수요기간 산정도 자동차 A/S 서비스 센터 부품 수요 예측에 중요한 요소라 할 수 있다.

제 2 절 연구의 시사점

본 연구의 수요 예측 모델은 자동차 A/S 서비스 센터 수리 부품 중 수요의 기간과 수량이 불규칙적으로 발생하는 Lumpy 수요 유형 부품에 대한 순환신경망 수요 예측 모델을 구현하는 것이다. 기존의 수요 예측 연구는 특정한 규칙적인 패턴과 변동 폭이 크지 않는 시계열 수요 데이터에 대하여 회귀모형이나 ARIMA와 같은 전통적인 통계 시계열 예측 모형을 이용하여 수요 예측이 연구되고 있었다(최가영 외, 2017; 윤한영 외, 2019; 홍지숙, 2019; 차효영 외, 2019; 김제철 외, 2019; Alsharif et al., 2019, 이성윤·안기명, 2020; Lai and Dzombak, 2020; 김승우 외, 2022).

수요가 불규칙적이고 변동 폭도 일정하지 않으면서 특정 기간에 다수의 수요가 발생하는 Lumpy 수요 패턴은 기존의 방식으로는 수요 예측의 오류 발생 가능성이 높다고 할 수 있다. 그리고 시계열 데이터의 전통적인 수요 예측 모형인 ARIMA는 주기적인 관측 값에 대한 추세와 경향 예측에는 적합하지만 주기성과 자기상관이 존재하지 않는 시계열 데이터를 예측하기에는 현실적으로 어려운 한계점이 있다(박진욱·박상현, 2017; 유병철·박영태, 2021; 김재성 외, 2020)

자동차라는 제품의 복잡성에 따른 많은 종류의 부품, 제품 수명 주기에 따른 부품의 단종과 부품 부족으로 인한 고객 불만 방지라는 높은 수준의

서비스 부품 중 자동차 수리 부품이 포함이 된다(권익현, 2017). 이러한 서비스 부품의 특성으로 적정한 수준의 부품 재고를 보유하기 위한 수요 예측은 중요한 사안이라 할 수 있다.

본 연구 대상의 자동차 서비스 센터의 수요 예측 모델은 수요 유형을 구분하지 않고 모든 부품에 대하여 구매, 판매 수요에 따른 재고 보유 수량을 확정한 후 재고 수량이 그 이하로 떨어지면 주문하는 방식이다. 부품 실무자 인터뷰에 따르면, Lumpy 수요유형과 같이 수요 기간과 수량이 불규칙적인 부품들도 특정 수량 이하로 재고수량이 감소하면 주문 리스트에 자동으로 포함된다. 이에 부품 실무자는 부품 주문 시 주문 리스트를 일일이 확인하면서 해당 부품을 제외해야하는 추가 작업이 발생하는 문제가 있다. 따라서 기존 예측 모델은 Smooth와 Intermittent 수요 유형의 재고 보유 수량 예측에는 적합하겠지만 Lumpy 수요 유형 예측을 위한 특화된 예측 모형이 필요하다고 할 수 있다.

본 연구에서는 자동차 A/S 수리 부품 중 수요기간과 수량이 매우 불규칙적인 Lumpy 수요 유형 부품을 대상으로, 인공신경망 중 순차적인 시계열 데이터 수요 예측에 성능이 우수한 순환신경망 단순RNN, LSTM, GRU 모델의 수요 예측 연구는 이례적이라 할 수 있다.

학문적인 관점의 본 연구는 순환신경망 알고리즘 모델을 이용하여 주기성과 자기 상관이 없고 불규칙적이면서 다품종 부품의 소량 수요가 발행하는 높은 수준의 서비스 부품에 대한 수요 예측 모형을 제안하였다.

일반적으로 순환신경망 모델 학습 시 데이터 셋의 품질도 중요하지만 충분한 학습 데이터 셋의 모델 훈련이 예측 성능을 향상시키는 중요한 요인이다. 그러나 서비스 부품과 같이 제품의 수명 주기에 따른 서비스 부품의 단종과 대체 부품으로 서비스 부품의 수요기간도 변하게 된다. 따라서 본 연구에서는 이러한 서비스 부품에 대한 수요 특성을 증명하는 계기를 마련

하였다. 즉, 서비스 부품에 대한 순환신경망 모델의 학습 데이터 셋 구성 시 제품과 서비스 부품의 생명주기를 바탕으로 수요기간에 따른 데이터 셋 생성을 고려해야 된다.

본 연구에서는 높은 서비스 수준을 요하는 자동차 A/S 수리 부품 중 가장 수요가 불확실한 Lumpy 수요 유형에 대한 예측을 순환신경망 모델에 적용하였다. 그리고 예측 성능을 비교·평가·검증함으로써 최적의 부품 재고 수요 예측이 가능한 일반화된 모형 구현 및 활용 가능을 제시하였다.

비즈니스 관점에서의 본 연구는 첫째, 자동차 수요의 증가와 함께 자동차 A/S 서비스 센터의 서비스 차량 입고 대수가 매년 증가하면서 수리 부품의 수요도 함께 증가하고 있다. 이러한 상황에 수리 부품의 적정 보유 재고 예측은 부품 부족으로 인한 수리 지연을 미연에 방지할 수 있다.

차량 고장이나 유지보수로 서비스 센터 방문하였으나 부품이 없는 경우 부품을 주문하게 되는데 이러한 주문을 백오더(Back Order)라고 한다. 백오더률이 높은 경우 많은 고객에게 부품 부족으로 인한 수리지연이 발생한다고 할 수 있다. 본 연구 대상의 서비스 센터는 매월 전체 부품 구매 건들 중 약 40% 이상이 백오더를 차지하고 있다. 월별 백오더와 재고오더(Stock Order) 수량으로 본 연구의 예측 모델 적용 시 연간 최대 68%까지 재고오더를 증가시키면서 백오더를 줄이는 효과가 있다. A/S 서비스 센터의 백오더 감소는 고객 방문 시 부품 부족에 따른 수리지연 없이 수리를 완료함으로써 고객에 대한 A/S 서비스 센터의 신뢰성 향상과 신속한 고장 수리로 고객 만족도 향상에도 기여할 것으로 기대된다. 둘째, 부품 구매 비용 절감 효과이다. 본 연구 대상의 A/S 서비스 센터는 월 또는 주 단위로 부품을 주문하고 구매하고 있다. 같은 부품이라도 월 단위 주문 시에는 평균적으로 판매가의 30% 할인, 주 단위 주문 시 판매가의 20% 할인을 받아 부품을 구매하고 있다. 긴급을 요하는 수리의 경우 당일 주문이 이루

어지게 되는데 판매가의 10%이하로 구매 원가가 발생하게 된다. 이와 같이 부품 재고 원가는 주문 유형에 따라 원가의 차이가 있다. 월 단위 재고 주문을 늘리고 긴급주문을 감소함으로써 전체적인 구매원가가 낮아지게 된다. 본 연구의 예측 모델을 활용하여 긴급주문 수량이 감소시키고 월 단위 주문 오더를 증가시키는 효과가 있다. 따라서 본 연구의 수요 예측 모델은 부품 수요를 미리 예측하여 월 단위 주문을 늘리고 긴급주문을 최소화함으로써 저 원가 구매로 서비스 센터의 전체 수리 매출 증가의 요인으로 작용하게 될 것이다.

셋째, 적정한 부품 재고 예측은 보관 창고 공간이나 관리 비용 등의 문제를 해결할 수 있다. 자동차연구원에 따르면, 내연기관차에 들어가는 부품은 약 3만개이고 전기차 부품은 대략적으로 1만 5천개로 추산하고 있다.

본 연구 대상의 A/S센터는 2021년 기준 월 평균 입고 대수 1,200 대를 수리하고 있고 보유 부품 수는 약 35,000개, 금액으로 28억에 해당한다. 그리고 12개월 이상 수요가 없는 부품이 전체 부품의 10%를 차지하고 금액으로는 2억8천에 해당된다. 이와 같이 장기 부품 재고의 보유는 보관 창고나 관리 비용의 문제와 함께 불필요한 재고 자산 증가의 원인이 될 수 있다. 따라서 본 연구의 수리 부품 재고 예측 모델을 실무에 적용함으로써 Dead Stock과 같은 비생산적인 요소를 제거하여 효율적이고 효과적인 서비스 센터 운영에 도움이 될 것이다.

마지막으로, 자동차 A/S 서비스 센터의 매출은 공임과 부품 매출로 이루어져 있다. 공임은 자동차 정비사의 인건비이고 부품 매출은 수리 시 발생된 부품 매출이다. 본 연구 대상 서비스 센터의 경우 전체 매출을 100으로 볼 때 공임과 부품 매출은 각각 약 20:80를 차지하고 있다. 부품 구매 원가를 고려하더라도 A/S 서비스 센터 전체 매출의 상당부분을 차지하고 있다. 본 연구의 예측모델에 따른 부품 구매 비용 절감은 부품 마진이 개

선되면서 전체적인 서비스 센터 매출 상승에 기여할 것으로 본다..

자동차 AS서비스 센터는 연간 사업 계획 수립 시 부품 구매 계획이 중요한 사안이 되고 있다. 따라서 본 연구의 수요 예측 모델은 부품 구매, 판매 및 재고 관리의 관점에서 서비스 센터의 전반적인 경영 계획 수립 시 주요 의사 결정 지원에 기여할 것으로 기대된다.

최근 산업계에서는 판매 후 서비스(After-Sales Service) 및 서비스 부품에 대한 수요 예측의 중요성을 인식하고 서비스 부품의 관리에 많은 투자를 하는 기업들이 늘어나고 있다(권익현, 2017). 이러한 현실 상황에 본 연구는 학문적으로는 순환신경망 알고리즘으로 높은 서비스 수준의 A/S 수리 부품 수요 예측의 근거를 마련했고 실무적으로 기업의 서비스 부품 관리 사업 확장 시 서비스 부품의 특성 인식과 적정 재고 예측 및 관리에 이바지할 것으로 기대한다.

제 3 절 연구의 한계점 및 향후 연구

본 연구는 인공신경망의 한 분류인 순환신경망 모델을 통해 자동차 A/S 서비스 센터의 수리 부품의 최적의 재고 수요 예측하는 것이다. 연구 진행 과정 중 적용하지 못한 몇 가지 과제와 향후 추가 연구 방안을 제시하고자 한다.

첫째, 예측 데이터 셋 구성에 대한 사항으로, 본 연구는 부품 구매, 판매 수량과 기간에 따른 보유 수량으로 예측 모델을 구현하였다. 그러나 모델 성능에 영향을 미칠 수 있는 다양한 외부 요소를 고려하지 못하였다. 수요 시계열 데이터 셋 이외에 부품 수요에 영향을 미칠 수 있는 차량 판매 대수와 연식, 서비스 센터 입고 대수와 차량 수리에 필요한 워크베이(Workbay)개수 등과 같은 외부 요소의 인과관계를 분석하여 특성 변수 추가 할 필요가 있다고 본다.

둘째, 부품 수요 유형을 Syntetos et al(2005)의 평균수요 간격(ADI)와 변동계수(CV^2)에 따라 4가지 유형으로만 분류하였다. 본 연구에서 35,000개의 부품 중 유효한 부품이 16,000 이상으로 다양한 부품을 4가지 유형으로만 분류하고 분석·예측하는 것은 예측 모델을 일반화하는데 한계로 작용할 수 있다. 수요 유형을 자동차 수리 부품의 특성에 따른 세분화를 통하여 순환신경망 모델 구현이 진행되어야 할 것이다.

셋째, 인공신경망은 크게 심층 신경망, 합성곱 신경망, 순환신경망으로 구분하고 있다. 본 연구는 비선형 시계열 데이터 예측에 적합한 순환신경망 단순RNN, LSTM, GRU으로 단일 예측 모델을 구현하였다. 그러나 김민경 등(2022)은 에너지 선물 스프레드 가격 시계열 데이터에 대하여 선형적 통계모형 ARIMA와 비선형 순환신경망 모형 LSTM, GRU을 결합한 하이브리드 순환신경망 예측 모델을 구현하였다. 그리고 모델 성능을 단일

예측 모델과 비교하여 하이브리드 모형이 손실 오차가 감소하는 것을 증명하였다. 따라서 본 연구 또한 전통적인 수요 예측 모델과 순환신경망 모델의 이점을 반영한 하이브리드 순환신경망 예측 모형으로 구현하여 예측 성능을 향상 시킬 수 있는 모델을 제안하고자 한다.

향후에는 위와 같은 연구의 한계점을 반영하여 부품 수요 시계열 데이터 이외의 수요 예측 성능에 영향을 미칠 수 있는 외부 요인을 분석한 후 특성 변수로 활용한다. 그리고 수요 유형을 서비스 부품 수요 특성에 맞게 세분화하여 순환신경망 모델 뿐만 아니라 전통적인 시계열 예측 모형과 결합한 하이브리드 모형 구현함으로써 서비스 부품 수요 예측 모델의 성능을 향상시키고 자동차 A/S 서비스 센터 수리 부품의 수요 예측 모델 일반화 연구에 기여하고자 한다.

PUKYONG NATIONAL UNIVERSITY 부경대학교

참고문헌

< 국 내 문 헌 >

김민경, 황수정, 김하영. “시계열 분해와 하이브리드 순환신경망 기반 스프레드 예측: 국제 에너지 선물 시장을 중심으로”. 재무관리연구, 제39권 제4호, 2022, pp.89-122.

김민식, 김형순, "심층신경망 기반의 음성인식을 위한 절충된 특징 정규화 방식", 한국음성학회논문집, 제12권 제3호, 2020, pp. 65-71.

김민정, 김정훈, "흉부 X-선 영상에서 심장비대증 분류를 위한 합성곱 신경망 모델 제안", 한국방사선학회논문지, 제15권 제5호, 2021, pp. 613-620.

김승우, 이평연, 권상욱, 김종훈, "시계열 모델 기반의 계절성에 특화된 S-ARIMA 모델을 사용한 리튬이온 배터리의 노화 예측 및 분석", 전력전자학회논문지, 제27권 제4호, pp. 316-324.

김재성, 양여진, 오민지, 이성웅, 권순동, 주완섭, “딥러닝 기법을 활용한 가구 부자재 주문 수요예측”, 한국빅데이터학회지, 제5권 제2호, 2020, PP. 111-120.

김제철, 손홍구, 박진서, "ARIMA-Intervention 모형을 통한 국제선 항공수요예측 연구", 대한교통학회지, 제37권 제1호, 2019, pp. 51-65.

김종배, 김유선, 박민영, “우리나라 기업들의 수요예측 실태에 관한 연구 - 2011년과 2020년 설문조사 비교·분석-”, 한국유통물류정책학회, 제8권 제4호, 2021, pp. 87-107.

정종진, 김지연, “LSTM을 이용한 주가예측 모델의 학습방법에 따른 성능분석”, 한국디지털융합복합연구, 제18권 제11호, 2020, pp. 259-266.

김형길, 오영희, “자동차 정비서비스의 고객만족에 관한 연구”, 산경논집, 제11권, 2003, pp. 118-120.

강대균, 현신우, 김광수, "온도와 강수를 이용하여 일별 일사량을 추정하기 위한 심층 신경망 모델 개발", 한국농림기상학회지, 제21권 제2호, 2019,

pp. 85-96.

강민제, "딥러닝을 위한 경사하강법 비교", 한국산학기술학회 논문지, 제21권 제2호, 2020, pp. 189-194.

강영옥, 조나혜, 박소연, 김지연, "합성곱신경망을 활용한 SNS 사진 분류 및 관광객과 거주자의 관광 활동 특성 분석", 대한지리학회지, 제56권 제3호, 2021, pp. 247-264.

구성관, 홍석민, 김기영, 권재일, "심층신경망을 활용한 풍속 예측 개선 모델 개발", 한국항행학회논문지, 제23권 제6호, 2019, pp. 597-604.

공동석, 곽영훈, 허정호, "도심지역 에너지계획을 위한 인공신경망 기반의 에너지 수요예측에 관한 연구", 대한건축학회 논문집, 제25권 제2회, 2010, pp. 221-230.

권익현, "부품 수명주기를 고려한 서비스 부품의 수요예측에 관한 연구", 대한안전경영과학회지, 제19권, 제3호, 2017, pp. 97-107.

민소아, 정윤서, "서울시 공공자전거 수요예측 모형 비교 연구", 한국데이터정보과학회지, 제32권 제3호, 2021, pp. 585-592.

박수호, 정민지, 황도현, 김나경, 윤홍주, "심층신경망을 활용한 Cochlodinium polykrikoides 적조 발생 예측 연구", 한국전자통신학회논문지, 제14권 제6권, 2019, pp. 1161-1170.

박소진, "자동차산업에서 고객만족과 충성도를 위한 통합 모델-자동차, 영업소, 서비스 센터의 지각된 품질이 고객만족과 충성도에 미치는 영향", 유통물류연구, 제6권 제1호, 2019, pp. 19-36.

박병준, 여기태, "시스템다이내믹스를 활용한 수입 자동차 소모품 출고예측에 관한 연구 - A 수입 자동차 부품 물류센터를 중심으로", 디지털융복합연구, 제19권 제1호, 2021, pp. 67-75.

박진수, 김윤배, 이하늘, 정기선, "간헐적 수요예측을 위한 부트스트랩 시뮬레이션 방법론 개발", 한국시뮬레이션학회논문지, 제23권 제3호, 2014, pp.19-25.

박진욱, 박상현, "인경신경망을 이용한 한국프로야구 관중 수요 예측에 관한 연구", 정보처리학회논문지, 제6권 제12호, 2017, pp. 565-572.

박진호, 이한덕, 송영효, "국내 자동차 수리용 부품 시장의 소비자잉여 손실 최소화 방안", 산업경제연구, 제26권, 제1호, 2013, pp. 111-136.

박종오, 박인선, 양창수, "자동차 정비서비스의 품질이 고객만족과 고객충성도에 미치는 영향", 한국서비스 경영학회지, 제11권, 제5호, 2010, pp. 176-198.

박현철, 이은지, 김윤재, 이상웅, "합성곱 신경망을 이용한 대장내시경 영상 분류", 한국차세대컴퓨팅학회 논문지, 제14권 제1호, 2018, pp. 89-98.

신성호, 이미경, 송사광, "LSTM 네트워크를 활용한 농산물 가격 예측 모델", 한국컨텐츠학회논문지, 제18권, 제11호, 2018, pp.416-429.

송민규, 마정목, "공군 수리부속 수요 데이터 분석기간 설정에 관한 실증연구", 한국산학기술학회논문지, 제23권, 제2호, 2022, pp. 197-185.

이경재, 김수재, 문형택, 한재윤, 추상호, "심층신경망 모형을 활용한 대중교통 이용자의 환승시간 추정에 관한 연구", 한국 ITS 학회논문지, 제19권 제1호, 2020, pp. 32-43.

이성윤, 안기명, "ARIMA 와 VAR· VEC 모형에 의한 부산항 물동량 예측과 관련성연구", Journal of Korean Navigation and Port Reserch, 제44권, 제1호, pp. 44-52.

이세혁, 김승현, 우용훈, 문재필, 양인철, "기계학습을 활용한 도로비탈면관리시스템 데이터 품질강화에 관한 연구". 대한지질공학회논문지, 제31권 제1호, 2021, pp. 31-42.

이민예, 성기우, 한성원, "계절조정을 활용한 전이학습 기반의 자동차 예비 부품 장기수요예측" 대한산업공학회지, 제47권, 제3호, 2021, pp.302-314.

오병훈, 김현철, "인공신경망을 이용한 수리부속 간헐적 수요예측", 한국정보처리학회논문집, 제24권, 제2호, 2017, PP. 824-826.

이영찬, 서창갑, "인공신경망을 이용한 항공기 기내식 수요예측의 예측력 개선 방안 연구", 한국정보시스템연구, 제10권 제2호, 2001, pp. 151-164.

이현상, 오세훈, "시계열 예측을 위한 LSTM 기반 딥러닝: 기업 신용평점 예측 사례", 한국정보시스템연구, 제29권 제1호, 2020, pp. 241-265.

오재건, 신현승, "국내 자동차 A/S용 부품 유통 문제와 대책 연구", 한국자동차공

학회, 제2권, 2005, pp. 1,143-1,148.
윤한영, 박성식, "ARIMA-Intervention 시계열 모형을 이용한 인천국제공항 식음료 매출 분석 및 추정 연구", 한국산학기술학회 논문지, 재20권, 제2호, 2019, pp. 458-468.
유병철, 박영태, "항공화물의 간헐적 수요예측에 대한 비교 모형 연구-Croston 모형과 Holts 모형을 중심으로", 한국항만경제학회지, 제37권, 제1호, 2021, pp. 71-85.
정경중, 최재식, “심층 순환신경망”, 정보화학회지 제33권 제8호, 2015, pp. 39-43.
정성훈, 진창하, “머신 러닝 방법을 이용한 오피스 임대료 산정 - 랜덤포레스트, 인공 신경망, 서포트 벡터 머신 활용 중심으로”, 부동산학 연구, 제26권, 제2호. 2020, pp. 23-53.
정동균, 이종화, 이현규, “머신러닝을 이용한 수입자동차 구매 해약 예측 모델 연구: H수입차 딜러사 대상으로”, 정보시스템 연구, 제30권, 제2호, 2021, pp. 105-126.
정이상, 정대현, “자동차 정비산업의 CRM 지향을 위한 통합 데이터베이스 설계”, 한국컴퓨터정보학회논문지, 제23권, 제5호, 2018, pp. 55-63.
정원희, 정다운, 강아영, 구영현, 유성준, "수요 패턴 별 최적 머신러닝 수요예측 모델 성능 비교". 한국차세대컴퓨팅학회 논문지, 제16권, 제6호, 2020, pp.76-89.
장훈석, "합성곱 신경망을 이용한 고선명 영상 획득", 한국정보기술학회논문지, 제19권 제9호, 2021, pp. 115-121.
지상민, 박지은, “비용함수와 파라미터를 이용한 효과적인 디지털 데이터 기계학습 방법론”, 디지털융복합연구, 제19권, 제10호, 2021, pp. 253-263.
지세현, 백의준, 신무곤, 채병민, 문호원, 김명섭, "합성 곱 신경망 기반 웹 응용 트래픽 분류 모델 설계", 한국통신학회논문지, 제44권 제6호, 2019, pp. 1113-1120.
조영기, 이현수, “변경된 Attention 메커니즘 기반의 LSTM을 통한 전력수요 예측 프레임웍”, 한국지능시스템학회논문지, 제30권, 제3호, 2020, PP. 242-250.

주우진, 김현식, 송미령, “자동차 A/S 부품 유통에서의 정보비대칭성에 관한 연구”, 경영논집, 제38권, 제4호, 2004, pp. 99-123.

조원호, 임용호, 박기호, ″합성곱 신경망을 이용한 딥러닝 기반의 토지피복 분류: 한국 토지피복을 대상으로″, 대한지리학회지, 제54권 제1호, 2019, pp. 1-16.

차효영, 오윤식, 송지우, 이태욱, ″다중개입 계절형 ARIMA 모형을 이용한 KTX 수송수요 예측″, 응용통계연구, 제32권, 제1호, 2019, pp. 139-148.

최가영, 이정희, 유리화, ″시계열분석을 통한 자연휴양림 계절별 이용수요 예측: 계절 ARIMA 모형과 지수평활 모형을 중심으로″, 관광경영연구, 제21권, 제3호, 2017, pp. 271-289.

최성희, “한국의 자동차정비산업(1)”, 한국 자동차 공학회 오토저널, 제27권, 제1호, 2005, pp. 166-122.

최정기, 최진영, “간헐적 수요를 갖는 철도 차량 유지 보수 부품을 위한 기계학습 기반 수요 예측 개선”, 대한설비관리학회지, 제26권, 제3호, 2021, pp. 17-25.

최희열, 민윤홍, “특집명 01:지능형 정보 시스템 ; 딥러닝 소개 및 주요 이슈”, 한국정보처리학회지, 제22권, 제1호, 2015, PP.7-15. 이재성, “심층 신경망의 발전 과정과 이해”, 한국통신학회, 제33권 제10호, 2016, pp.40-48.

홍원표, 김원영, 송영석, 임석규, ″인공신경망모델을 이용한 산사태 예측″, 한국지반공학회논문집, 제20권 제8호, 2004, pp. 67-75.

홍지숙, ″시계열 자료를 이용한 항공 수요예측: 대구국제공항을 중심으로″, 관광연구, 제34권, 제3호, 2019, pp. 61-77.

홍정식, 안재경, 홍석기, ″ 자동차 부품 수요의 예측 모형 개발″, 대한산업공학회지, 제27권, 제3호, 2001, pp.233-238.

여주대학 산업기술연구소, “자동차 정비사업체의 경영분석과 표준작업시간 책정에 관한 연구”, 2001.

송명구, 김경유, 안소현, “텍스트 분선을 통한 국내 자동차 산업구조 변화”, KiET 산업연구원, 연구자료, 2021-10.

한국 자동차 산업협동조합, https://www.kaica.or.kr/, 2022

< 국 외 문 헌>

Abraham, A., "Artificial neural networks", Handbook of measuring system d esign, 2005.

Agostinelli, F., Hoffman, M., Sadowski, P., and Baldi, P., "Learning activation functions to improve deep neural networks", arXiv preprint arXiv:1412.6830, 2014.

Alalawin, A., Arabiyat, L. M., Alalaween, W., Qamar, A., and Mukattash, A., "Forecasting vehicle's spare parts price and demand", Journal of Quality in Maintenance Engineering.

Alsharif, M. H., Younes, M. K., and Kim, J, "Time series ARIMA model for prediction of daily and monthly average global solar radiation: The case study of Seoul", South Korea. Symmetry, Vol. 11, No. 2, 2019, pp. 1-17.

Amin-Naseri, M. R., & Tabar, B. R., "Neural network approach to lumpy demand forecasting for spare parts in process industries", In 2008 IEEE International Conference on Computer and Communication Engineering, 2008, pp. 1378-1382.

Bengio, Y., Simard, P., and Frasconi.P., "Learning long-term dependencies with gradient descent is difficult", IEEE Transactions on Neural Networks, Vol. 5, No. 2, 1994, pp. 157-166.

Brownlee, J., "What is the Difference Between a Batch and an Epoch in a Neural Network", Machine Learning Mastery, Vol. 20, 2018.

Bod´en, M., "A guide to recurrent neural networks and backpropagation", In THE DALLAS PROJECT, SICS TECHNICAL REPORT T2002:03, SICS, 2002.

Box, Jenkins, and Gwilym M. Jenkins. "Reinsel. time series analysis, forecasting and control," Tercera. NJ: Prentice Hall, Englewood Cliffs,

NJ, USA, 1994.

Boylan, J. E., and Syntetos, A. A., "Spare parts management: a review of forecasting research and extensions", IMA journal of management mathematics, Vol. 21, No.3, 2010, pp.227-237.

Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y., "Learning phrase representations using RNN encoder-decoder for statistical machine translation", arXiv preprint arXiv:1406.1078, 2014.

Choi, D., Shallue, C. J., Nado, Z., Lee, J., Maddison, C. J., and Dahl, G. E., "On empirical comparisons of optimizers for deep learning", arXiv preprint arXiv:1910.05446, 2019.

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.

Claesen, M., and De Moor, B., "Hyperparameter search in machine learning", arXiv preprint arXiv:1502.02127, 2015.

Datta, L. "A survey on activation functions and their relation with xavier and he normal initialization", arXiv preprint arXiv:2004.06632, 2020.

Diaz, G. I., Fokoue-Nkoutche, A., Nannicini, G., and Samulowitz, H., "An effective algorithm for hyperparameter optimization of neural networks", IBM Journal of Research and Development, Vol. 61, No. 4/5, 2017, pp. 1-9.

Elman, J. L., "Finding structure in time", Cognitive Science, Vol. 14, No. 2, 1990, pp. 179 - 211.

Elshawi, R., Maher, M., and Sakr, S., "Automated machine learning: State-of-the-art and open challenges", arXiv preprint arXiv:1906.02287. 2019.

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.

Glorot, X., & Bengio, Y., "Understanding the difficulty of training deep feedforward neural networks", In Proceedings of the thirteenth international conference on artificial intelligence and statistics, 2010, pp.249-256.

Graves, A., Mohamed, A. R., & Hinton, G., "Speech recognition with deep recurrent neural networks", In 2013 IEEE international conference on acoustics, speech and signal processing, 2013. pp. 6645-6649.

Hill, T., O'Conner, M., and Remus, W, "Artificial neural network models for times forecasts", Management Science, Vol. 42, No. 7, 1996 pp. 1082-1092.

Hochreiter S., Bengio Y., Frasconi P., and Schmidhuber J., "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies," A Field Guide to Dynamical Recurrent Neural Networks. IEEE Press, 2001.

Hochreiter, S., and Schmidhuber, J., "Long short-term memory", Neural Computation, Vol. 9, 1997, pp. 1735-1780.

Kourentzes, N., "Intermittent demand forecasts with neural networks", International Journal of Production Economics, Vol. 143, No. 1, 2013, pp. 198-206.

He, K., Zhang, X., Ren, S., & Sun, J., "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification", In Proceedings of the IEEE international conference on computer vision, 2015, pp. 1026-1034.

Krizhevsky, A., Sutskever, I., and Hinton, G. E., "Imagenet classification with deep convolutional neural networks", Communications of the ACM, Vol. 60, No. 6, 2017, pp. 84-90.

Kukačka, J., Golkov, V., and Cremers, D., "Regularization for deep learning: A taxonomy", arXiv preprint arXiv:1710.10686, 2017.

Lai, Y., and Dzombak, D. A., "Use of the autoregressive integrated moving average (ARIMA) model to forecast near-term regional temperature and precipitation", Weather and Forecasting, Vol. 35, No. 3, 2020, pp. 959-976.

Lecun Y., Bottou L., Bengio Y., and Haffner P., "Gradient Based Learning Applied to Document Recognition", Proceedings of the IEEE, Vol. 86, 1998, pp.2278-2324.

Lipton, Z. C., Berkowitz, J., and Elkan, C., "A critical review of recurrent neural networks for sequence learning", arXiv preprint arXiv:1506.00019, 2015.

Lolli, F., Balugani, E., Ishizaka, A., Gamberini, R., Rimini, B., and Regattieri, A., "Machine learning for multi-criteria inventory classification applied to intermittent demand", Production Planning & Control, Vol. 30, No.1, 2019, pp. 76-89.

Nair, V., and Hinton, G. E., "Rectified linear units improve restricted boltzmann machines", In Icml., 2010.

Maas, A. L., Hannun, A. Y., and Ng, A. Y., "Rectifier nonlinearities improve neural network acoustic models", In in ICML Workshop on Deep Learning for Audio, Speech and Language Processing, Vol. 30, No. 1, 2013, p. 3.

McCulloch, W. S., and Pitts, W., "A logical calculus of the ideas immanent in nervous activity", The bulletin of mathematical biophysics, Vol. 5, No 4, 1943, pp.115-133.

Minsky, M., and Papert, S., "Perceptrons", MIT Press, 1969.

Owen, A. B., “A robust hybrid of lasso and ridge regression”, Contemporary Mathematics, Vol. 443, No. 7, 2007, pp. 59-72.

Rosenblatt, F., “The perceptron: a probabilistic model for information storage and organization in the brain”. Psychological review, Vol. 65, No. 6, 1958, pp.386-408.

Rožanec, J. M., Fortuna, B., and Mladenić, D., "Reframing demand forecasting: a two-fold approach for lumpy and intermittent demand". Sustainability, Vol. 14, No.15, 2021, pp1-28.

Ruder, S., “An overview of gradient descent optimization algorithms”, arXiv preprint arXiv:1609.04747, 2016.

Rumelhart, D. E., Hinton, G. E., and Williams, R. J., “Learning representations by back-propagating error”, nature, Vol 323. No. 6088, 1986, pp533-536.

Sherbrooke, C. C., "Optimal inventory modeling of systems: multi-echelon techniques", Vol. 72, Springer Science & Business Media, 2006.

Sharma, S., Sharma, S., and Athaiya, A., “Activation functions in neural networks”, towards data science, Vol. 6, No. 12, 2017, pp. 310-316.

Smith, L. N., “A disciplined approach to neural network hyper-parameters: Part 1--learning rate, batch size, momentum, and weight decay” arXiv preprint arXiv:1803.09820, 2018

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R.,“ Dropout: a simple way to prevent neural networks from overfitting”, The journal of machine learning research, Vol. 15, No. 1, 2014, pp. 1929-1958.

Sodhi, S. S., and Chandra, P., “Interval based weight initialization method for sigmoidal feedforward artificial neural networks”, Aasri Procedia, Vol. 6, 2014, pp. 19-25.

Sutskever, I., Vinyals, O., and Le, Q. V.. "Sequence to sequence learning with

neural networks", Advances in neural information processing systems, Vol. 27, 2014

Syntetos, A. A., Boylan, J. E. and Croston, J. D., "On the categorization of demand patterns", Journal of the Operational Research Society, Vol. 56, No. 3, 2005, pp. 495-503.

Willemain, T. R., Smart, C. N., and Schwarz, H. F., "A new approach to forecasting intermittent demand for service parts inventories", International Journal of forecasting, Vol. 20, No. 3, 2004, pp. 375-387.

Werbos, P. J., "Backpropagation through time: what it does and how to do it". Proceedings of the IEEE, Vol. 78, No. 10, 1990, pp.1550-1560.

Yang, L., and Shami, A., "On hyperparameter optimization of machine learning algorithms: Theory and practice. Neurocomputing", Vol. 415, 2020, pp. 295-316.

Zeiler, M. D., "Adadelta: an adaptive learning rate method", arXiv preprint arXiv:1212.5701, 2012.

Olah, C, "Understanding LSTM Network-colah's blog", https://colah.github.io/posts/2015-08-Understanding-LSTMs/,2015.