

데이터 분석 기법을 활용한 서비스 부품의 저장 위치 선정 방안 수립 연구

Research on Location Selection Method Development for Storing Service
Parts using Data Analytics

손진호¹ · 신광섭^{2*}

(주) 미소정보기술¹, 인천대학교 동북아물류대학원²

요 약

서비스 부품은 일반적인 완성품에 비해 종류의 다양성, 수요의 불명확성, 빠른 대응에 대한 높은 요구 등과 같이 체계적 관리의 어려움을 유발하는 속성을 가지고 있다. 특히, 서비스 부품의 입고 주기는 길지만 출고 주기는 상대적으로 낮은 편이어서, 서비스 부품 저장 창고의 경우 전체 작업 중 오더 피킹이 가장 중요한 작업으로 인식되고 있다. 그러나 출고 수요에 대한 주기, 빈도, 출고량은 부품이 가지는 고유한 특징에 따라 달라지기 때문에 일관된 보관위치 결정 기준을 활용할 경우 물류 센터 내 작업 효율성을 높이는 데 한계가 존재할 수밖에 없다. 본 연구에서는 서비스 부품이 가지는 다양한 특성 데이터를 바탕으로 부품의 유형을 구분하고, 각 유형별 수요예측 모형을 개발하여 입출고를 위한 저장과 오더 피킹의 전체 거리를 최소화하기 위한 방안을 제시하였다. 이를 통해 서비스 부품의 입출고 수량을 변화시키지 않은 상태에서도 물류 센터 내 작업 효율성과 함께 공간 활용의 효율성도 동시에 향상시킬 수 있을 것으로 예상된다.

■ 중심어 : 서비스 부품, 오더 피킹, 수요예측, 보관위치, 과학기술

Abstract

Service part has the attribute causing a difficulty of the systematic management like a kind of diversity, uncertainty of demand, high request for quick response against general complete product. Especially, order picking is recognized as the most important work in the warehouse of the parts since inbound cycle of the service part long but outbound cycle is relatively short. But, increasing work efficiency in the warehouse has a limitation that cycle, frequency and quantity for the outbound request depend on the inherent features of the part. Through this research, not only are the types of the parts classified with the various and specified data but also the method is presented that it minimizes (that) the whole distances of the order picking and store location about both inbound and outbound by developing the model of the demand prediction. Based on this study, I expect that all of the work efficiency and the space utilization will be improved without a change of the inbound and outbound quantity in the warehouse.

■ Keyword : Service Parts, Order Picking, Forecasting Storage Location

I. 서론

항공, 교통, 전자 등의 산업들이 발전하면서 서비스 부품의 중요성이 더욱 부각되고 있다. 특히, 운영 중인 장비의 고장이 발생하여 즉각적으로 부품의 교체 또는 수리가 이루어지지 않을 경우, 비용뿐 아니라 고객에 대한 서비스 만족도에 큰 영향을 미치게 되어 해당 기업 또는 기관은 상당한 비용을 지불해야만 한다. 따라서 많은 기업과 기관들은 서비스 부품의 공급에 탁월한 서비스를 원하고 있다.

Morris[16]의 분석한 보고서에 따르면 14개 회사의 서비스 수익은 판매량의 30%에 해당되며, 서비스 부품의 재고는 제품 판매의 8.75%의 가치를 가질 수 있다고 한다. US Bancorp에 따르면 서비스 부품으로 인한 비용이 연간 7천억 달러가 지출되고 있으며, 이는 미국 내수 총생산의 8%임을 감안할 때 매우 높은 수준의 재고 투자율이라 할 수 있다. 현재는 서비스 부품에 대한 중요성이 부각되어 많은 연구가 활발히 진행되고 있다[12]. 서비스 부품은 품목의 다양성, 수요의 불투명성, 빠른 대응에 대한 높은 요구 등과 같이 체계적 관리의 어려움을 유발하는 속성을 가지고 있다. 이러한 서비스 부품의 특성으로 다음과 같이 세 가지로 요약될 수 있다[13].

- 다양성: 완성품의 경우 단일 제품 혹은 SKU 단위에서의 수요와 공급의 계획 및 관리가 이루어지는 것이 일반적이다. 그러나 서비스 부품의 경우 이미 생산 및 판매가 이루어진 완성품에 대한 유지보수를 위한 목적으로 관리되며, 하나의 완성품은 다양한 하위 부품으로 구성되고 반대로 하나의 서비스 부품이 여러 종류의 완성품의 구성요소로 설계되기도 한다. 따라서 완성품에 비해 서비스 부품은 그 종류뿐만 아니라 활용 대상에서 다양성을 가진다.
- 산발성: 서비스 부품이 가진 다양성으로 인

해 높은 주문 빈도를 가지는 부품이 존재하는 반면 빈도가 매우 낮거나 장기간에 걸쳐 간헐적인 수요가 산발적으로 발생하는 패턴을 가진다.

- 상호연관성: 설비 또는 장비의 판매와 연관하여 많은 수요가 발생하는 서비스 부품이 있는 반면 낮은 상관관계를 가지나 운영상의 치명적 영향을 주는 서비스 보장성 부품의 수요가 발생하는 패턴을 가진다.

서비스 부품은 완성품 한 단위를 기준으로 적게는 10개 미만에서부터 많게는 수천 개의 부품이 소요되어 구성되어 있다. 이러한 다량의 서비스 부품은 대부분 완성품의 고장 혹은 정기적인 교체로부터 발생하기 때문에 수요의 편차가 크고, 입고 주기가 길어지게 된다. 사실상 불특정 수요에 대한 수요예측이 상당히 힘들고 불가능한 경우도 존재한다. 따라서 서비스 부품의 출고 수요에 대한 주기, 빈도, 출고량은 서비스 부품이 가지는 고유한 특징에 따라 달라지기 때문에 일관된 보관위치 결정 기준을 활용할 경우 물류 센터 내 작업 효율성을 높이는 데 한계가 존재할 수밖에 없다.

본 연구에서는 서비스 부품이 가지는 다양한 특성 데이터를 바탕으로 부품의 유형을 구분하고, 각 유형별 수요예측 모형을 개발하여 물류 센터 내 작업효율성을 입출고를 위한 저장과 오더 피킹의 전체 거리를 기준으로 측정하고 이를 최소화하기 위한 방안을 제시하고자 한다.

II. 이론적 배경 및 관련 연구

2.1 수요예측 관련 연구

수요예측(demand forecasting)은 제품이나 상품, 서비스 등에 대한 미래의 수요를 예측하는 것이다. 수요예측은 기업에 있어서 중요한 예측이며 경영계획의 기초가 된다. 수요예측치를 바

탕으로 판매, 생산, 인력, 자재, 재무계획 등이 연속적으로 형성된다. 수요예측에 있어서 공통적인 특징은 아래와 같다.

- 예측은 과거 추이 또는 인과관계가 지속되는 것으로 미래의 수요에 대하여 가정한다. 예를 들면, 이동평균법이나 지수평활법은 과거의 추이를 예측범위의 미래에도 지속된다고 가정하며 회귀분석은 과거의 추이가 함수관계로 적용되는 것을 전제 한다.
- 완벽한 예측은 없다. 예측에는 언제나 예측 오차가 있으며, 사용자는 주어진 예측의 불확실성(예측오차)을 검토하고 이를 적절하게 대비 및 대응 하여야 한다.
- 어떠한 예측기법도 불규칙변동(random variation)을 정확하게 판단하거나 예측할 수 없다. 불규칙변동의 경우 많은 통제 불가능한 원인에 의하여 발생하며 이러한 원인의 영향이 클수록 예측의 정확도가 떨어진다.
- 예측의 대상기간이 길수록 정확도는 낮아진다. 단기예측보다 중장기예측의 신뢰성이 더 떨어진단다[5].

2.2 시계열자료의 분해

시계열 자료의 실제 수요는 변동요인, 추세순환, 계절, 우연의 내가지로 분리할 수 있다. 이러한 변동 중 일부분 규칙성을 가지고 설명 가능한 요인을 ‘체계적 변동’이라고 하며 그렇지 않은 나머지 변동들을 ‘불규칙변동’이라고 한다.

- 추세요인: 장기적이며 점진적인 변동을 추세를 한다. 인구, 소득, 물가 등 수시로 작은 폭의 변동을 나타내지만 장기적으로는 꾸준한 상승, 하강 또는 수평화의 추이를 나타낸다.
- 순환요인(cyclical component): 1년 이상의 주기로 수요의 파장의 곡선을 그리며 이를

순환변동이라 한다. 순환변환의 대표적인 예는 경기변동이다. 경기변동은 사회, 정치, 경제적인 환경요인의 변동에 의해 발생하는데 주기와 진폭이 일정치 않아 예측이 어렵다. 따라서 현 시점이 순환 사이클의 어떠한 국면(상승 국면, 하강 국면)에 위치하는가를 판단하고 그 결과를 기준으로 예측치를 적당히 상향 또는 하향 조정하여야 한다.

- 계절요인(seasonal component): 일반적으로 1년을 기준 주기로 반복되는 수요의 변동을 계절변동이라 한다. 계절변동은 관습, 기후, 전통 등의 자연적인 또는 제도적인 요인에 의하여 발생한다. 계절변동은 순환변동에 대비하여 규칙적이며 예측하기에는 훨씬 용이하다.
- 우연요인: 일반적으로 불규칙 요인(irregular component)이라고도 한다. 다수의 불규칙적이며 우발적인 요인이 작용하기 때문에 계절, 추세, 순환의 세 가지 요인을 정확히 파악하여 예측하더라도 얼마간의 예측오차가 발생할 수 있다[5].

시계열 분해법으로 예측하는 경우 시계열데이터를 4가지로 구성요인으로 분리시켜 각각의 영향을 검토한다. 수요 변동요인 중 어떠한 규칙성을 가지고 설명이 가능한 체계적인 변동은 수요예측에 반영 된다. 또한 수요예측이 갖추어야 하는 이러한 특성을 적응성(adaptability)이라고 한다. 반대로 설명할 수 없는 불규칙변동은 수요예측에 반영되어서는 안 되기 때문에 이러한 특성을 안정성(stability)이라고 한다. 보통 적응성을 향상시키려면 낮아지고 안정성이 낮아지고 안정성을 향상시키려면 적응성이 낮아지기 때문에 시계열 예측 기법에서는 양자 간의 합리적 균형을 모색하는 것이 필요하다. 시계열(time series)은 경영자료, 경제자료, 교통량, 대기오염자료, 지진파등 많은 종류의 시계열이 존

재하여 시계열 분석은 사용/응용 범위가 넓은 통계적 분석 기법이다. 시계열 분석의 목적은 시계열의 확률적 체계를 이해하여 모형화 하는 부분과 과거의 수치를 사용하여 예상된 시계열 모형으로 예측하는 데 의의가 있으며, 이를 기초로 미래를 위한 정책 결정 또는 수립의 기초 정보로 제공하고자 하는 것이다. 시계열은 정해진 시간의 흐름에 따라 관찰되며 자료들 사이에 관련성을 가지기 때문에 확률적 체계가 변하는 특징이 있다. 시계열의 특성에 따라 시계열 모형과 분석 방법들은 이미 많은 연구가 개발되어 있는 상황이다[2].

이러한 시계열 분해법을 기초로 서비스 부품에 대한 수요예측은 수십 년 동안 연구 되어왔다. 서비스 부품 SKU의 간헐적 수요 패턴과 평활한 수요 패턴 사이의 차이를 고려한 모델이 많은 연구가들에 의해 연구되었으나, 그 중 Croston[10]은 수요의 크기와 요구되는 시간에 간헐적 수요를 포함한 모델을 제안하였다.

최근 연구는 또한 Croston's method 또는 Syntetos & Boylan Approximation중 더 나은 패턴으로 예측을 수행하는 수요 패턴의 식별에 초점을 맞추고 있으며, 현실적인 수요 패턴을 얻기 위해서 부트스트랩 방법도 예측에 사용 되었다. 이러한 특정 방법에는 이동평균법이나 단순지수평활법과 같은 예측 방법들이 쉽게 이해하고 적용 가능하다는 사실에 많이 사용된다[8].

2.3 군집분석

서비스 부품은 완성품에 비하여 수요의 편차가 크고 간헐적인 수요가 산발적으로 발생하는 패턴을 가진다. 이러한 특성의 서비스 부품은 군집을 분류 하지 않을 경우 무수히 많은 개별 부품의 수요에 대해 재고를 유지하고 저장 위치를 결정하는데 상당히 많은 비용과 시간이 필요하다. 따라서 유사한 패턴을 가진 서비스 부품의 수요 군집 분석은 수요예측 및 저장 위치 결

정에 적용할 수 있다.

2.3.1 군집의 수 결정

최적의 군집 수를 결정하기 위한 연구 역시 상당히 많은 연구가들에 의해 수행 되었다.

Milligan and Cooper[15]는 군집의 수를 결정하기 위해 몬테카를로 시뮬레이션을 통해 기존 연구에서 제안된 30개의 기준에 대해 효과성을 분석하고 다양한 분야에서 적용할 수 있는 새로운 기준들을 제안하였다. 그 중 Caliński and Harabasz[9]의 방법은 가장 효과적인 연구라 할 수 있다. 432회의 시뮬레이션에서 390회(90.2%)의 올바른 군집의 수를 증명했다. Duda and Hart[11]의 방법은 432회의 시뮬레이션에서 388회(89.8%)의 올바른 군집의 수를 찾았다. 두 가지 방법은 정확도에 있어서 거의 차이가 없는 수준이라 Caliński and Harabasz[9] 및 Duda and Hart(1973)의 방법이 군집의 수를 결정하기 위해 활용할 수 있는 객관적 기준으로 사용할 수 있다는 결론을 얻을 수 있다[15]. Calinski and Harabasz[9]는 다음의 기준을 제안하였다.

$$Pseudo f = \frac{tr(B)/(k-1)}{tr(W)/(n-k)} \quad (1)$$

식 (1)을 보면 B는 군집 간 제곱합 및 교차곱 행렬이며, W는 군집 내 제곱합 및 교차곱 행렬이다. $tr()$ 는 trace로 행렬의 대각선의 합을 나타낸다. k는 군집의 수이며, n은 변수의 수이다. B와 W의 대각선 부분은 제곱합만으로 구성되므로, k개의 군집이 있을 때 군집 내의 제곱합을 SSW_k , 군집 간 제곱합을 SSB_k , 전체 제곱합을 SST로 나타내면 다음과 같이 표현할 수 있다.

$$Pseudo F = \frac{SSB_k/(k-1)}{SSW_k/(n-k)} \quad (2) \\ = \frac{(SST - SSW_k)/(k-1)}{SSW_k/(n-k)}$$

군집의 수 k 를 2에서부터 증가시키면서 변화를 비교하여 가장 큰 값이 나올 때 군집의 수를 채택하게 된다[9].

2.3.2 군집의 분류

군집 분류의 경우 특히 대용량 데이터에서는 각각의 객체를 요약하는 것보다는 전체를 유사한 객체들의 군집(cluster)으로 구분한다. 복잡한 구조를 대표할 수 있는 군집들을 관찰함으로써 전체 데이터에서 의미 있는 정보를 얻어낼 수 있는 장점이 있다.

이러한 군집분석에는 K-means 알고리즘이 많이 사용되는데, K-means 알고리즘은 군집화 문제를 해결하는데 가장 간단한 자율학습 알고리즘 중 하나이며 사전에 정해진 임의의 클러스터 개수를 통해 주어진 데이터 집합을 분류할 수 있는 방법이다. Data 이외에 클러스터의 수 k 를 사전에 지정하면, k 개수만큼 seed points가 설정되고 임의로 선택된 seed point는 클러스터의 중심으로 사용된다. 각각의 개별 데이터 항목들은 어떤 seed point와 가장 근접한 지를 판단하여 가장 유사한 seed point로 대표되는 클러스터에 할당된다. K-means algorithm과 Forgy' algorithm의 차이점은 하나의 샘플이 하나의 클러스터에 할당 되자마자 클러스터의 centroid가 다시 계산된다는 것이다. 또한 Forgy' algorithm이 반복적인 반면에 k-means algorithm은 데이터 셋에서 단지 두 번만의 pass가 이루어진다. 그 과정은 다음과 같다.

단계 1: 처음에는 k 개의 클러스터로서 시작한다. 남아있는 k 의 샘플들에 대해서는 가장 밀접한 센트로이드를 찾는다. 이것과 가장 밀접한 센트로이드를 가지는 것을 확인 후 클러스터에 샘플을 포함시킨다. 각 샘플들이 할당된 후에 클러스터의 센트로이드가 다시 계산된다.

단계 2: 각각의 샘플에 대하여 가장 밀접한 센트로이드를 찾는다. 가장 밀접해 있는 센트로이드를 가진 것으로 확인되면 클러스터에 샘플을 위치시킨다[14].

MacQueen[14]이 제안한 k-means 군집분석은 다양한 환경에서 분석을 통해 결과를 빠르게 도출할 수 있다. 만약 객체들 사이의 거리를 수치로 표현해 낼 수 있다면, 거의 모든 형태의 데이터에 적용이 가능한 간단한 구조를 가진다. 또한 변수들에 대한 역할 정의 없이 적용 가능하고 사전 정보 없이도 데이터에 대하여 의미 있는 구조를 얻을 수 있는 장점이 있다.

하지만 초기에 평균값에 대한 의존도가 상당히 높아 임의로 추출된 객체간 인접해 있는 경우에는 클러스터링의 정확도가 떨어지며 여러 가지 자료유형을 포함하는 데이터에서는 객체 사이의 거리 정의와 가중치 결정의 어려움이 있다. 또한 초기 군집수의 적합성에 따라 클러스터링의 성능이 결정되어 최적의 결과를 보장할 수 없다는 것이 단점이다[1].

2.4 물류센터 내 재고의 배치

물류센터에 계획된 제품 또는 상품이 입고될 경우 먼저 검수준비가 진행된다. 검수가 완료된 제품 또는 상품은 적재공간으로 이동하게 되며, 이후 분류작업을 통하여 적재 또는 출고를 결정하게 된다. 물류센터의 기능은 입고, 보관, 가공/포장 및 출고로 나눌 수 있다. 이 중 재고의 배치는 입고처리 후 제품을 보관할 위치를 결정하는 것으로 위치 결정 기준에 따라 임의 위치 저장방법, 근접 위치 우선(Closed Open Location), 지정 위치(Dedicated) 및 출고 빈도수 우선(Full Turnover Storage) 지정 방식으로 구분할 수 있다.

2.4.1 임의위치 저장방법 (Random Storage)

일반적인 보관물류센터에 제품이 입고되는

순서부터 보관을 하는 순서로서 저장 공간이 지정되어 있지 않다. 일반 평지 창고의 대량생산인 경우는 임의 위치저장방법으로 운영되기도 하지만 현재는 그렇지 않다. 임의 위치 저장 방법은 입고 프로세스 시간이 단축되지만 출고 프로세스 시간이 증가하기도 한다. 제품별로 지정된 보관위치가 없고, 제품 입고 시 무작위로 적재 가능한 위치에 할당하는 방식이다[3].

2.4.2 Closed Open Location Storage

출고장 혹은 특정 위치를 기준으로 가장 가까운 곳에 위치한 저장 가능한 위치부터 순차적으로 보관하는 방법이다[3].

2.4.3 Dedicated Storage

SKU(Stock Keeping Unit)별로 사전에 보관 위치를 지정하고, 제품 입고 시 해당 SKU의 위치에 저장하는 방식으로 오더피킹 시 제품 위치 파악이 쉽고, 재고 유지 및 관리가 쉬우나 공간 효율성이 가장 낮다는 단점을 가지고 있다[3-4]. 만약 해당 위치의 적재공간에 저장 불가능한 경우, 지정된 저장 공간에서 가장 가까운 위치에 저장한다[4].

2.4.4 입출고 빈도수 저장방식(Full Turnover Storage)

제품의 저장기간에 따라 저장 공간을 구별하여 보관하는 것을 원칙으로 하는 방법으로, 제품의 저장회전율이 빠른 제품부터 입고장에서 가까운 곳이나 출고장에서 가까운 공간에 저장하는 방법이다. 동일한 위치에 저장할 제품들에 대해 각각의 고유한 위치를 정하고 그 장소에만 저장하는 방법으로, 입출고 빈도수가 큰 제품을 입구에서 가장 가까운 곳에 할당한다[4].

2.4.5 등급별 저장 방식(Class Based Storage)

임의 저장방식과 지정위치 저장방식을 혼합

한 방식으로 입출고 빈도수에 따라 우선 제품들을 재분류 한다[6]. 계절별 제품의 수요에 따라 출고량이 다르게 발생하는 특정 시점에 수요와 출고량이 급격히 증가함으로 인해 발생하는 공간 측면의 문제를 해소하기 위하여 등급별 저장방식을 많이 적용한다. 입고와 출고 빈도수 저장방식과 유사하다고 할 수 있지만 제품의 재분류 여부에 따라 구분된다.

2.4.6 Family Group Storage

관련성이 높은 제품들을 그룹화 하여 같은 제품들을 인접한 위치에 보관하는 방식이다[4]. 여러 품목의 부품들을 제품단위별로 군집을 하고 부품을 보관하는 경우가 많다. 그러나 작업자의 출고품 분류 시 동일 부품의 보관에 의하여 불출 오류가 발생하는 문제점이 있다.

2.5 기존 연구와의 차별성

이미 많은 수요예측에 대한 연구, 제품의 ABC 등급의 분류에 대한 연구, 물류센터 내 재고 재배치에 관한 많은 연구가 진행되었다. 하지만 제품의 수요예측 또는 서비스 부품의 시계열 현상을 가지고 예측하거나 매출 금액과 재고의 수량을 기준으로 하는 ABC 등급 분류, 물류센터의 오더피킹의 거리 또는 시간을 단축하는 데 집중하고 있다.

본 연구는 서비스 부품의 시계열 데이터를 기반으로 패턴을 분석 후 수요의 평균과 편차를 기준으로 유사성이 있는 부품의 군집 분류를 위한 k-means 클러스터링을 진행한다. 기존의 ABC등급이 제품이나 상품에 보편적으로 사용할 수 있는 시계열 기준의 매출 금액과 품목의 수량과 무게로 결정 되었다면 본 연구에서는 서비스 부품이 가지는 특성인 다양한 편차와 수요의 평균으로 군집의 수를 최적화 하여 결정하며 고정 등급을 사용하는 ABC 분석 대비 계절성 및 상대적 대응력을 높은 수요 패턴의 유사

성을 기준으로 분류하는 부분이 기존의 연구와 차별화 되는 부분이기도 하다. 이 후 유사한 수요패턴의 분류된 군집의 최적의 수요예측을 위한 MAPE를 측정하여 군집의 수요예측 방법을 제시한다. 이는 서비스 부품의 특성상 미래의 변화되는 수요의 특성을 대비하기 위하여 단기 수요예측을 적용한 부분이다.

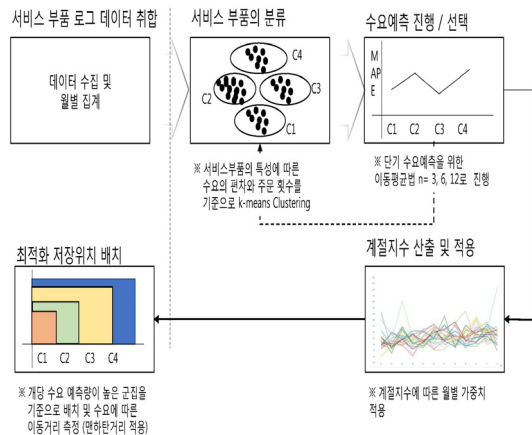
물류센터의 배치를 통한 물류 센터 내 작업 및 공간 활용의 효율성 향상시키기 위해 관련연구를 기반으로 한 이동 거리 단축을 목적으로 데이터 분석기반으로 수학적 모델을 구성하여 특정 시점의 데이터를 추정하는 방법인 시계열 예측 기법을 사용하기로 한다. 일반적인 시계열 분석과 서비스 부품에 대한 수요예측에 대한 방법은 많은 연구가 있다. 이를 기반으로 단기 수요예측인 이동평균법을 이용하여 데이터 분석 후 시계열의 가중치를 더한 수요의 패턴과 조합하여 최적의 위치를 구하는 것이 본 연구의 핵심이기도 하다.

기업 또는 기관의 서비스 부품을 관리하는 조직은 분야/기능별로 세분화관리 되어 오고 있다. 물론 소조직의 경우 단일 프로세스로 서비스 부품의 특성에 따른 수요예측, 저장위치에 대한 배치를 진행 할 것이다. 하지만 기존연구에서는 기능 단위별로 세부적인 군집에 대한 분류를 하지 못하였으며 출고 또는 입고의 이력으로 저장 위치를 배치하여 왔다.

본 연구에서는 서비스 부품이 가지는 다양한 특성의 데이터를 바탕으로 부품의 유형을 구분하고, 각 유형별 수요예측 모형을 개발하여 입출고를 위한 저장과 오더 피킹의 전체 거리를 최소화하기 위한 방안을 연구한다. 이를 통하여 서비스 부품의 입출고 수량을 변화시키지 않은 상태에서 서비스 부품의 특성을 고려한 군집 분류와 군집의 수요예측이 물류 센터 내 작업 효율성과 함께 공간 활용의 효율성도 동시에 향상 시키는 것을 목적으로 한다.

III. 클러스터링 기반의 재고 위치 결정 모형

본 연구에서는 시계열 데이터의 수요패턴을 분석하기 위해 k-means 클러스터링을 통한 그룹화, 개별 수요 품목에 대한 수요예측방법 분류 및 수요의 계절지수 산출 후 물류센터 내 제품의 배치 위치를 조정함으로써 집하를 위한 이동거리를 최소화할 수 있다. 아래 <그림 1>은 본 연구에서 제안하는 클러스터링 기반의 수요예측 및 재고 위치 결정을 위한 과정을 보여주고 있다.



<그림 1> 연구수행 절차

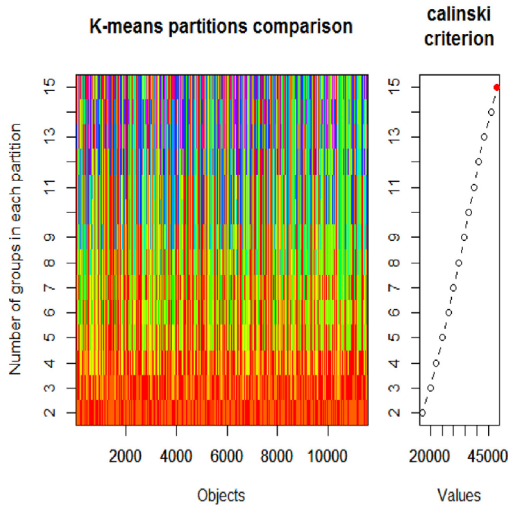
3.1 서비스 부품의 군집 분석

수요패턴의 분류는 서비스 부품의 수요 패턴을 관찰함으로써 데이터에 대한 의미 있는 군집을 분류할 수 있다. 각 품목의 시계열 데이터와 수요에 대한 각각의 패턴을 분석하면 서비스 부품의 수요에 대한 높은 편차와 수요 횟수가 발생하며 이러한 서비스 부품의 특성이 있는 편차의 높은 값에 의한 영향을 최소화하기 위한 수식 (3)을 활용하여 정규화한다.

$$Z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (3)$$

$Z_i = 0$ 에서 1의 정규화
 $x =$ 객체 속성
 $i =$ 해당 객체 index

서비스 부품의 특성상 많은 편차와 다양한 제품군을 보유하게 된다. 또한 단기 수요예측을 적용하기 위하여 일정 범위의 군집까지 고려해야하기 때문에 군집의 수를 결정하기 위하여 Calinski and Harabasz[9]의 기준을 사용하여 아래 식 (4)와 같이 *Pseudo-F*를 기반으로 평가한다.



<그림 2> 최적 군집의 수 결정 과정 예시

$$Pseudo\ f = \frac{tr(B) / (k-1)}{tr(W) / (n-k)} \quad (4)$$

B : 군집간의 제곱합(sum of squares) 및 교차곱(cross product) 행렬

W : 군집내 제곱합 및 교차곱 행렬

$tr()$: 행렬의 대각선 부분의 합


k : 군집의 수

n : 변수의 수

군집의 수를 2개에서부터 증가시키면서 수치 변화의 변화를 비교하여 가장 값이 클 때의 군집의 수를 채택하게 된다. 위 <그림 2>에서 보여주는

예시에서는 최적 군집의 수가 15로 결정되었다. k-Means 알고리즘을 이용한 클러스터링의 결과는 다음 <그림 3>과 같이 표현될 수 있다. 군집 분석 결과의 적합성을 판단하기 위해 TSS(Total sum of squares)를 사용한다.

군집분석의 결과인 각 클러스터는 크게 fast mover와 slow mover로 정의하여 관리할 수 있다. fast mover의 경우 서비스 레벨을 위하여 안전재고의 산출 시 일정 가중치를 더하여 관리할 수 있으며 slow mover의 경우 안전 재고의 레벨을 낮추어 관리 할 수 있다.



<그림 3> k-means 클러스터링 결과

3.2 군집별 수요예측 모델

이 군집을 통한 각 서비스 부품 특성상 단기 수요예측을 위하여 이동평균법(Moving Average)의 3, 6, 12개월을 사용한다. 최종적으로 예측한 데이터의 평균절대오차(MAE: Mean Absolute Error)와 평균 절대값 퍼센트 오차(MAPE: Mean Absolute Percent Error)를 바탕으로 성능평가 후 우수한 모형을 선택한다.

본 연구에서는 $n = 3, 6, 12$ 로 지정하여 단기수요예측 모델을 시뮬레이션하며 최종적으로 예측한 데이터의 평균절대오차(MAE: Mean Absolute Error)와 평균 절대 오차율(MAPE: Mean Absolute Percentage Error)을 측정한다. 평균절대오차는 실제값과 예측값 차이에 대한 절대값의 총합을 예측기간 수로 나눈 것을 뜻한다.

$$MAE = \frac{1}{K} \sum_{t=1}^k |Y_t - F_t| \quad (5)$$

$$MAPE = \frac{1}{k} \sum_{t=1}^k \left| \frac{Y_t - F_t}{Y_t} \right| \quad (6)$$

3.3 최적 저장위치 결정과 비교기준

본 연구에서 제안하는 서비스 부품의 재고 위치는 군집 분석 후 군집별 수요예측을 통해 결정된다. 기존의 입출고 기준의 서비스 부품 저장 위치 결정 결과와의 정량적 비교를 위해 총 이동거리를 측정한다. 물류센터의 경우 부품이 저장되어 있는 위치로의 이동은 직선거리가 아닌 맨하탄 거리를 이용하는 것이 타당하다. 물류센터 내 일반적인 장애물이 많이 존재하기 때문에 오퍼레이터(작업자)의 실제 이동거리에 가까운 척도가 필요하다.

$$d = |x_1 - x_2| + |y_1 - y_2| \quad (7)$$

IV. 사례 연구

4.1 사례의 개요

본 연구에서 제안하는 기법에 대한 실제 적용 가능성과 효과성을 검증하기 위해 A기업을 대상으로 분석한다. 현재 A기업은 북미, 유럽 및 한국에 서비스 부품의 물류센터를 보유하고 글로벌 서비스를 제공하고 있다. 2약 1년간 한국으로 접수된 수요 58만 건의 데이터를 대상으로 분석하였다.

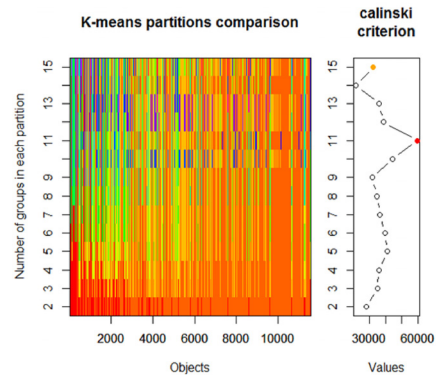
물류센터의 경우 무작위 적재 방식을 적용하고 있어, 입고장 주변에 주로 고회전 서비스 부품이 적재되어 왔다. 입고장과 출고장과 거리가 멀기 때문에 출고 작업자의 인원이 과도하게 투입되고, 긴 이동거리로 작업시간이 불필요하게 길어진 상황이다. 또한 그간의 다양한 프로젝트를 통해 물류센터 내 재고 배치를 최적화하기

위해 노력하였으나 무작위 적재 방식을 변경하지 못해 상시 재고가 혼재되어 있으며 재고의 정확도 또한 상당히 떨어져 있는 상태이다.


4.2 서비스 부품의 분류

A기업의 서비스 부품은 수요의 편차가 매우 크며 다량의 별크품목에 의한 출고 수량의 판단은 적용할 수 없다. 따라서 연구방법에서 제시한 수요의 편차와 횡수를 기초로 군집의 수를 결정하고 군집 분류를 위한 k-means 클러스터링을 진행하기로 한다.

정규화된 수요 횡수, 편차의 데이터로 대상은 11,554품목으로 <그림 4>와 같이 최적 군집의 개수는 11로 확인되었으며, 이를 기반으로 클러스터링한 결과는 <그림 5>와 같다. 또한 <표 1>과 같이 TSS의 값이 93.0%로 적합성을 보이고 있다.



<그림 4> k-means 클러스터링 결과



<그림 5> k-means 클러스터링 결과

<표 1> k-means 클러스터링 TSS 값(사례연구)

Within cluster sum of squares by cluster(between_SS / total_SS = 93.0 %)

Cluster	1	2	3	4	5	6	7	8	9	10	11
SS	0.27	0.13	0.39	0.40	0.56	0.85	0.18	0.37	0.35	0.48	0.37

4.3 군집별 수요예측

군집의 설정 후 각 군집에 대한 수요예측을 이동평균을 통해 수행하였다. 해당 수요예측 결과에 따라 수요예측 방법을 통한 검증을 진행하며 데이터 분석을 기반으로 물류센터의 배치 시 수요에 대한 배치를 진행한다.

<표 2> 군집의 수요현황

군집	품목수 (SKU)	점유율 (%)	수요	점유율 (%)
1	772	6.7	19,769	11.0
2	382	3.3	15,451	8.6
3	8,059	69.8	80,302	44.8
4	160	1.4	9,666	5.4
5	1,739	15.1	28,552	15.9
6	62	0.5	5,384	3.0
7	26	0.2	1,862	1.0
8	7	0.1	372	0.2
9	36	0.3	4,103	2.3
10	207	1.8	7,170	4.0
11	104	0.9	6,630	3.7
계	11,554	100.0	179,261	100.0

<표 3> 수요예측 결과 및 성능 평가(MAPE)

군집	이동평균법 (n = 3)	이동평균법 (n = 6)	이동평균법 (n = 12)
1	5.6%	7.0%	8.6%
2	13.0%	14.2%	11.9%
3	31.4%	28.2%	24.3%
4	17.9%	16.1%	11.0%
5	27.3%	23.7%	16.1%
6	16.6%	14.6%	16.5%
7	26.8%	23.9%	19.6%
8	42.1%	43.5%	36.5%
9	21.6%	20.2%	17.8%
10	21.2%	22.5%	20.7%
11	15.6%	12.7%	10.5%

<표 2>는 1년간의 수요에 대한 전반적인 군집별로 분석한 결과를 보여주고 있으며, 해당 군집에 대한 수요예측 결과를 MAPE 기준으로 평가한 결과는 <표 3>과 같다. 그 결과로 개별 군집별 수요예측을 위한 기준을 군집 1은 n = 3, 군집 6은 n = 6으로 그 외의 경우 이동평균법 n = 12와 같이 설정할 수 있다.

이러한 군집별로 분류되는 수요예측 방법을 선택할 경우 서비스 부품의 특성상 대량의 부품에 대한 소량 또는 간헐적인 수요에 효율적인 예측 및 재고 관리에 목적을 두고 있다. 이후 각 군집의 월별 기준의 3개년 계절 지수를 산출하여 매월 또는 분기의 예측 시 반영되게 가중치를 부여하여 수요예측치에 반영하였다.


4.4 최적의 위치 결정 및 성능평가

4.4.1 최적의 보관 위치 결정

최적의 위치를 결정하기 위한 기준으로는 기존의 운영방식인 무작위 적재, 입고장 우선배치, 데이터기반의 최적화 위치를 적용하였다. 이후

<표 4> 배치 순위 결정

군집	배치순위	품목 수	수요예측량	품목당 예측량
1	9	772	1,297	14
2	6	382	1,094	27
3	11	6,353	1,559	1
4	4	160	761	42
5	10	1,738	1,396	5
6	2	62	402	101
7	5	26	148	42
8	7	7	22	20
9	1	36	329	143
10	8	207	466	18
11	3	104	527	55



〈그림 6〉 우선순위 기준 재고 저장 위치 기준

상품의 출고를 위한 이동거리를 기준으로 각 기준의 성능을 평가하였다.

수요예측된 총 9,847개의 서비스 품목을 각 영역 당 11개의 품목을 저장할 수 있다고 가정하였으며 900개 영역을 I형 배치로 진행하였다. 수요예측 후 수요량을 기준으로 각 군집의 분포를 진행하였다. 그 배치는 <표 4>와 같이 품목당 예측 평균량이 많은 군집을 출고위치가 가장 가까운 곳으로 <그림 6>과 같이 배치하였다.

4.4.2 최적의 위치 검증

랜덤방식과 서비스 부품의 수요예측 데이터 기반을 이용한 적재 방식의 이동거리는 배치 후 각각 맨하탄 거리 방식으로 측정하였다. 최적화 배치는 이동평균법으로 산출된 수요예측치를 기준으로 배치 순서 및 셀을 결정하였다. 배치 시의 셀은 900개로 설정하였으며 배치 순서가 결정된 군집과 군집의 품목을 각 셀당 11품목이 저장된다는 가정하고 배치를 진행하였다. 수요예측치가 높은 품목에 대한 군집과 아이템 순으로 배치를 하였다. 통계적 검증을 위하여 각각 군집의 수요에 맞게 수요 횟수를 난수생성 후 적용하여 1주 단위별 작업자의 왕복 이동 거리를 측정하였다. 한 번의 이동으로 하나의 품목

을 피킹하는 것으로 가정하였다. 총 30회의 시뮬레이션을 수행하였다.

시뮬레이션은 <표 5>와 같이 각 군집의 기존 수요를 기초로 군집별 난수를 적용하여 최적화 배치, 랜덤배치, 입고장 주변의 배치를 측정 후 이동거리의 합계를 구하였다. 각각의 세트는 30번 진행되어 t-검정을 위한 합계를 <표 6>과 같이 도출하였다. <표 6>의 데이터를 기준으로 <표 7>과 같이 t-검정을 하였다.

〈표 5〉 시뮬레이션 구성현황

군집	1 SET		
	최적	랜덤	입고
1	161,480	445,928	717,523
2	74,329	343,931	593,801,
3	2,357,465	1,793,279	1,261,617
4	31,460	184,047	346,385
5	286,843	489,628	695,803
6	16,560	182,020	314,663
7	5,075	28,245	50,270
8	1,001	2,875	6,951
9	9,949	132,783	270,317
10	32,270	112,909	206,201
11	19,877	146,761	256,411
계	2,997,309	3,862,405	4,719,942

〈표 6〉 배치 후 이동거리 측정

군집	평균			최적화 개선	
	최적	랜덤	입고	랜덤	입고
1	160,986	439,970	722,459	63.4%	77.7%
2	74,197	336,158	580,884	77.9%	87.2%
3	2,366,483	1,807,523	1,261,176	-30.9%	-87.6%
4	31,148	182,553	335,534	82.9%	90.7%
5	291,680	486,249	700,069	40.0%	58.3%
6	16,477	174,462	306,112	90.6%	94.6%
7	5,309	28,868	54,871	81.6%	90.3%
8	1,016	3,164	7,222	67.9%	85.9%
9	9,540	138,816	258,767	93.1%	96.3%
10	32,976	114,961	203,789	71.3%	83.8%
11	19,813	144,395	277,915	86.3%	92.9%
합계	3,009,626	3,857,118	4,708,800	22.0%	36.1%

t-검정 쌍대 비교를 보면 유의수준 0.05보다 P 값이 모두 다 작음으로 최적화 배치는 랜덤저장 방식과 입고장 배치 방식보다 유의하다는 귀무가설이 채택이 되었다. 최적화 배치와 비교를 위한 무작위 저장방식과 입고장 배치 방식의 시뮬레이션 값에 대한 평균을 비교한 측정값은 <표 6>과 같이 정리하였다. 서비스 부품의 특성상 높은 편차가 발생하는 경우는 다양한 품목과 적재 셀에

발생된다. 하지만 본 연구에서는 높은 수요의 품목을 미리 수요예측 데이터 기반에 최적의 위치에 배치를 한다면 랜덤방식에 비하여 22% 정도, 입고장 배치에 비하면 36.1%를 단축시킬 수 있을 것이다. 수요가 크고 저장 위치를 많이 확보한 군집의 경우 더 효율적 이었으며 편차가 심한 군집 3번의 경우는 저회전 또는 수요가 미비하게 발생하는 군집으로 랜덤저장방식과 입고장 배치 방식에 비하여 수요예측 데이터 기반의 저장 배치의 효율성이 크지 않은 것으로 판단되었다.

V. 결론

본 연구는 대부분의 산업 서비스 부품은 각각의 비즈니스 특성도 있으나 서비스 부품이 가지는 다양한 특성은 공통적인 것이다. 이러한 특성을 가진 데이터를 바탕으로 서비스 부품의 유형을 구분하고, 각 유형별 수요예측 모형을 개발하여 입출고를 위한 저장과 오더 피킹의 전체 거리를 최소화하기 위한 방안을 제시하였다. 이를 통해 서비스 부품의 입출고 수량을 변화시키지 않은 상태에서도 물류 센터 내 작업 효율성과

〈표 7〉 시뮬레이션의 통계 검정 결과

t-검정 : 쌍체비교			t-검정 : 쌍체비교			t-검정 : 쌍체비교			t-검정 : 쌍체비교		
	랜덤	최적		랜덤	최적		랜덤	최적		랜덤	최적
평균	3857118.32	3009626.38	평균	3009626.387	3857118	평균	4708799.57	300962.38	평균	3009626.38	4708800
분산	580843053	205985095	분산	205985095.7	5.81E+08	분산	938221512.8	205985095	분산	205985095	9.38E+08
관측수	30	30	관측수	30	30	관측수	30	30	관측수	30	30
피어슨 상관계수	0.2813411		피어슨 상관계수	0.2813411		피어슨 상관계수	-0.03010634		피어슨 상관계수	-0.0301634	
가설 평균차	0		가설 평균차	0		가설 평균차	0		가설 평균차	0	
자유도	29		자유도	29		자유도	29		자유도	29	
t 통계량	190.74923		t 통계량	-190.74923		t 통계량	272.006793		t 통계량	-272.006793	
P(T<=t) 단측검정	0.0000		P(T<=t) 단측검정	0.000		P(T<=t) 단측검정	0.0000		P(T<=t) 단측검정	0.0000	
t 기각치 양측검정	1.6991		t 기각치 양측검정	1.699		t 기각치 양측검정	1.6991		t 기각치 양측검정	1.6991	
P(T<=t) 양측검정	0.0000		P(T<=t) 양측검정	0.000		P(T<=t) 양측검정	0.0000		P(T<=t) 양측검정	0.0000	
t 기각치 양측검정	2.0452		t 기각치 양측검정	2.045		t 기각치 양측검정	2.0452		t 기각치 양측검정	2.0452	

함께 공간 활용의 효율성도 동시에 향상 시킬 수 있을 것으로 예상된다.

본 연구의 한계점은 넓은 연구범위와 특정 산업군에 대한 사례 연구를 제시한 것과 단기 수요예측을 위한 축소된 수요예측 방법을 제시한 점이다. 향후 다양한 산업군의 서비스 부품에 적용하여 효율성을 검증하는 절차가 필요하다. 추후 연구방향은 다음과 같다. 서비스 부품의 유형별 패턴 분석에 대하여 효율적인 분석을 진행 및 향상시키는 연구와 여러 산업군의 다양한 서비스 부품의 특성을 고려할 수 있는 예외사항이 적용된 최적화 모델링이 필요하다.

참 고 문 헌

- [1] 김정연, “강화된 k-평균 군집분석에서 초기치 선정의 복잡도 개선”, 제주대학교 대학원석사 학위논문, 2012.
- [2] 김재석, “관광여가 산업의 자산구조가 경영성과에 미치는 영향”, 관광학연구, 제30권, 제3호, pp.293-310, 2006.
- [3] 김창욱, 김성식, 배경환, “자동창고의 적체현상에 관한 연구”, 경영과학, 제7권, 제1호, pp.138-154, 1990.
- [4] 김창환, “Lean Six Sigma 기반의 물류센터 물류 프로세스 개선 방법론”, 인천대학교 대학원 석사학위논문, 2008.
- [5] 이강수, “자동차 보수용 부품의 수요패턴을 고려한 예측모형 선정 방법론 연구”, 고려대학교 공학대학원, 2007.
- [6] 이형규, “창고내 저장위치 결정을 위한 데이터 마이닝 응용”, 한양대학교 대학원 석사학위 논문, 2008.
- [7] 조진행, 오세조, “물류관리: 이론과 설계”, 서울, 두남, 2008.
- [8] Bacchetti, A. and N. Saccani, “Spare parts classification and demand forecasting for stock control: Investigating the gap between research and practice”, *OMEGA*, Vol.40, No.6, pp.722-737, 2012.
- [9] Caliński, T. and J. Harabasz, “A dendrite method for cluster analysis”, *Taylor & Francis*, Vol.3, No.1, pp.1-27, 1974.
- [10] Croston, J., “Forecasting and stock control for intermittent demands”, *Operation Research Quarterly*, pp.289-303, 1972.
- [11] Duda, R. and P. Hart, “Pattern classification and scene analysis”, Wiley New York, 1973.
- [12] Eaves, A. and B. Kingsman, “Forecasting for the ordering and stock-holding of consumable spare parts”, *Journal of the Operational Research Society*, Vol.55, No.4, pp.431-437, 2004.
- [13] Lengu, D. and A. Syntetos, and M. Z. Babaic, “Spare parts management: Linking distributional assumptions to demand classification”, *Elsevier*, Vol.235, No.3, pp.624-635, 2014.
- [14] Macqueen, J., “Some methods for classification and analysis of multivariate observations”, University of California Press, 1967.
- [15] Milligan, G. and M. Cooper, “An examination of procedures for determining the number of clusters in a data set”, *Psychometrika*, Vol.50, No.2, pp.159-179, 1985.
- [16] Morris, A., Y. Cohen, and V. Agrawal, “Service parts logistics: a benchmark analysis”, *Taylor & Francis*, Vol.29, No.8, pp.627-639, 1997.

저 자 소 개



손 진 호(Jin-Ho Son)

- 2014년 : 인천대학교 동북아물류대학원 (석사)
- 현재 : (주)미소정보기술 근무
- 관심분야 : 빅데이터, 데이터 마이닝, 딥러닝, AI



신 광 섭(KwangSup Shin)

- 2003년 : 서울대학교 산업공학과 (공학사)
- 2006년 : 서울대학교 산업공학과 (공학석사)
- 2012년 : 서울대학교 산업공학과 (공학박사)
- 2012년~현재 : 인천대학교 동북아물류대학원 교수
- 관심분야 : 빅데이터, 물류 및 SCM, 위험 관리