

반도체 소재-부품 기업의 인공지능경망(ANN)을 이용한 수요예측 비교연구

기태우

인하대학교 물류전문대학원

목차

- 1. 서론
 - 1.1. 연구 배경 및 목적
 - 1.2. 연구의 범위와 방법
- 2. 문헌연구
- 3. 수요예측 방법론
 - 3.1. 전통적 수요예측 이론
 - 3.2. 인공신경망과(ANN)
- 4. 연구 방법과 데이터
 - 4.1. 회사개요 및 특성
 - 4.2. A사의 수요예측 모델링
 - 4.3. ANN 인공신경망
- 5. 결 과
- 6. 결 론

1.1. 연구배경 및 목적

□ 연구배경

- 기업은 한정된 내부 자원의 효율적인 관리와 신속한 의사 결정 등을 통해 기업의 경쟁력 향상을 도모해야 한다. 이는 원부자재의 조달부터 최종 고객까지 전체적인 공급망 관리(Supply Chain Management, SCM)로 확장된다. 이를 위해 기업은 보다 정확한 수요계획을 통해 생산계획, 공급계획의 준비를 필요로 한다.
- Supply chain 의 끝단에 위치하여 소재나 부품을 공급하는 기업은 Supply Chain 내에서 채찍효과가 크게 작용하며 수요의 왜곡하는 현상이 심하다. 또한, 반도체는 이미 전기, 전자, 통신 및 자동차, 선박 등 많은 산업에 사용되는 부품으로 경기에 민감하게 반응하기 때문에 수요예측에 어려움이 있다.
- 기업의 자원과 자본의 한계로 수요예측의 정확도는 경쟁력 향상에 필수적이며 본 연구는 인공지능망(ANN)모델을 적용하여 기업에서 필요한 보다 향상된 수요예측 모델로 활용할 수 있는지를 확인한다.

1.1. 연구배경 및 목적

□ 연구목적

- 인공지능망(ANN)으로 기업의 판매 데이터로 예측하여 기존에 사용하는 전통적인 수요 모델과 비교하여 보다 높은 수요예측치를 제시할 수 있는지를 확인한다.
- 인공지능망(ANN)을 이용한 수요예측을 반도체 소재 산업군에 적용한 사례를 통해 향후 연구나 실제 판매 데이터를 사용한 사례의 연구에 도움을 준다.

1.2. 연구의 범위와 방법

- A사의 판매 데이터를 이용하여 인공신경망(ANN) 분석과 기존에 사용하고 있는 전통적인 시계열 모델링인 이동평균법 (moving average), 지수평활법 (exponential smoothing, Holt & Winters) 그리고 ARIMA 모델의 예측 데이터와 실제 판매 데이터를 비교하여 분석한다.
- 사용할 데이터는 5가지 제품의 월별 판매 수량으로 총 기간은 33개월이다.
- 관련한 예측, 분석 프로그램은 R을 사용하였다.
- MAPE(평균절대비율오차)를 각 모델의 예측 값과 실제 3개월 판매 데이터와 비교한다.

2. 문헌연구

- 시계열 예측과 분석은 지난 수십 년 동안 활발한 연구의 분야이다. 시계열 예측은 많은 의사 결정 과정의 시작의 기본이 되며 정확도는 중요하기 때문에 예측의 효율성을 개선하기 위한 연구는 계속되고 있다. 여러 전통적인 시계열 방법이 꾸준히 사용되고 발전되었으며 최근에는 인공지능망(ANN)을 수요 예측의 방법으로 사용하였다.
- 인공지능망(ANN)은 인지 과학, 컴퓨터 과학, 전기 공학 및 금융과 같은 다양한 분야에서 전통적인 통계 방법으로 쉽게 식별할 수 없는 데이터 패턴을 식별하고 모델링하는 기술로 발전되었다. Qi와 Maddala(1999)는 주식 수익의 예측 가능성을 입증하는 연구가 신경망에 의해 개선될 수 있다는 것을 보여주었고 또한 인공지능망(ANN)은 마케팅 (Krycha와 Wagner 1999) 및 소매업 (West et al. 1997)에도 사용되었다.
- Adamowski(2011)는 인공지능망(ANN)은 입력과 출력 데이터 세트 사이의 복잡한 비선형 관계를 해결할 수 있는 유연한 수학 알고리즘을 가진 데이터 기반 프로세스임을 강조하였고 지난 10년 동안 강우량, 하천유량, 지하수 및 강수량, 수질 문제와 같은 일정치 않은 과거 데이터를 기반으로 다변량 시계열의 수요를 예측하는 방법론으로 많이 사용되고 있다.

2. 문헌연구

- Jain과 Ormsbee(2002)는 하루 물 수요 예측을 회귀 분석과 인공신경망 모델로 예측하였고 전일과 당일의 일일 최대 온도를 바탕으로 한 예측에서 인공신경망 모델이 회귀 분석 모델보다 더 좋은 결과를 가진다고 결론 내렸으며 Adamowski (2008)은 캐나다 오타와에서 단기적으로 여름철 일일 최대 물 수요를 예측하는데 인공신경망을 사용하는 것이 다중 선형 회귀 분석보다 보다 나은 것으로 설명한다.
- Adamowski et al. (2012)은 다양한 부분에서 인공신경망(ANN)을 이용한 수요예측이 도입되고 있고 인공 신경망의 주요 장점 중 두가지는 인공신경망(ANN) 적용에 대해서 데이터 대한 사전 지식이 필요하지 않고 비선형 데이터에도 효과적이라는 것이다.
- Kumar et al.(2014)는 수요예측에 인공신경망(ANN)을 사용하여 소비자의 수요를 충족시키고 초과재고를 감소시킴으로써 수요와 공급의 균형을 이루고자 했다. 또한 수요 예측 모델에서 얻은 결과를 이용하여 신경망의 다양한 훈련 방법에 대한 비교 분석을 제시한다.

2. 문헌연구

- 인공신경망(ANN)을 사용하면 특정 모델 형식을 지정할 필요가 없고 오히려 인공신경망(ANN) 모델은 데이터로부터 제시된 특징을 기반으로 훈련되고 적용되어 데이터 출력 프레임이 형성된다. 이 데이터 중심 접근법은 적절한 데이터 생성 프로세스를 제안하는 이론적 지침이 없는 많은 경험적 데이터 세트에 적합하다.
- 본 연구는 제품의 단기 수요 예측을 위해 인공 신경망(ANN)을 활용한 연구로 반도체 소재-부품 회사인 A사의 제품의 수요예측을 위해 기존의 수요예측 방법인 단순이동평균법 (Simple Moving Average), 홀트& 윈터스 지수평활법 (Holt, Winter's Exponential Smoothing), ARIMA 모델과 인공신경망(ANN)의 방법을 시험하고 비교한다.

3.1. 전통적 수요예측 이론

- 이동평균법(Moving Average)은 과거 n 기간 실제 수요를 평균하여 미래의 수요치를 예측하는 기법이다.
- 지수평활법(Exponential Smoothing)은 이동평균법과 유사하나 가장 가까운 자료에 큰 가중치를 부여한다. 계절적인 패턴이나 추세를 갖는 데이터에 Winters와 Holt 모델이 사용될 수 있다.
- ARIMA (Autoregressive Integrated Moving Average) 는 데이터에서 복잡한 패턴을 식별하고 예측을 생성할 수 있는 능력을 가지고 있다.

3.2. ANN 인공신경망

□ 인공신경망(Artificial Neural Network)의 기본 구성

- 딥러닝은 인공신경망을 학습하는 방법으로 동물의 신경계 구조를 모사한 것이고 퍼셉트론과 엷지로 구성된다. 퍼셉트론은 신경 세포(Neuron)을 엷지는 신경세포를 연결하는 시냅스(Synapse)를 표현한 것이다.
- 퍼셉트론은 인공신경망의 정보를 전파하는 역할을 한다. 수학적으로 일종의 함수이고 함수 값이 다음의 퍼셉트론으로 전파된다. 사용되는 함수는 생물의 자극-역치의 관계이며 활성화 함수(Activation Function)라고 부른다. 활성화함수의 역할은 특정 퍼셉트론으로 들어오는 입력 값이 일정 수준의 역치(Threshold)를 넘어서면 일정 값을 전파하고 그렇지 않으면 어떠한 값도 전파하지 않는 것이다. 자극-역치는 계단 함수(Step Function)로 표현할 수 있고 정보가 전파되는 지점에서 미분이 불가능하므로 이것을 근사하여 활용하는 것이 일반적이다. 대표적인 활성화 함수로는 시그모이드(Sigmoid), 쌍곡 탄젠트(Tanh), 정류된 선형 유닛(Rectified Linear Unit)이 있다.
- 엷지는 퍼셉트론을 연결하는 값으로 엷지의 값은 두 퍼셉트론의 연관성이 높을수록 높은 값을 갖는다. 햄의 이론(Hebbian Theory) 라고 불린다. 엷지는 학습이라는 행위로 최적화되는 값인데 딥러닝에 활용되는 인공신경망은 수 백 만개에서 수 억 개에 이르는 엷지로 구성되기 때문에 최적의 엷지를 탐색한다는 것 즉 학습 과정은 매우 많은 계산을 요구한다.
- 퍼셉트론을 노드(Node)나 버텍스(Vertex)로 지칭하고 엷지는 링크(Link)로 표현하기도 한다. 엷지의 값은 두 퍼셉트론을 연결하는 강도를 나타내기 때문에 가중치(Weight)라고도 한다.

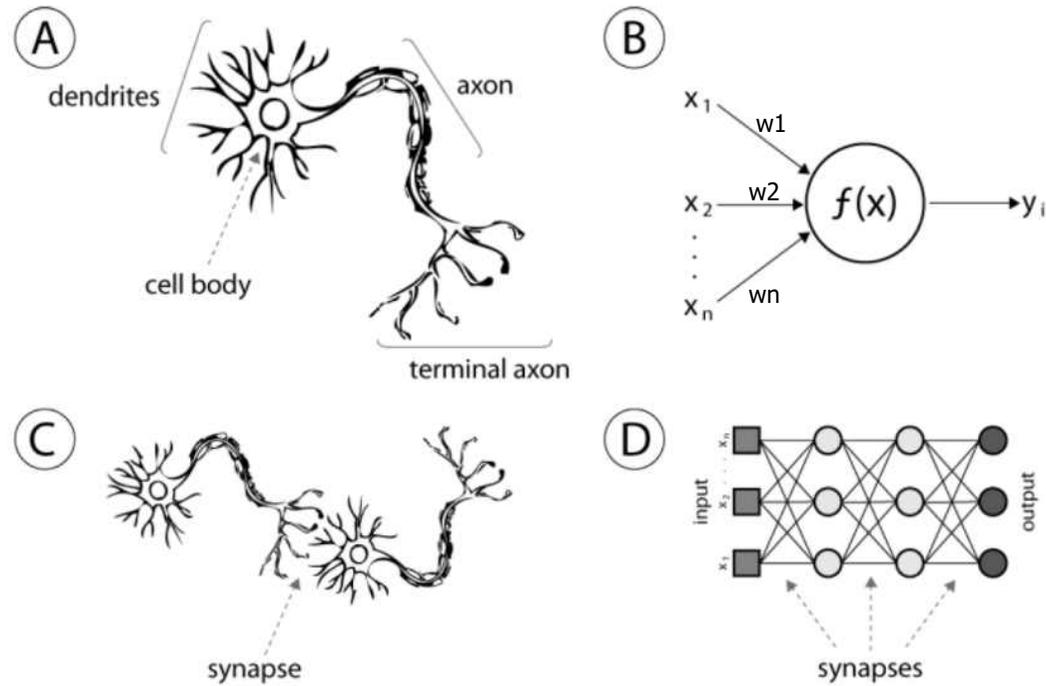
3.2. ANN 인공신경망

□ 인공신경망의 구조

- 기본적인 인공신경망인 다층 퍼셉트론은 세 개의 층으로 구성되는데 입력(Input), 은닉(Hidden), 출력(Output)층의 순서로 입력층은 인공신경망에 입력되는 데이터고, 은닉층은 엷지의 가중치에 따라 정보를 전파하고 출력층은 출력 값이 산출된다.
- 은닉층의 역할은 비선형분류기의 역할을 한다고 요약할 수 있으며 2015년 네이처에 “Deep Learning”이라고 명명된 논문에 게재되었으며 인공신경망의 연구가 딥러닝에 이르기까지의 전반적인 내용을 다루었다. 예를 들어 2차원 좌표를 표현되는 사각형의 영역을 특정 곡선이 A 영역과 B 영역으로 이등분했다고 가정하면 문제는 사각형 내의 측정 좌표가 A와 B 영역 중 어디에 속하는지 분류하는 것이다. 좌표 값과 A또는 B영역에 속하는 값을 입력과 출력으로 구성하여 다층 퍼셉트론을 학습시키는 경우 은닉층은 사각형의 영역을 재구성하여 영역을 구분하는 곡선을 직선으로 바꾸는 역할을 한다.

3.2. ANN 인공신경망

인공신경망의 도식화

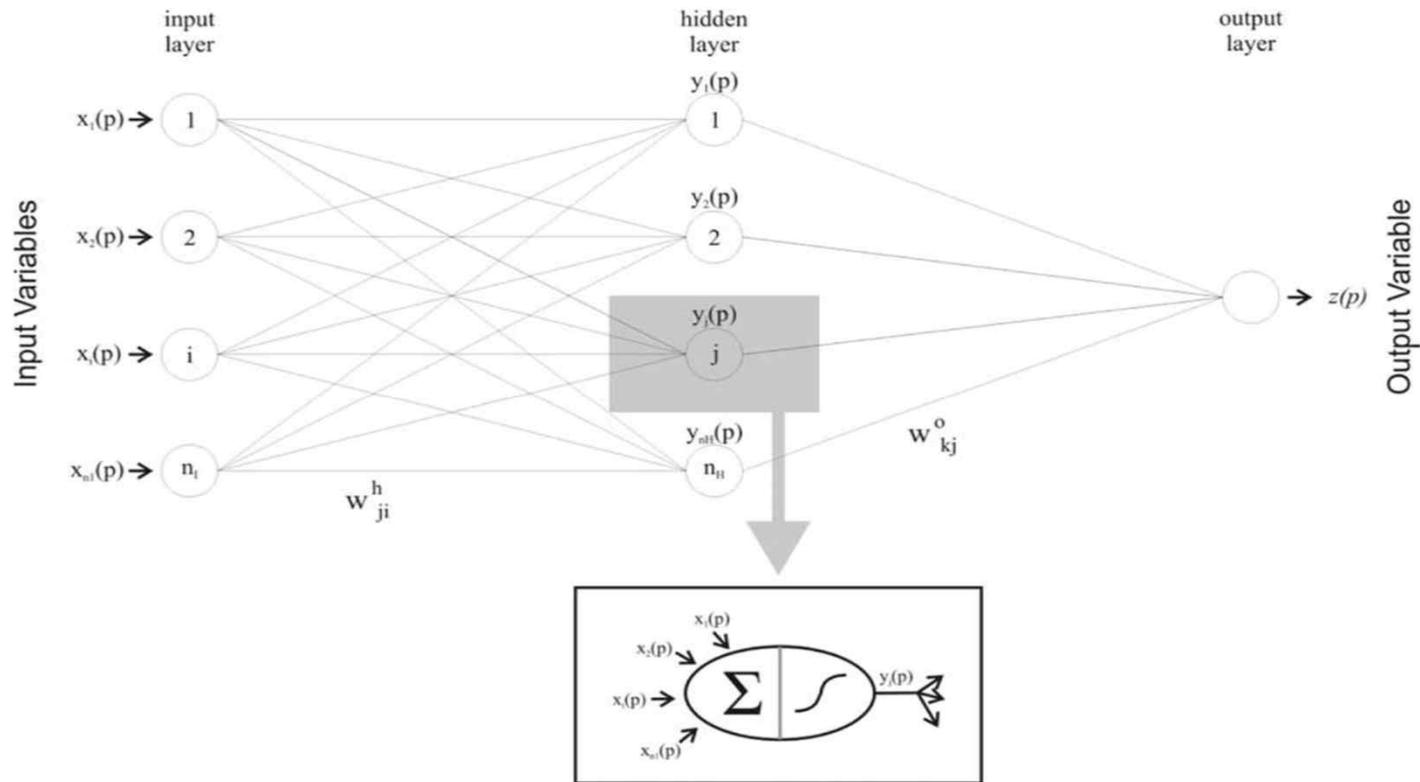


x_1, x_2, x_n : 퍼셉트론의 입력

w_1, w_2, w_n : 입력값과 퍼셉트론의 관계를 나타내는 가중치

y_i : 출력

3.2. ANN 인공신경망



ANN architecture with one hidden layer (Adamowski, 2007).

4.1. A 기업 개요 및 특성

- 반도체 및 하이테크 산업에 소재를 공급하는 글로벌 소재 공급업체이다.
 - 반도체 공정에 필요한 가스, 특수 케미컬, 가스 및 액체 정화필터 등 생산 판매
 - 다양한 제품 포트폴리오 가지고 소재 개발에 높은 투자를 하고 있다
- 미국, 캐나다, 중국, 프랑스, 독일, 이스라엘, 일본, 말레이시아, 싱가포르, 대만 그리고 한국에 제조시설과 고객 서비스 연구 시설 등의 인프라를 갖추고 있다.
- 연간 매출은 \$18억 달러 (약 2조원)
- 글로벌 전체 직원은 약 5,800명
- 한국의 직원은 약 330명으로 연구시설과 생산 시설 등이 있다.
- 한국 매출은 약 3000억원
- 주요 매출처는 반도체 제조업체이다.

4.1. A 기업 개요 및 특성

□ A사 기업 특성

- A사는 반도체 제조용 소재-부품을 반도체 제조회사에 납품을 하고 있는 소재-부품 기업으로 적극적인 M&A를 통해 사업 영역의 확장과 매출 증대를 위해 노력하고 있다.
- 판매하는 제품은 반도체 제조에 사용되는 부품과 소재 제품으로 채찍효과 (bullwhip effect)의 영향을 크게 받는 supply chain 의 거의 마지막 부근에 위치한 산업용 소재 제품이다.
- 반도체는 경기에 민감하며 급격한 주문의 변경이나 공장의 생산문제로 선주문이 많고 공장에서는 경기에 따라 변하는 주문량에 따라 효율적인 운영에 많은 어려움이 있다.

4.2. A사의 수요예측 모델링

- 수요예측 모델링을 통해서 영업과 마케팅 부서에 기본 수요예측 값을 제공
 - 예측 모델링은 SAP(ERP) 에서 3년간의 판매량 정보와 현 주문정보를 가지고 별도의 IT system에서 수요예측 수량이 계산된다. IT system 에서 제공되는 수요예측 모델링은 내장되어 있는 모델링 중 오차가 가장 낮은 Best fit model을 선택해서 제시한다.
 - 기존 예측 모델은 moving average, exponential smoothing, weighed moving average, holt-winters 모형 등이 사용되었다.
 - 한국 고객에게 판매되는 47개의 주요 제품의 평균 MAPE는 36.8% 예측 정확도는 63.2% 이다.

4.2. A사의 수요예측 모델링

- 기업의 모든 계획은 수요예측 데이터에서 시작되기 때문에 수요예측 데이터의 정확도가 중요하다.
- 기존 모델링에 의한 수요예측 향상에 대한 한계가 있기 때문에 개선을 위해서는 새로운 수요예측 방법론이 필요하다.

4.2. A사 수요예측 정확도 평가

□ Percent Accuracy = 1 - %Error

□ Forecast Error Metric

- MAPE (Mean Absolute Percentage Error, 평균절대비율오차)

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{d_i - f_i}{d_i} \right|}{n} 100\%$$

– d_i = actual value, f_i = forecasted value, n = # of observations

- WMAPE (Weighted Mean Absolute Percentage Error, 가중평균절대비율오차)

4.3. ANN 인공지능망

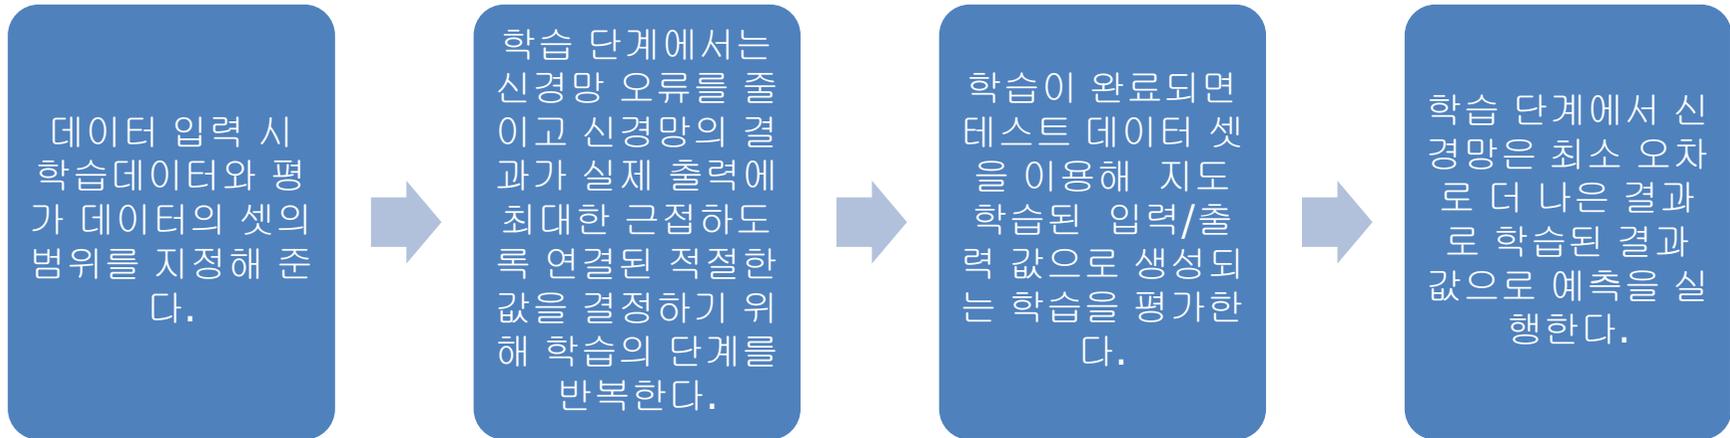
- ANN 과 기존 사용한 모델을 이용한 A 사 수요 예측
 - 인공지능망(ANN) 과 이동평균법(moving average), 지수평활법(exponential smoothing, Holt&Winters), ARIMA 모델 비교
 - 5가지 제품 선정, 33개월 판매 수량 data
 - 관측치 선정 후 실제 3개월 판매치 MAPE(평균절대비율오차)로 비교
 - 사용 프로그램 R

- ANN 모델 설정
 - INPUT NODES 6, HIDDEN NODES 6, OUTPUT NODES 3
 - ITERATION 은 30~ 120 사이로 변경하여 학습 후 가장 적은 오차의 data 사용

- Exponential smoothing
 - 데이터의 시계열에 종류에 따라 Simple, Holt and Winter's 등을 자동 선택

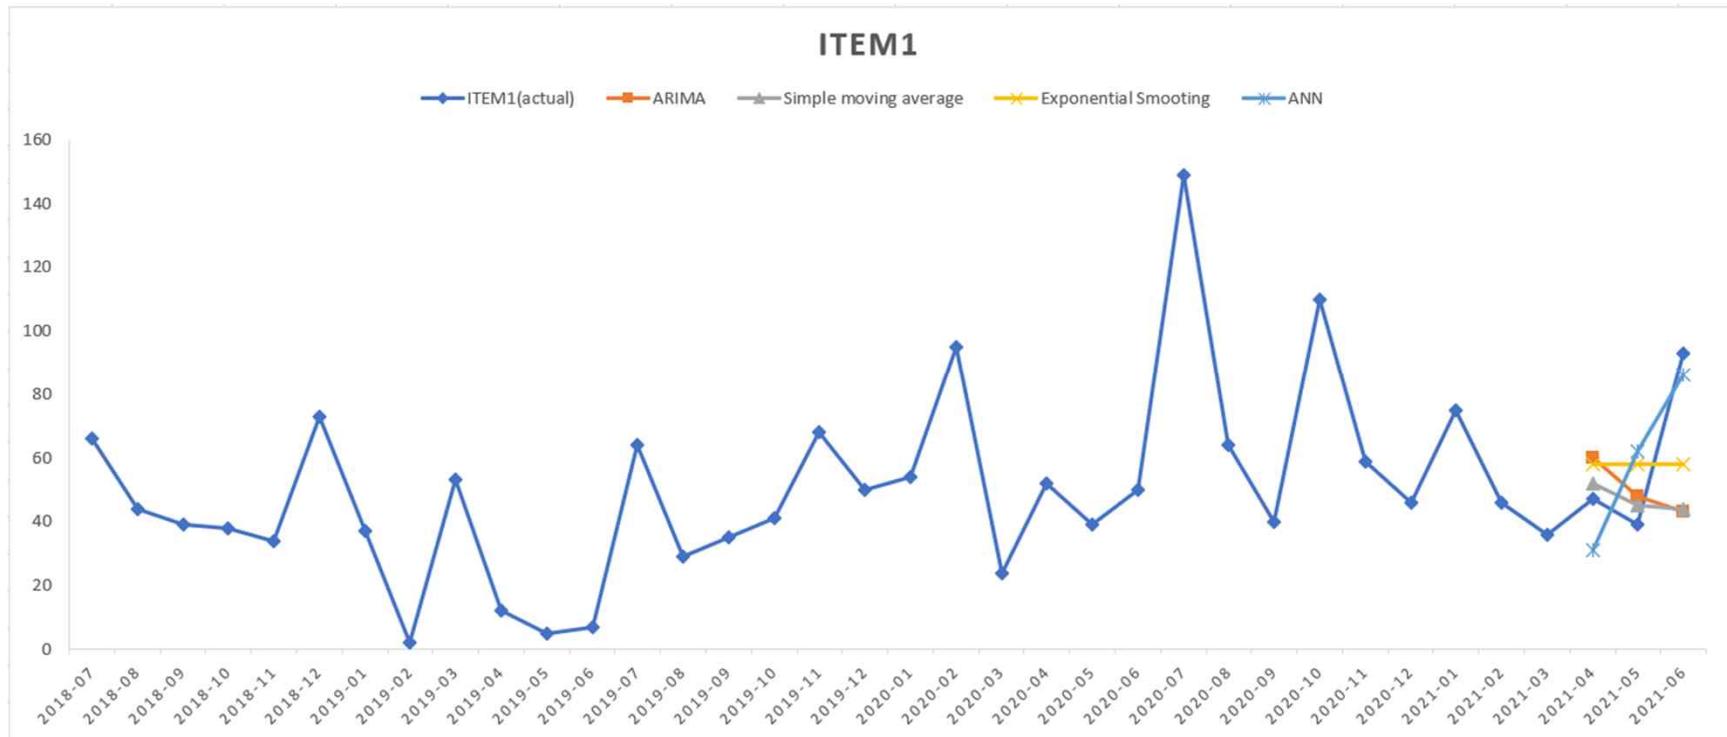
- ARIMA 모델 설정
 - Test에 따라 자동적으로 선택 ARIMA (2,1,0),(1,0,0),(0,0,1) 등 선택 후 결과 출력

4.3. ANN 인공신경망



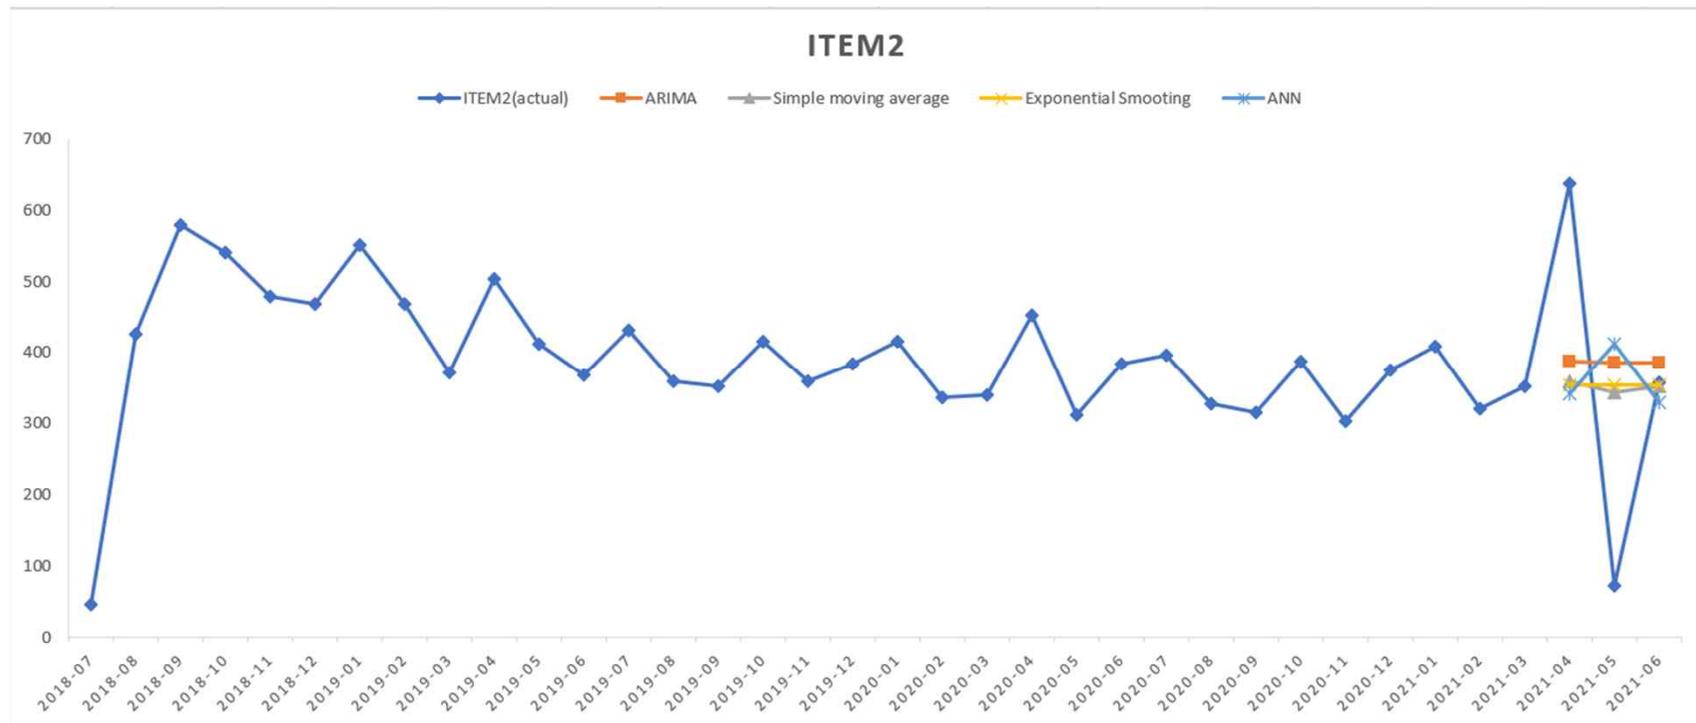
5. 결과

- Item1의 예측 오차는 ANN은 0%, Exponential Smoothing은 2.8%, ARIMA는 15.6%, Simple moving average는 21.2%로 ANN 모델의 정확도가 가장 높았다.



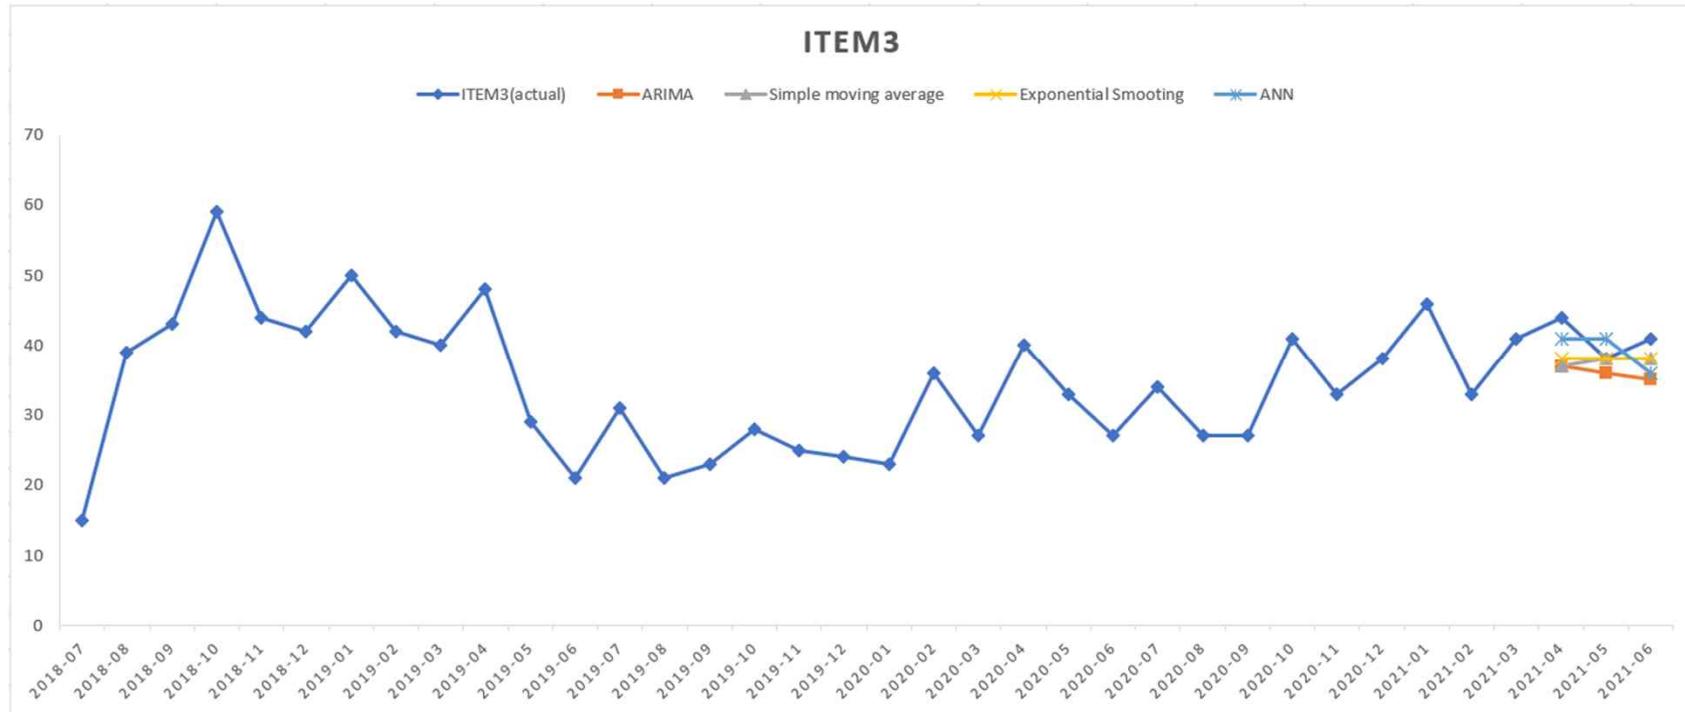
5. 결과

- Item2의 예측 오차는 Exponential Smoothing이 0.3%, Simple moving average가 1.1% ANN이 1.4% 그리고 ARIMA는 8.5%로 Exponential Smoothing이 가장 높은 정확도를 보인다.



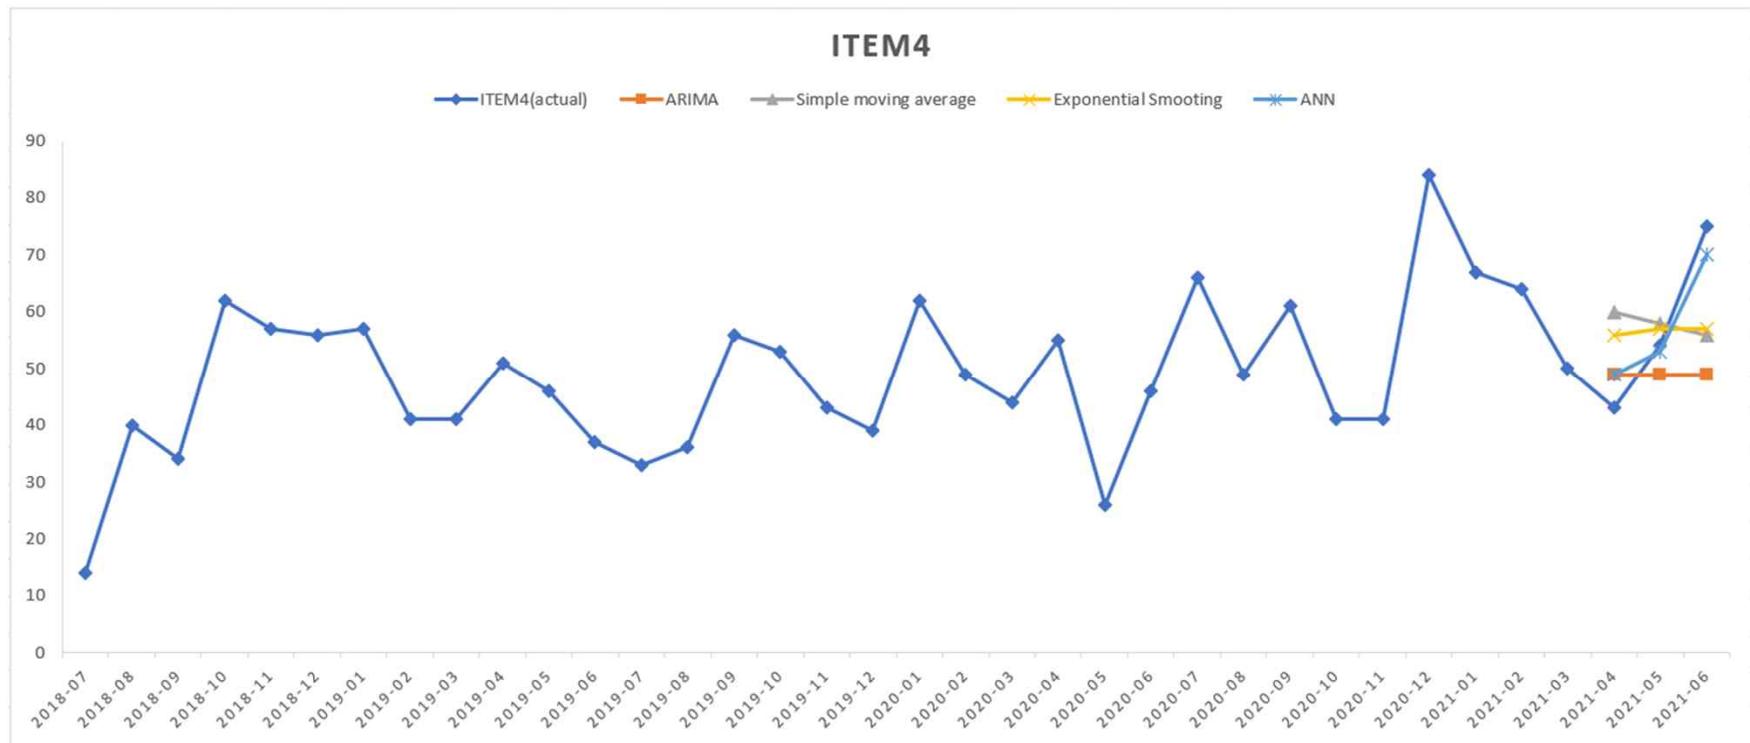
5. 결과

- Item3의 예측오차는 ANN은 4.1%, Exponential Smoothing은 7.3%, Simple Moving Average는 8.1%, ARIMA는 12.2%로 ANN이 가장 정확도가 높았다.



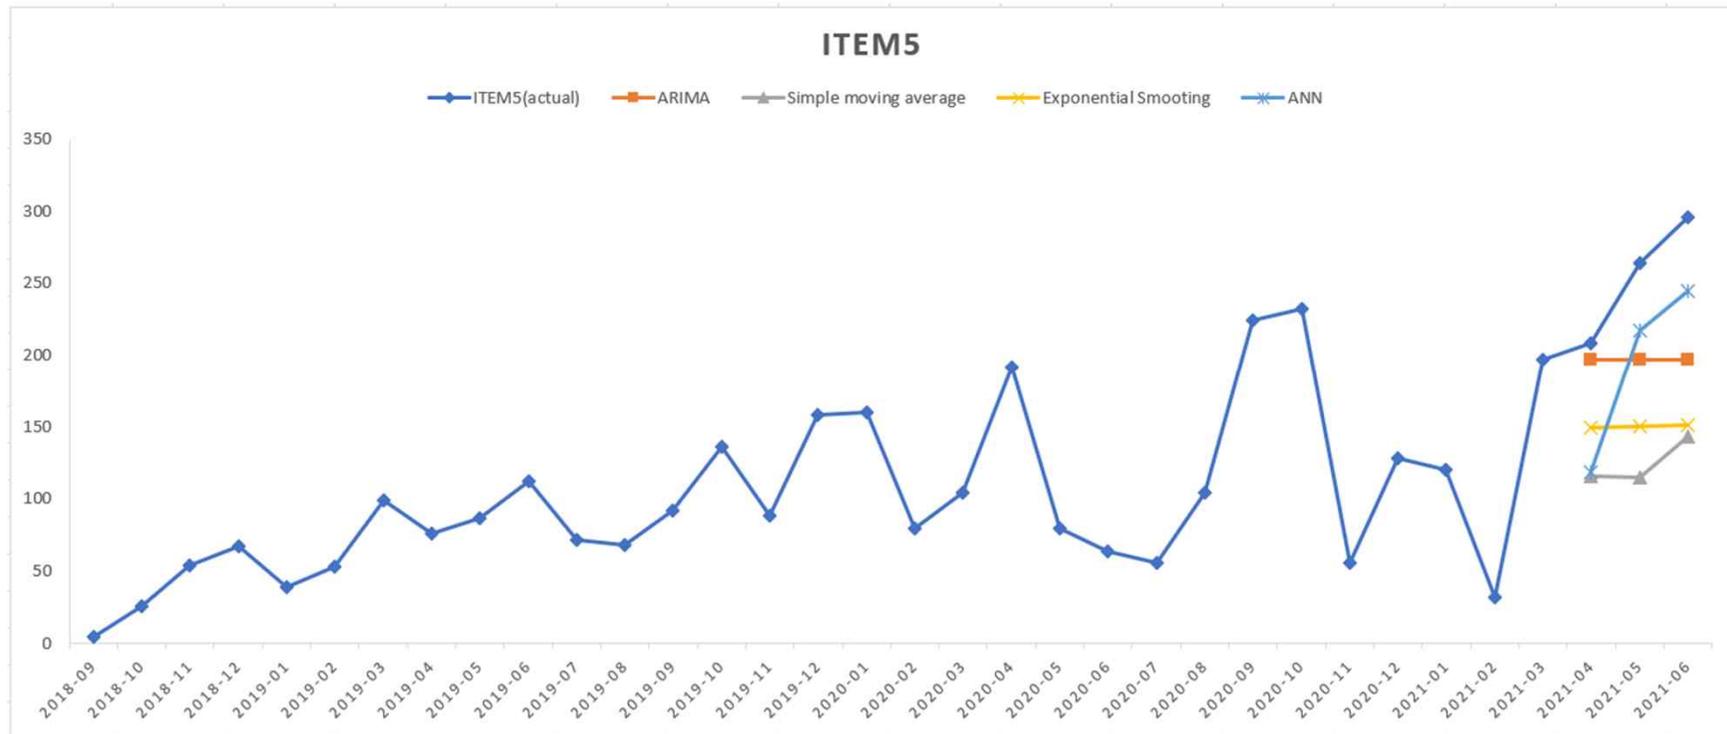
5. 결과

- Item4의 예측 오차는 ANN은 0%, Simple moving average 와 Exponential Smoothing은 1.2% 그리고 ARIMA는 14.5%로 ANN의 정확도가 높다.



5. 결과

- Item5의 예측 오차는 ARIMA는 23%, ANN은 24.5%, Exponential Smoothing 41.4% 그리고 Simple Moving Average는 51.3%로 전체적으로 에러가 높으나 그중 ARIMA가 가장 높은 정확도를 보인다.



5. 결과

□ 각 제품별 수요예측 모형별 예측 오차율

MAPE (%)	Simple moving average	Exponential Smoothing	ARIMA	ANN
ITEM1	21.2%	2.8%	15.6%	0.0%
ITEM2	1.1%	0.3%	8.5%	1.4%
ITEM3	8.1%	7.3%	12.2%	4.1%
ITEM4	1.2%	1.2%	14.5%	0.0%
ITEM5	51.3%	41.4%	23.0%	24.5%

□ 평균 수요예측 오차율

MAPE (%)	Simple moving average	Exponential Smoothing	ARIMA	ANN
Average MAPE	16.6%	10.6%	14.8%	6.0%

6. 결론

- 본 연구에서 반도체 소재-부품 기업에서 제공된 실제 데이터를 사용하여 인공신경망(ANN)을 이용한 수요 예측을 다른 시계열 모델의 예측 값과 함께 비교하여 실험하였다. 결과는 인공신경망(ANN)이 실험에서 전반적으로 가장 낮은 예측오차(MAPE)를 예측하였다.
- 연구는 다섯가지 제품을 선정하여 인공신경망(ANN) 모델과 단순이동평균법 (Simple Moving Average), 홀트-윈터스 지수평활법 (Holt-Winters Exponential Smoothing), ARIMA (자동회귀누적 이동평균법, Autoregressive Integrated Moving Average) 모델을 사용하였다. 데이터는 36개월 월별 판매량으로 33개월 데이터로 예측 후 3개월 실제 판매 데이터로 평가하는 단기 예측을 실시하였다. 실험한 시계열 데이터 중 월별 변동성에 대한 차이가 큰 품목에 대한 예측 어려가 다른 품목보다 높게 나왔으며 다섯가지 품목의 예측 정확도가 가장 높은 모델은 인공신경망(ANN) 이었다. 인공신경망(ANN)이 테스트된 다른 모델보다 더 정확한 예측 결과를 제공한다고 판단된다.
- 시계열 예측에서 데이터의 변동성이 크지 않은 경우는 지수평활법 (Exponential Smoothing)이나 단순 이동평균법 (Simple Moving Average)도 높은 예측 결과를 가져왔다. 반도체 공정 후 세정에 사용하는 케미컬 제품들은 지속적인 수요가 있고 수요의 변동성이 크지 않기 때문이다. 판매의 변동성이 큰 데이터의 경우는 전체적으로 낮은 예측 정확도를 보였고 ARIMA나 ANN의 예측 정확도가 비교적 높았다. 수요의 변동성이 높은 제품의 경우 반도체 공정에서 한번에 교체되는 특수 가스 와 필터류로 반도체 공정의 정비 기간에 교체가 이루어지는 제품이다. 반도체 공정 라인이 정지할 때 교체되는 특징이 있으며 생산라인 정지 후 공정 프로세스 비용이 상당하기 때문에 문제가 없으면 공정을 계속 진행하고 기회가 있을 때 교체되는 특징이 있다. 실제 시계열 데이터의 경우 변동 폭이 큰 제품의 예측이 어렵기 때문에 판매 비중이 높고 변동성이 큰 제품 위주로 데이터의 유형에 따라 인공신경망(ANN)과 함께 기존의 시계열 방법론과 비교하여 적절한 모델링을 사용하는 것이 정확도를 높이는 방법일 것이다.

감사합니다!