

# Multi Objective Vehicle and Drone Routing Problem with Time Window

Tae Joon Park\*, Yerim Chung\*

## Abstract

In this paper, we study the multi-objectives vehicle and drone routing problem with time windows, MOVDRPTW for short, which is defined in an urban delivery network. We consider the dual modal delivery system consisting of drones and vehicles. Drones are used as a complement to the vehicle and operate in a point to point manner between the depot and the customer. Customers make various requests. They prefer to receive delivery services within the predetermined time range and some customers require fast delivery. The purpose of this paper is to investigate the effectiveness of the delivery strategy of using drones and vehicles together with a multi-objective measures. As experiment datasets, we use the instances generated based on actual courier delivery data. We propose a hybrid multi-objective evolutionary algorithm for solving MOVDRPTW. Our results confirm that the vehicle-drone mixed strategy has 30% cost advantage over vehicle only strategy.

▶ Keyword: Drone, Multi-Objective Vehicle Routing Problem, Hybrid-Meta-Heuristics, Evolutionary Algorithm, Distribution Network

## 1. Introduction

최근 드론에 관한 관심이 높아지면서 배송 네트워크에 드론의 운용을 고려한 몇몇 연구가 소개된 바 있는데, 차량과 드론의 협업을 고려하거나 드론과 차량을 병렬적으로 사용하는 외판원(Traveling Salesman Problem) 계열의 문제들이 다수를 차지하고 있다 [1-4]. 드론 배송과 관련된 선행연구들에서는 배송차량과 드론을 일대일로 매칭시켜 운영하는 방법을 살펴보았다[1][2]. 해당 선행 연구들에서는 배송차량이 드론을 운용하기 위한 플랫폼 역할을 하였기 때문에 배송차량과 드론의 운행을 동기화(Synchronization)하는 것이 중요한 요소였다. 선행연구들에서 문제를 해결하는 접근에 있어서는 드론을 이용해 배송하는 문제가 기존의 외판원 문제(TSP)의 변형이라고 접근하고, 풀이법을 외판원 문제의 풀이에 사용된 바 있는 2 단계 풀이법(Two-phase algorithm)이나 [1], 선클러스터후프로시저(Cluster first-route second)와 같은 방식 [2][3][4]을 사용하였다. 또 선행연구들에서

는 운행종료시간의 최소화[1-2], 이윤의 최대화[3], 비용의 최소화[4]를 문제에서 달성하고자 하는 목적으로 정의하였다.

국내에서는 차량일정계획(Vehicle Routing Problem: VRP) 계열의 문제에 드론을 결합한 연구는 [5]의 연구가 있다. 이 연구에서는 단목적 다거점 드론 차량 일정계획(Single Objective Multi Depots Vehicle and Drone Routing Problem with Time Window) 문제를 다루었는데, 이는 희망 배송 시간대를 가지는 고객과 복수의 차고지, 그리고 단일 분배센터로 이루어진 배송 네트워크에서 총비용을 최소화하는 차량과 드론의 운행일정을 결정하는 문제이다. 논문 [5]의 저자들은 이 문제를 풀기 위해 유전 알고리즘을 제안하고, 이를 솔로몬(Solomon) 인스턴스에 적용하여 배송산업에 있어 드론 사용의 유용성을 입증한 바 있다.

본 연구는 논문 [5]의 확장 버전으로, 희망 배송 시간대를

• First Author: Tae Joon Park, Corresponding Author: Yerim Chung

\*Tae Joon Park (xoxoqr@naver.com), Dept. of Yonsei School of Business, Yonsei University, Seoul, Korea

\*Yerim Chung (yerimchung@yonsei.ac.kr), Dept. of Yonsei School of Business, Yonsei University, Seoul, Korea

• Received: 2018. 10. 02, Revised: 2018. 12. 15, Accepted: 2018. 12. 28.

• This work was supported by the Ministry of Education of the Republic of Korea and the National Research Foundation of Korea (NRF-2017S1A5A8022220).

• This research was supported by the Yonsei University Research Fund of 2017-22-0074.

가지는 고객과 복수의 차고지, 그리고 단일 분배센터로 이루어진 배송 네트워크에서, 배송에 사용된 드론과 차량의 대수와 총 운용비용을 동시에 최소화시키는 다목적 일정계획(Multi Objectives Vehicle and Drone Routing Problem with Time Window: MOVDRPTW) 문제를 다룬다. 실험에서는 실제 택배 배송지 데이터에 기반하여 생성된 배송 데이터를 사용하였다. 알고리즘 측면에서는 복수의 알고리즘을 혼합한 형태의 하이브리드 메타 휴리스틱인 HMOEA(Hybrid Multi-Objective Evolutionary Algorithm)를 제안하면서, 단일 방식 휴리스틱(Single population based heuristic)을 사용한 선행 연구들과의 차이점을 확보하였다.

본 논문은 서론을 포함하여 총 6장으로 구성되어 있다. 2장에서는 서로 다른 특징을 가지는 두 가지 운송수단이 동시에 운용되는 MOVDRPTW의 문제 상황을 소개하고, 3장에서는 MOVDRPTW를 풀기 위해 사용된 알고리즘인 HMOEA를 소개한다. 4장에서는 도심지역의 택배 배송 데이터를 기반으로 생성된 인스턴스들을 대상으로 드론-차량 혼용전략과 차량만을 사용하는 전략을 비교한다. 5장에서는 본 연구의 의의와 한계점을 논의하고 6장에서는 본 연구의 결론과 제안하는 후속 연구에 대해 설명한다.

## II. Problem statements and network model

배송산업에서 드론의 운영이 소개된 이후에 많은 물류업체들이 드론을 활용한 배송에 관심을 가지고 있지만, 실제로 이를 운영하는 방식과 관련된 연구는 현장의 관심에 비해 상대적으로 그 수가 적다고 할 수 있다.

본 논문에서는 일반적으로 물류회사에서 운영하는 단위 배송 구역을 대상으로 배송 네트워크를 구성하였다. 도시지의 경우, 단위 배송 구역은 반경 2~2.5km 이내의 구(區) 단위로 볼 수 있으며, 복수의 차고지와 1 개의 분배센터, 그리고 다수의 고객을 포함하고 있다. 배송차량들은 구역 내 위치하는 소속 차고지에 정차되어 있다가, 분배센터로 이동하여 당일 배송할 짐을 적재하고 배송을 시작한다. 배송차량은 적재한 화물을 모두 배송할 때까지 운행을 계속하며, 차고지로 복귀함으로써 운행을 종료한다. 모든 차량은 사전에 정해진 배송 종료시점 이전에 운행을 종료해야 한다.

고객의 경우에는 ‘일반 고객’ 외에도 특정 시간대 안에 배송 받기를 희망하는 ‘희망 시간 고객’이나, 자신이 지정한 배송 시간대보다 일찍 배송될 경우 추가비용을 지불할 의사가 있는 ‘빠른 배송 고객’과 같은 다양한 소비자들이 고려된다. ‘희망 시간 고객’의 경우에는 사전에 요청한 시간대에 서비스를 받기 희망하는 고객으로, 배송을 받는 시점이 사전에 요구한 시간 구간보다 빠르거나 늦은 경우 모두 서비스 만족도가 감소한다. ‘빠른 배송 고객’은 사전에 희망하는 배송 시간대를 정하지만, 정해진

시간대 보다 더 빠른 배송 서비스를 받는 경우 고객의 만족도가 증가하는 고객이다. ‘빠른 배송 고객’은 배송 시점이 정해진 시간대를 넘기는 경우에는 고객 만족도가 감소한다.

더불어 드론은 기술적인 한계로 인하여 1번에 1개의 화물만을 운반할 수 있기 때문에 드론은 차고지와 고객을 점대점(point to point)로 운행한다. 반면 차량은 다수 고객의 짐을 한번에 싣고, 고객들에게 순차적으로 화물을 배송하는 밀크런(milk-run)식 운행을 한다. Fig. 1의 점선인 드론 라우트에서, 드론은 차고지2와 고객5 사이를 점대점으로 운행하였고, 다시 고객6을 서비스하기 위해 이동하고 있다. Fig. 1에서 실선인 차량 라우트는 차고지1을 출발하여, 분배센터에서 당일 배송할 짐을 적재한 후, 고객1, 고객2, 고객3을 배송하였고, 고객4를 배송하기 위해 이동하는 중이다.

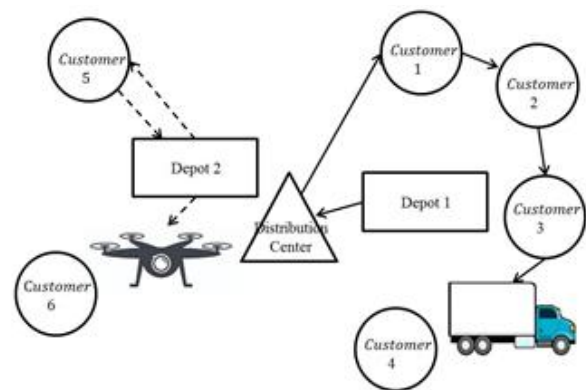


Fig. 1. Network Model for MOVDRPTW

이러한 상황에서 MOVDRPTW는 다목적 최적화 문제로, 배송에 사용된 차량과 드론의 총 대수, 그리고 차량과 드론의 운행으로 인한 비용과 고객의 희망 시간대를 맞추지 못해 발생한 페널티 비용을 합한 총 비용을 최소화 하는 것을 목적으로 한다. 차량과 드론의 운행과 관련된 비용에는 차고지에서 분배센터로의 운행, 분배센터에서 고객으로의 운행, 그리고 마지막 고객에서 다시 차고지로의 운행이 포함된다.

## III. HMOEA

### : Hybrid Multi-Objective Evolutionary Algorithm

#### 1. HMOEA

진화알고리즘은 메타휴리스틱(Metaheuristic) 계열의 방법론으로써 짧은 연산시간 내에 실용적인 수준의 해를 제공하기 때문에 많은 분야에서 사용되고 있다. 진화알고리즘은 다양한 해를 생성한 후, 생성된 해의 모집단을 개선시키면서 더 좋은 해를 탐색하는 메타휴리스틱으로, 후행 세대에서 더 우수한 유전

자가 살아남아 다수를 차지하는 자연의 진화과정을 모방한 알고리즘이다 [6]. MOVDRTW와 같은 조합최적화 문제들은 최적해를 구하기 위해서 많은 연산이 필요하기 때문에, 정확해법이나 근사알고리즘으로는 매일 변화하는 배송네트워크의 일정 계획을 세우는 것에는 어려움이 있다. 때문에 상대적으로 짧은 연산시간 내에 실용적인 수준의 해를 제공할 수 있는 진화알고리즘은 실제 운영계획에서 많이 사용되고 있다 [7][8][9].

진화알고리즘은 파레토 최적(Pareto optimal)과 합쳐져, 다목적 문제를 효과적으로 풀 수 있다. 다목적 문제를 단목적 문제로 변형하여 경우에는 알고리즘이 문제를 푸는 과정에서 왜곡들이 발생할 수 있는데, 파레토 최적은 개별 목적식을 모두 고려함으로써 왜곡을 피할 수 있기 때문이다[10][11][12]. 단목적 최적화는 해의 평가 기준이 한 개의 목적식이기 때문에 1차원 해 공간에서 모든 해들의 적합도를 표현할 수 있다. 그러나 다목적 최적화 문제에서는 해 공간이 2차원 이상이기 때문에 각각의 항목을 별도로 변환하지 않으면서 해들의 적합도를 평가할 수 있는 방법이 필요하다. 지배(Dominance)는 파레토 최적(pareto optimal)의 개념으로, 2개의 해를 비교할 때, n 차원의 해공간에서, 몇 개의 차원(목적식)에 대해 우위를 가지는냐를 보는 방법이다. 어떤 해의 지배수는 해당 해가 지배하는 다른 해의 숫자이다 [18]. MOVDRTW와 같은 계열인 용량 제한이 있는 차량일정 계획 문제 (capacitated vehicle routing problem)는 전체 비용과 사용된 차량의 대수를 동시에 최소화시키는 다목적 최적화 문제로, 진화 알고리즘에 다부서치를 결합한 하이레벨 팀워크(High Level Teamwork) 알고리즘이 연구된 바 있다[13].

진화알고리즘을 설계할 때는 다양한 해의 탐색(Explore)과 좋은 품질의 해를 확보(Exploit)하여야 한다. 탐색의 경우에는 초기해를 무작위로 생성하거나, 진화과정에서 돌연변이를 발생시켜 기존의 해 집단에서는 발견되지 않았던 다른 유형의 해를 해집단에 추가함으로써 구현이 가능하다. 확보의 경우에는 존에 가지고 있는 해를 대상으로 알고리즘의 진화과정을 수행함으로써, 기존의 해를 개선하는 것으로 구현이 가능하다. 하지만 탐색과 확보는 상충관계에 있는데, 만약 연산 초기에 알고리즘이 확보와 관련된 연산을 수행하는 경우에는 진화알고리즘의 탐색능력을 저하시키고, 다양성의 저하로 연결된다 [14]. 조합 최적화와 같이 이웃해가 정확하게 정의되지 않는 문제의 경우에는 다양한 초기해를 빠르게 생성한 이후에 진화알고리즘을 사용하여 해의 품질을 개선시키는 접근이 활용되고 있다.

2. Structure of HMOEA

본 연구에서는 MOVDRTW를 풀기 위해서 HMOEA를 제안한다. HMOEA는 무작위방식(randomized greedy heuristic)으로 생성된 초기해가, 진화과정을 통해 개선되고, 다시 충지역해 탐색을 거치는 하이레벨 릴레이 하이브리드(High-level Relay Hybridization) 구조를 갖는다(Fig. 2.).

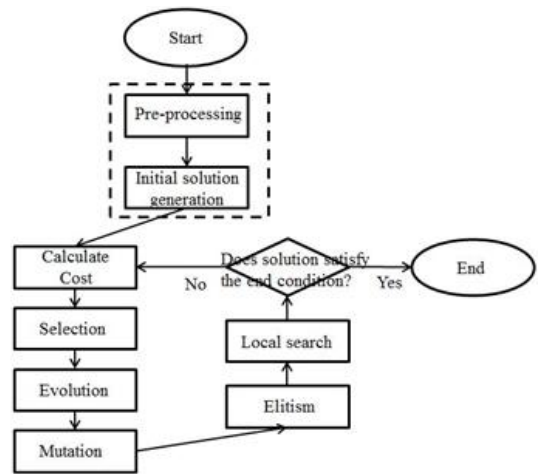


Fig. 2. Structure of HMOEA

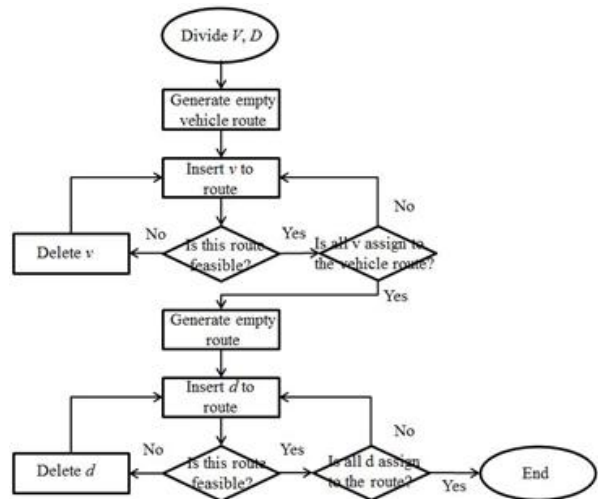


Fig. 3. Random Generation of Initial Solutions

HMOEA는 초기해 형성, 적합도 평가, 유전연산, 엘리티즘, 지역해 탐색의 구조로 이루어져 있다 (Fig. 2). 알고리즘은 실험 데이터를 읽어 들이고, 이를 연산에 적합 형태로 가공하는 전처리 작업에서부터 시작한다. Fig.2의 초기해 생성(initial solution generation)에서는 무작위 방식을 사용하는데, 이는 다양한 돌연변이 생성방식(Mutation)과 함께 HMOEA이 다양한 해를 탐색할 수 있게 한다. 무작위 초기해 생성은 두 단계로 구분된다 (Fig. 3). 이는 배송물의 무게나, 차고지로부터의 거리와 같은 요소 때문에 반드시 차량으로 서비스되어야 하는 고객(V)과 차량과 드론 모두에 의해 서비스가 가능한 고객(D)으로 나뉘기 때문이다. 이후 V에 속한 고객에 대해 차량 라우트를 구성하고, 이는 모든 V고객이 서비스될 때까지 계속된다. 남은 고객들(D)의 경우에는 사전에 정의된 확률에 따라 운송수단이 선택되고, 해당 라우트의 가능해 조건이 유지되는 한도 내에서 고객들을 할당한다.

초기해 생성 후에는 생성된 해들에 대해 총비용이 계산 (Calculate cost)되고, 모집단 내에서 해 쌍(pair)들 간에 라우트 교환교차(route exchange crossover)를 이용한 진화연산 (Evolution)이 수행된다. 이후 돌연변이가 일정한 확률로 출현하

고, 해의 다양성을 증가시킨다. 엘리티즘(elitism)에서는 파레토 랭킹(pareto rank)을 통해 우수한 해들을 다음 세대로 넘긴다. 엘리티즘(elitism)은 해당 세대에서 알고리즘이 구한 해의 집단 중 좋은 해를 보관하며, 좋은 해들이 후행 연산으로 소실되지 하는 기능을 함으로써, 필요한 연산량을 줄여주는 역할을 한다[15].

HMOEA에서는 일정 연산 횟수(100번)마다, 모든 라우트에 대해 상층 지역해 탐색을 수행하여 해를 개선시키고, 해의 확보(exploit)을 효과적으로 수행한다. HMOEA은 일정 반복 횟수(1000번)에 도달하거나, 일정 횟수(10회) 이상 해의 품질이 개선되지 않을 경우 종료된다.

### 3. Variable length chromosome

HMOEA는 다수의 라우트로 구성된 변수 길이 해 표현(variable length chromosome)을 사용한다. 진화알고리즘에 있어서는 유전연산자에 따라 적합한 해 표현을 사용하는 것이 연산시간을 단축시킬 수 있다[16]. 변수 길이 해 표현은 유전연산자의 계산단위인 라우트를 기준으로 해가 구성되어 있기 때문에, 유전연산의 효율성을 높여준다.




Fig. 4. Variable Length Chromosome in the HMOEA

개별 해(chromosome)는 전체적인 정보를 나타내는 부분(A)와 드론과 차량의 라우트 정보를 나타내는 부분인 (B)와 (C)로 구성되어 있다.(Fig. 4) 모든 해들은 동일한 구조를 가지고 있지만, 각 라우트의 운송수단, 서비스하는 고객, 서비스하는 순서에 따라 다른 해 표현을 가지게 된다. 각 해는 3가지 종류의 라우트를 가질 수 있다.

해 정보인 (A)는 해의 모든 라우트 총비용(total cost), 필요한 운송수단 대수 정보를 담고 있다. 실제 배송라우트를 의미하는 (B)와 (C)의 앞 3자리는 해당 라우트의 비용, 적합도 그리고 해당 라우트의 운송수단을 의미하는 패러미터(1=차량, 0=드론) 정보를 담고 있다. 그 뒤에 나오는 성분(gene)들은 해당 라우트의 운행정보인 고객방문순서를 가지고 있다. 드론 경우는 고객을 점대점으로 운행하며, 차량 라우트인 (C)의 경우에는 차고지에서 출발하여 분배센터에서 화물을 적재한 후 고객들을 연속적으로 방문하는 구조를 가진다.

### 4 Route exchange crossover

유전 연산자는 유전과정에서 어떠한 정보를 중점적으로 이용할 것인지, 어떠한 정보를 다음 세대에 넘겨줄 것인지를 결정하는 역할을 한다. HMOEA에서 불가능해가 많아지는 것은 연

산의 효율성을 감소시키기 때문에, 유전 연산자에 의해 불가능해가 발생하는 것을 줄여야 한다. MOVRPTW에서 불가능해는 어떤 해가 모든 고객을 서비스할 수 없거나, 운행종료시점이 배송네트워크 운영시간을 초과하는 라우트를 가지거나, 드론의 용량보다 더 무거운 화물이 할당되는 경우에 발생한다. 또 MOVRPTW와 같은 순서기반의 조합 최적화문제에서는 해의 변화 정도와 결과 값의 개선 정도 사이에 일정한 상관관계가 없다고 알려져 있기 때문에 필요한 정보만을 효과적으로 다음 세대로 유전시킬 수 있는 유전 연산자가 필요하다[17].

고객이 서비스 받는 시간과 고객을 서비스하기 위해 차량이나 드론이 움직이는 거리가 고객의 순서에 의해 결정되기 때문에, 순서 정보를 유전시키는 수 있는 라우트 교환교차가 적합하다고 판단된다. 임의로 선택 된 두 해에 대해서 라우트 교환교차는 각 해에서 적합도가 가장 좋은 라우트를 뽑아서, 상대방 해에 삽입한다. 적합도는 해당 라우트의 고객 1인당 서비스 비용이다. 이 때 라우트에서 발생하는 겹치는 고객들은 제거한다.




Fig. 5. Route Exchange Crossover

Fig. 5의 예시는  $C_1$ 과  $C_2$ 가 뽑혔고,  $C_2$ 에서 고객순서를 가지고 있는  $R_1$ 이  $C_1$ 로 삽입되는 과정을 보여준다.  $C_2$ 의  $R_1 = [1,3,1,6,1,7,1,8,1]$ 은 드론 라우트이며, 이 삽입과정으로 인해  $C_1$ 의 차량 라우트인  $r_2 = [1,2,4,5,6,7,9,1]$ 와 겹치는 고객(6과 7)이  $C_1$ 에서 생기게 된다. 따라서 가능해를 유지하기 위해  $r_2$ 에서 고객 6과 7을 제거하여,  $r_2$ 를  $[1,2,4,5,9,1]$ 로 수정한다. 이때,  $R_1$ 은  $C_2$ 에도 계속 남아있기 때문에, 좋은 고객순서인  $[1,3,1,6,1,7,1,8,1]$ 가  $C_1$ 과  $C_2$  모두에서 존재하며, 두 해 모두 가능해를 유지하게 된다.

### 5. Mutation

돌연변이는 일정한 확률에 의해 발생하며 해의 라우트에 변형을 가한다. 이는 유전과정에서 발생하지 못했던 다양한 해를 발생시키며, 유전 연산자로는 할 수 없던 개선을 이끌어낸다. 본 연구에서는 역순서, 단순교차, 역순서 교차 연산 돌연변이를 통해, 해에 변형을 주고자 하였다.

역순서 돌연변이의 경우에는 해에서 대상 라우트를 선택하고 해당 라우트의 전체 고객의 순서를 역순으로 바꾼다. 단순교차 연산자, 역순서 교차 연산자는 한 해 내의 두 라우트를 선택하는 것에서부터 시작한다. 이 때 2개의 난수를 생성하여 교환할 구간의 시작과 종료부분을 정한다. 이후 각 라우트에서 앞서 구한 교환 구간에 있는 고객들을 교환한다. 선택되는 2개의 라

우트의 운송수단이 동일할 필요는 없다. 다만 두 라우트 사이의 구간 교환 가정에서 불가능해를 발생시키는 고객의 경우에는 교환이 취소되며, 해당 고객의 짝에 해당하는 고객 역시 교환되지 않고 그대로 유지된다. 역순서 교차 연산자의 경우는 단순교차 연산자와 달리 교차 과정에서 고객들의 순서를 역순으로 변경한다. 또 단순교차와 같이 교환된 고객 중 불가능 해가 생성되는 경우에는 해당 고객 쌍의 교환 작업을 취소한다.

## 6. Pareto ranking

```

Input:  $S' = S_{n-1} \cup S_n$ 
For  $s_i$  in  $S'$ :
  Compute  $rank_i$  and  $niche_i$ 
 $S''$  append non-dominated solution set
While  $|S''| < population\ size$  :
  For  $s_i, s_j$  in  $S'$ :  $i \neq j$ 
    Pick one candidate
   $S'' = S_n$ 

```

Fig. 6. Pseudo Code of Pareto Ranking and Elitism

HMOEA에서는 연산마다 다음 세대의 해를 선택하는데 이는 Fig.2의 선택에 해당한다. 본 연구에서는 이를 위해 지배기반 순위(Dominance-based approaches)계열의 랭킹(rank)과 틈새(niche) 개념을 혼용한 방법을 사용하였다. 파레토 개념을 사용한 우수 해의 선택은 한 세대 이전의 해 집단과 유전 과정이 완료된 현재 세대의 해집단에서 파레토 랭킹을 계산하는 것에서 시작한다(Fig. 6). MOVRPTW를 마주하는 물류운영사의 경우에는 1)운행비용의 최소화, 2)운행에 필요한 차량과 드론의 수를 최소화시키는 것이 주요한 의사결정 요인이다. 1)의 경우에는 운행에서 발생하는 변동비용과 고객들의 희망배송시간대를 지키지 못해서 발생할 수 있는 패널티 비용의 합이다. 어떤 해( $s$ )의 운행비용(Operating Cost<sub>s</sub>)의 경우에는 다음과 같이 계산된다.

$$\begin{aligned}
 & \text{Operating Cost}_s \\
 &= \sum_{r \in R} (\text{moving distance}_r * \text{unit moving cost}_r * \text{mode correction factor}_r)
 \end{aligned}$$

운행비용은 각 라우트가 이동한 거리(moving distance<sub>r</sub>)에 이동비용(unit moving cost<sub>r</sub>)을 곱한 값으로 계산된다. 이때 차량과 드론은 각자 다른 값의 운송수단 보정계수(correction factor<sub>r</sub>)를 가진다. 이를 통해 차량은 맨해튼 방식으로 움직이고, 드론의 경우에는 직선에 가깝게 움직이는 차이를 반영하고자 하였다. 2)는 차량과 드론의 대수의 합으로 계산된다. 이렇게 1)과 2)를 목적식으로 계산된 파레토 랭킹을 토대로  $S'$ 에서 지배당하지 않는 해(non-dominated solution)를 우선적으로 선택한다. MOVRPTW는 1)과 2)를 모두 최소화 하는 문제이기 때문에, 어떤 해의 파레토 랭킹은 해당 해 보다 1)과 2)가 큰 값을 가지는 해들의 숫자에 반비례한다. 즉 1)과 2)가 동시에 작아져야 높은 파레토 랭킹을 가지게 된다. 또

한 남은 해들의 경우에는 임의로 2개의 쌍을 묶어, 더 적은 랭크를 가지는 해를 다음 세대로 유전시킨다. 이 과정에서 동차가 발생하는 경우에는 정규화된 해 공간에서 계산된 틈새 값이 더 적은(해공간에서 해당해 주변에 유사한 해가 상대적으로 적음)해를 선택하게 된다. 틈새값의 경우에는 다음과 같이 계산된다.

$$niche_i = \sum_{j \in neighborhood_i} \left(1 - \frac{d_{ij}}{niche\ radius_i}\right)^2$$

$neighborhood_i$ 는 해  $i$ 의 이웃 중, 정규화된 해 공간에서, 해  $i$ 와의 거리가  $niche\ radius$  보다 가까운 해들의 집합을 의미한다. 정규화를 수행하는 이유는 1)과 2)의 값의 범위가 다르기 때문에 발생하는 틈새값 계산 과정에서의 왜곡을 피하기 위함이다. 또 틈새값의 사용은 더 적은 해를 선택함으로써 해들이 한쪽으로 치우치는 것을 방지하고 기존의 해와는 다른 해를 보존함으로써, 유전알고리즘의 주요 요소인 탐색을 수행할 수 있게 한다.

## 7. Local search in HMOEA

HMOEA는 상층지역 해탐색(off-set local search)을 통해, 계산된 해의 이웃해들을 재탐색는데, 이는 메타 휴리스틱 기반 알고리즘에서 추가적인 지역탐색으로 더 좋은 해를 얻을 수 있기 때문이다 [19]. 그러나 MOVRPTW와 같이 이웃해가 명확하지 않은 해공간을 탐색할 때는 효과적인 규칙이 필요하다. 만약 규칙 없이 모든 해공간을 탐색한다면 알고리즘의 연산량을 증가시킬 것이고, 규칙이 너무 엄격하다면, 다른 이웃해에 대해 지역 해탐색이 이루어지지 않을 것이기 때문이다. 상층 지역해 탐색의 탐색 규칙은 두 라우트의 노드를 교환함으로써 전체 비용이 감소할 수 있는 노드 교환 쌍인 방출 체인(ejection-chain)[20]을 변형한 것이다.




Fig. 7. Off-set Local Search Range



Fig. 8. Desired Time Window and Arrival Time of the Two Customers in the Off-set Relationship

본 연구에서는 서로 다른 라우트에 있는 고객 쌍 중, 상호간의 서비스 시간(도착 시간)이 바뀔으로써 원래 희망배송 시간대에 더 잘 맞춰 질 수 있는 고객 쌍을 '두 고객은 서로 상충관계이다.'라고 정의한다. 상충 지역 탐색 알고리즘은 기준 노드를 잡고, 해당 노드와 일정 범위 안에 있는 노드 중, 상충 관계를 만족시키는 노드를 찾는 것에서부터 시작한다(Fig. 7). 이 과정에서 비용이 감소하는 것은 두 노드가 교환되면서 만족시키지 못했던 고객의 희망 배송 시간대가 지켜지기 때문이다. Fig. 8은 라우트 1에 속한 고객  $i$ 의 희망 시간대  $[ET_i, LT_i]$ 와 배송 도착시간  $T_i^1$  그리고, 라우트 2에 속한 고객  $j$ 의 희망 시간대  $[ET_j, LT_j]$ 와 배송 도착시간  $T_j^2$ 을 보여주고 있다. 이 두 노드를 서로 바꾸면 시간 패널티를 줄일 수 있다. 이러한 두 노드의 관계를 상충관계라고 한다. 노드 교환은 반드시 일정거리 내의 노드 사이에 이루어져야 하며(Fig. 8), 이는 두 노드의 교환으로 인해 발생하는 비용을 최소화시키고, 동시에 삽입으로 인한 후행 고객들의 TW의 변동을 최소화하기 위한 전략이다.

## 8. Route reducing method

HMOEA에서 다른 해에서 적합도가 높은 라우트를 삽입하는 라우트 교환교차 유전연산자의 작동방식은 해의 라우트 수를 증가시킬 수 있다. 이는 MOVDRPTW의 목적이 필요한 차량의 대수를 최소화시키는 것임을 고려하면, 결과에 부정적인 영향을 미치는 요인이다. 하지만 진화알고리즘을 일체계획문제에 사용한 선행연구들에서는 이 현상에 대한 언급이 명확히 이루어지지 않고 있다. 라우트 줄이기는 이렇게 증가할 수 있는 해 내의 라우트 수를 줄이기 위해 고안되었다.

HMOEA는 진화과정이 끝난 후에 라우트 줄이기를 시행한다. 라우트 줄이기 작업은 가장 짧은 길이의 라우트 내의 고객들을 최소비용으로 삽입될 수 있는 다른 라우트에 삽입함으로써, 해 내의 라우트의 수를 유전과정 이전과 동일하게 유지하고자 한다. 이때, 라우트 선정 기준은 서비스한 고객의 수로 하는데 이는 서비스한 고객의 수가 라우트 줄이기의 연산량을 증가시키기 때문이다. 라우트 줄이기는 개별 해에서 서비스하는 고객의 수가 가장 적은 라우트에 대하여 다음과 같이 진행된다.

(1) 삽입 가능 후보군 탐색: 기준 고객( $i$ )을 대상으로 일정거리 이내에 다른 라우트에 서비스 받는 고객들( $j$ )을 파악하고, 삽입 가능 후보군( $j \in J$ )에 넣는다. 탐색의 범위 제한은 기준 고객( $i$ )으로부터의 거리가 후보( $j$ )의 운송수단으로 20분 이내에 도달 가능한 거리로 제한한다.

(2) 삽입 비용 산정: 기준 고객( $i$ )이 후보군의 고객( $j$ ) 앞뒤에 삽입될 때 발생하는 비용을 계산한다. 이때, 후보군의 고객( $j$ )이 드론 라우트에 있다면 기준 고객( $i$ )의 무게가 드론이 배송 가능한지 확인하며, 그렇지 않다면 후보군에서 제외한다.

(3) 삽입: 후보군의 고객들( $j \in J$ ) 중에서 가장 적은 비용을 발생시키는 라우트에 해당 고객을 삽입한다. 삽입되는 라우트의 경우에는 다른 고객들의 도착시간을 기준 고객( $i$ )을 서비스

하는데 추가로 필요한 시간만큼 늦춘다.

라우트 줄이기에서는 삽입 가능 후보군 탐색 시 탐색 범위를 제한하는데, 이는 탐색 범위와 삽입 비용에 영향을 미치는 주요한 요소이기 때문이다. 예를 들어 차량의 경우에 삽입 비용을 줄이려면, 기준 고객( $i$ )와 가까운 고객을 서비스하는 라우트에 고객이 삽입되어야 한다. 또 드론 라우트의 경우에는 삽입되고자 하는 라우트의 차고지가 기준 고객( $i$ )과 가까울수록, 삽입 비용을 최소화할 수 있다.

## V. Experiment

4.1에서는 실험에 사용된 데이터와 이를 MOVDRPTW의 문제상황에 맞는 데이터로 변환하는 과정을 소개한다. 4.2에서는 실험 결과에 대해 각 시나리오별로 차량만 사용한 배송네트워크와 드론을 혼용한 배송네트워크 간의 전체비용, 운송수단 별 비용, 운송수단의 민감성에 대한 주제로 실험 결과를 해석한다. 이를 바탕으로 드론의 실제 도입이 도심지 물류 환경에 미칠 수 있는 영향을 살펴보고자 한다.

### 1. Experiment Data

실험을 위해서는 실제 데이터에 기반한 4가지의 상이한 데이터가 사용되었다. MOVDRPTW에서 데이터의 정보는 크게 위치 데이터와 희망배송시간대 데이터로 구분되는데, 위치 데이터의 경우에는 우정사업본부의 데이터를 기반으로 하였으며, 희망배송시간대 데이터의 경우는 배송 수요가 특정 시간대에 집중되는 시나리오를 가정하고 생성하였다.

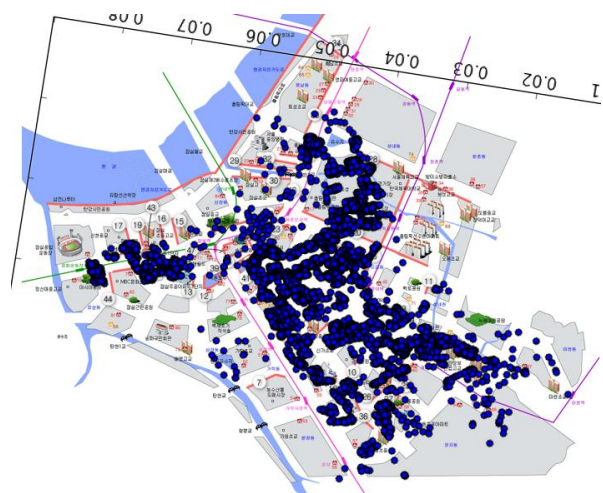


Fig. 9. Customer Locations in Songpa-gu in Seoul

위치 데이터의 경우는 우정사업본부의 송파구 송장 데이터를 기반으로 한다. 송장 데이터는 고객의 위치에 대한 정보를 담고 있다. 다만 우정사업본부에서 제공한 송장데이터는 동 단

위 정보만 기재되어 있기 때문에, 해당 동에 있는 건물들에 우편물들을 다시 할당하는 작업과 이를 좌표 데이터로 변경하는 작업이 상용 지도 프로그램API를 통해 수행되었다. 변환된 종교객의 위치 데이터는 4200개로, 이 중 200개의 고객들을 무작위로 추출하여 위치 데이터를 구성하였다.

희망배송시간대 데이터의 경우는 4가지 시나리오를 가정하고, 시나리오에 맞추어 삼각분포를 통해 생성되었다. 각 시나리오 오는 오전 8시부터 오후 10시 사이에 서비스가 이루어진다고 가정하며, 생성되는 분포에 필요한 파라미터 값을 가지고 있다. 시나리오는 희망배송시간대 생성에 사용된 삼각분포의 중앙값이 언제인지에 따라서 1)'Early', 2)'Middle', 3)'Late', 4)'All day'로 나뉜다. 1)'Early', 2)'Middle', 3)'Late'은 해당 시점에 고객들의 수요가 집중되는 시나리오로, 가장 많은 빈도가 생성되는 지점의 값인 중앙값이 사용되는 삼각분포를 사용해 희망배송시간대가 생성되었다. 4)'All day'은 고객들의 희망배송시간대가 하루 종일 균등하게 분포되어있는 시나리오로, 무작위 분포를 사용하였다.

1)'Early': 희망배송시간대 생성 시 삼각분포의 중앙값이 오전 10시로 출근 전이나, 일과 시작 후 가까운 시간 내에 배송서비스받기 원하는 고객의 수요가 많은 시나리오이다.

2)'Middle': 희망배송시간대 생성 시 삼각분포의 중앙값이 오후 3시인 경우로 일과 중에 필요한 주문이 많은 시나리오이다.

3)'Late': 희망배송시간대 생성 시 삼각분포의 중앙값이 오후 6시인 경우로 퇴근 후 및 일과 종료 후에 수요가 많은 시나리오이다.

4)'All day': 희망배송시간대가 무작위로 생성된 경우로 하루 종일에 걸쳐 고객들의 수요가 있는 시나리오이다.

우정사업본부의 위치 데이터와 시나리오에 기반한 희망배송시간대 데이터를 결합하면, MOVDRPTW에 필요한 데이터를 구성할 수 있다.

이와 같이 고객들의 수요가 특정시간에 집중되는 시나리오는 근래에 시도되고 있는 배송 서비스를 참고하여 구성되었다. 'Early'의 경우에는 신선식품 분야에서 시도되고 있는 오전배송을 참고하였다. 'Middle'과 'Late'는 음식배송 분야에서 점심과 저녁시간에 배송 수요가 집중되는 특징을 반영하기 위해 구성되었다. 또 앞의 시나리오들에서 고객들의 수요가 특정시간에 집중되기 때문에 'All day'를 통해 앞의 시나리오들과 다르게 고객들의 수요가 하루 종일 꾸준히 분포되어 있는 일반적인 상품의 경우를 보고자 하였다.

하지만 본 연구의 시나리오들의 생성에 사용된 삼각분포의 중앙값은 정량적인 데이터가 공개되지 않은 상황에서 본 연구자들에 의해 추정된 값이기 때문에, 추후에 고객들의 희망배송시간대와 관련 있는 정량적인 데이터를 활용한다면 더 객관적인 시나리오를 생성할 수 있을 것이다.

## 2. Experiment results

본 연구의 목적은 배송네트워크에 있어서 드론을 혼용하는

전략의 유용성을 살펴보는 것이다. 이를 위해서는, 드론을 혼용하는 드론혼용전략과 차량만을 사용하는 차량전략을 여러 측면에서 비교, 분석하는 것이 필요하다. 또 드론혼용전략에서는 생성된 드론 라우트와 차량 라우트를 비교하는 것이 바람직하며, 마지막으로, 드론 라우트와 차량 라우트의 민감성에 대한 분석이 이루어져야 한다.

### 2.1 Total cost comparison between vehicle only strategy and drone mixed strategy


HMOEA 종료 후 계산되는 각 해들의 총비용(Total Cost)은 운행비용과 시간비용의 합으로 계산된다. 운행비용은 이동거리, 거리상수, 단위거리 당 운행비용의 곱으로 계산된다. 거리상수는 지상의 도로를 이용하는 차량과 달리 비행하는 드론의 운행방식을 고려하기 위해 사용되었다. 시간비용은 고객들이 배송받은 시점이 고객들이 사전에 가지고 있던 희망배송시간대를 벗어나는 경우에 계산되며, 개별 고객들의 시간비용의 총합이 전체 시간비용이 된다. 어떤 해(s)의 시간비용( $Time Cost_s$ )의 경우에는 다음과 같이 계산된다.

$$\begin{aligned} Time\ cost_s &= \sum_{c \in Timewindow\ Customer} [a \max(ET_c, 0) + b \max(LT_c, 0)] \\ &+ \sum_{c \in Fast\ Customer} [c \max(ET_c, 0) + b \max(LT_c, 0)] \end{aligned}$$

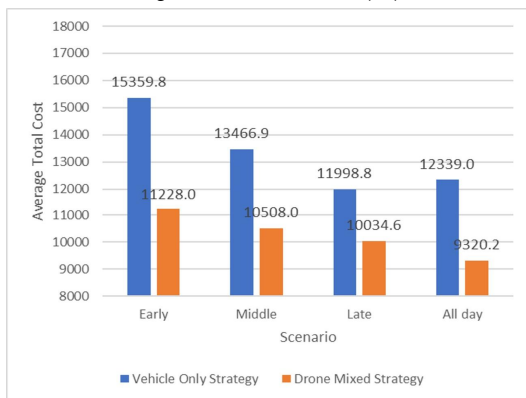
시간 비용( $Time Cost_s$ )은 모든 고객에 대해, 개별 고객이 어떠한 유형의 서비스를 원하는지에 따라 다르게 계산된다. 사전에 차량과 드론의 이동속도가 정의되어 있기 때문에, 해에 저장되어 있는 라우트가 서비스한 고객에 대한 정보를 통해 각 고객이 서비스 받은 시간을 계산할 수 있다.

모든 고객들은 일반고객, 희망배송시간대고객(*Timewindow Customer*) 그리고 빠른고객(*Fast Customer*) 중 한 고객에 속하게 된다. 희망배송시간대 고객의 시간 비용의 경우에는 고객이 사전에 요청한 배송 시간대 내에 고객들의 서비스를 받은 경우에는 0의 값을 가진다. 희망배송 시간대보다 이르거나 늦은 시간에 도착하는 경우에는 해당 시간 만큼에 패널티( $a, b$ )를 곱한 값이 시간 비용으로 계산된다.

빠른 고객은 본인이 요청한 배송 시간대 보다 더 빠르게 서비스를 받고 싶어하는 의향이 있고, 이에 대한 추가 지불의사가 있다고 가정하였다. 때문에 고객이 사전에 요청한 배송 시간대 보다 빠르게 배송한 경우에 추가적인 이익의 발생을 구현하였다. 목적식은 비용이기 때문에, 이는 일찍 도착한 시간에 음의 계수( $c$ )를 곱함으로써 추가적인 이익으로 표현되었다. 하지만 빠른고객의 경우도 본인이 요청한 시간보다 더 늦는 경우에는 희망배송시간대 고객과 같이 패널티( $b$ )가 발생한다.



A. Average Total cost of all population



B. Average Total cost of the Upper 20%

Fig. 10. Average total cost

각각의 시나리오에 대해 차량전략과 드론혼용전략을 적용한 결과는 다음과 같다. Fig. 10-A는 알고리즘이 종료된 시점의 모든 해들의 총비용 평균(Average Total Cost)을 보여주고 있다. 총비용 평균 측면에서 드론혼용전략이 배송 수요가 늦은 오후에 집중된 늦음 시나리오를 제외한 모든 시나리오에서 차량 네트워크들에 비해 우위를 보이고 있다. Fig. 10-A에서는 ‘Early’, ‘Middle’, ‘All day’ 시나리오에서는 드론혼용전략이 차량전략에 비해 3214.3, 1038.9, 2542.7 만금의 총비용 우위를 가진다. 이는 3 가지 시나리오에서 드론혼용전략이 22.8%정도 총비용적인 측면에서 우위를 가진다고 볼 수 있다. 다만 ‘Late’ 시나리오에서는 차량전략이 드론혼용전략에 비해 273.3의 우위를 가진다. 차량전략이 ‘Late’ 에서는 드론혼용전략에 비해 2.6%정도의 총비용적 우위를 가지지만, 이는 다른 시나리오들에서 드론혼용전략이 차량전략에 비해서 가졌던 총비용적 우위와 비교하였을 때는 우위의 강도가 약하다고 볼 수 있다.

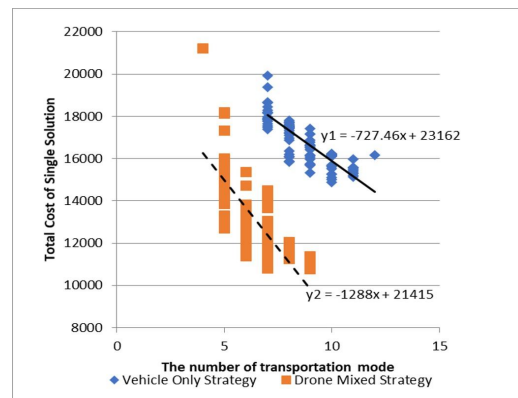
Fig. 10-B는 알고리즘이 종료된 시점의 배송네트워크들 중 총비용 평균이 적은 상위 배송네트워크(상위 20%)들의 총비용 평균을 보여주고 있다. HOMEA의 특징상, 탐색을 위한 요소들로 인해 연산과정에서 성능이 좋지 않은 해들을 가지게 된다. 운영적 측면에서는 전체 해 집단에서 성능이 좋은 소수의 상위 배송네트워크를 선택해 사용하기 때문에, Fig. 10-A의 전체 배송네트워크의 평균값뿐 아니라 상위 배송네트워크의 평균값

을 고려하는 것은 의미가 있다. 상위 20%에 해당하는 배송 네트워크에서 발생한 총비용 평균을 비교해보면, 늦음 시나리오를 포함한 모든 시나리오에서 드론혼용전략이 비용적인 우위를 가진다는 것을 확인할 수 있다. Fig. 10-B를 통해 상위 20%의 해에서는 ‘Early’, ‘Middle’, ‘Late’, ‘All day’ 각 시나리오에서 드론혼용전략이 차량전략에 비해 4131.8, 2958.9, 1964.2, 3018.9 만금의 총비용 우위를 가짐을 확인할 수 있다. 이는 모든 해의 평균을 보았던 Fig. 10-A보다 높은 수치인 평균 30.9%로, 상위 20%의 해에 있어서는 드론혼용전략의 총비용적인 우위가 더 강하게 나타나는 것으로 볼 수 있다.

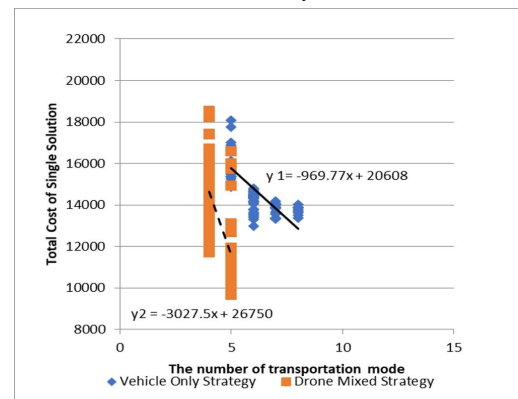
이를 통해 드론혼용전략의 비용적 우위는 드론 운용에 필요한 제반 시설을 확보하는 데 필요한 초기 도입 비용이 상대적으로 낮은 운용비용을 통해 상쇄될 수 있음을 의미한다고 할 수 있다.

## 2.2 Total cost and number of vehicles and drones

본 절에서는 2.1에서 본 비용과 차량과 드론의 대수를 함께 살펴보고자 한다. 차량전략의 경우 운송 대수는 차량의 대수를 의미하며, 드론혼용전략의 경우 운송 대수는 배송에 사용된 차량과 드론 대수의 합을 의미한다.




A. Total costs and the number of transportation mode in the ‘Early Scenario’

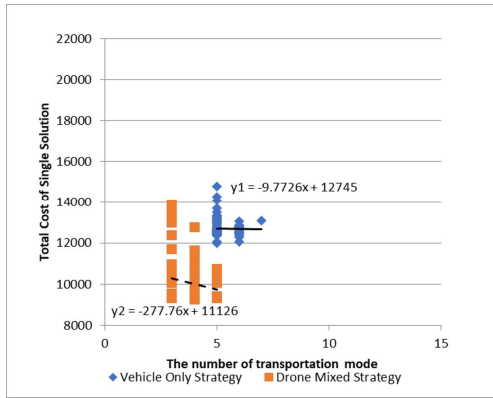


B. Total costs and the number of transportation mode in the ‘Middle Scenario’





C. Total costs and the number of transportation mode in the 'Late Scenario'




D. Total costs and the number of transportation mode in the 'All day Scenario'

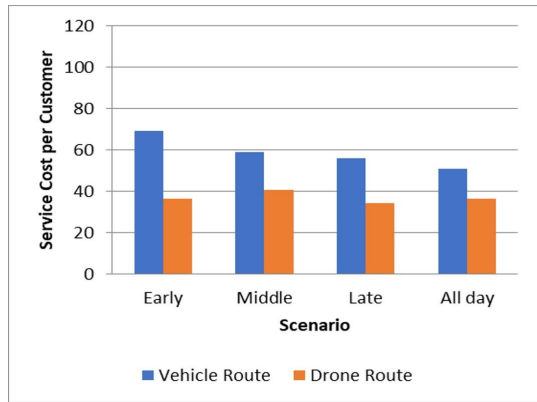
Fig. 11. Total costs and the number of used vehicles and drones in each of four Scenarios

Fig. 11은 빠른 배송에 대한 수요가 집중되는 시간에 따라 구분된 4개의 시나리오 별로 배송네트워크들의 총비용과 사용된 차량과 드론의 대수 합을 보여준다. Fig. 11-A,B,C,D 각 그림에서  $y_1$ 은 차량전략에서 차량 대수에 대한 총비용에 대한 선형추정이다.  $y_2$ 은 드론혼용전략에서 드론과 차량 대수 합에 대한 총비용에 대한 선형추정이다. 모든 시나리오에서 드론혼용 전략의 총비용 선형추정인  $y_2$ 의 기울기 절대값이 더 큰 것을 볼 수 있다. 이는 드론혼용전략에서 운송수단을 한 대 더 추가할 때 감소 될 수 있는 총비용이, 차량전략의 경우보다 더 크음을 의미한다. 이러한 경향은 고객들의 수요가 특정 시간대에 집중된 'Early', 'Middle', 'Late' 시나리오에서 강하게 나타난다 (Fig. 11-A,B,C).

한편, 드론의 대당 도입 가격은 차량 한대 가격의 30%정도 인데, 이는 운영자의 시각에서 배송네트워크에 투입되는 드론의 수를 쉽게 조절할 수 있음을 의미한다. 이는 드론혼용전략에서 운영자는 상대적으로 낮은 비용으로 드론을 추가하여 총비용을 낮출 수 있고, 이는 차량전략에 대한 상대적인 우위로 작용할 수 있다.



A. Average Service Cost per Customer



B. Average Service Cost per Customer of the Upper 20%

Fig. 12. Average Service Cost

### 2.3 Service cost comparison

드론혼용전략에서 드론 라우트와 차량 라우트를 비교함으로써, 각 운송수단의 특성이 운영에 미치는 영향을 살펴볼 수 있다. Fig. 12-A,B는 전체 평균과 상위(20%) 해들에 대해, 드론 혼용전략에서 차량과 드론에 의해 배송받은 고객 1인당 서비스 비용을 보여준다. 고객 1인당 서비스 비용은 드론 또는 차량을 운행하는데 사용되는 운행비용과 고객의 희망배송 시간대를 지키지 못한 경우에 발생한 시간비용의 합을 해당 라우트가 서비스한 고객의 수로 나눈 값이다. Fig. 12에서 볼 수 있듯이, 드론 라우트가 차량 라우트에 비해 더 낮은 고객 1인당 서비스 비용을 가진다. 점대점 방식으로 운행되는 드론의 경우 차량에 비해 일반적으로 더 많은 거리를 운행함에도 불구하고, 드론 라우트의 고객 1인당 서비스 비용이 더 낮다는 점은 드론의 낮은 거리당 운행비용이 이를 상쇄시켜 준다는 것을 의미한다.

Table 1은 드론혼용전략에서 드론과 차량 라우트의 고객 1인당 운행비용과 시간비용을 보여준다. 모든 시나리오에 있어서 드론 라우트는 차량 라우트에 비해 더 낮은 운행비용을 보여준다. 이러한 경향은 시간비용에서 더 뚜렷하게 나타나는데, 이는 드론에 의해 서비스를 받은 고객들이 차량에 의해 서비스를 받은 고객들에 비해 본인들의 희망배송시간에 더 많이 배송받았음을 의미한다. 이는 고객의 시각에서 체감 서비스 수준과

직결되어 있기 때문에, 드론 라우트의 고객들이 차량 라우트의 고객들보다 더 좋은 수준의 서비스를 체험하였다고 볼 수 있다.

Table 1. The operating cost and time cost per customer in drone and vehicle route in the drone mixed strategy./ ( ) indicated the value of upper 20% of EA population

Scenario	Drone Route		Vehicle Route	
	Operating Cost	Time Cost	Operating Cost	Time Cost
Early	37.91 (36.63)	0.97 (-0.28)	75.65 (61)	20.86 (8.06)
Middle	42.47 (39.92)	2.61 (0.57)	76.71 (56.32)	21.28 (2.44)
Late	36.96 (36.99)	-3.05 (-2.86)	66.13 (53.48)	11.65 (2.44)
All day	37.59 (37.55)	-1.13 (-1.17)	54.47 (49.23)	4.69 (1.49)

흥미로운 점은 ‘All day’ 시나리오 보다는, 배송 수요가 특정 시간대에 집중되어있는 시나리오들에 있어서 드론 라우트의 비용 우위가 더 두드러진다는 점이다. 이러한 경향은 ‘Early’와 ‘Late’ 시나리오에서 강하게 나타났다. 예를 들어 고객들의 수요가 퇴근 시간인 6시 이후에 집중되어있고 대부분의 고객들이 빠른배송을 희망하는 음식배송산업의 시각에서는 드론혼용전략이 더 효과적일 수 있다.

### 2.4 Sensitivity of drone route and vehicle route in drone mixed strategy

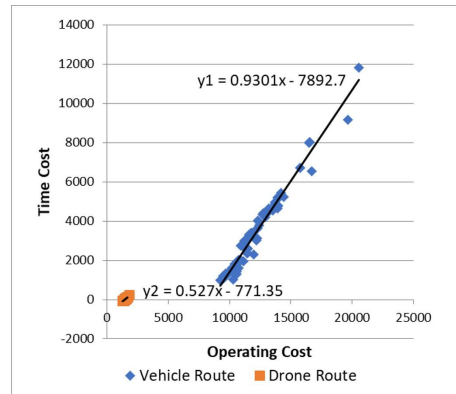
드론이나 차량이 운행하는 거리는 고객들의 배송 수요와 라우트 계획의 효율성에 의해 결정된다. 고객들의 배송 수요는 월별이나 특정한 사건에 의해 증가하는데, 증가 된 배송 수요는 배송네트워크의 운행거리를 증가시킨다. 또 갑작스러운 교통체증이나, 고객의 부재로 인해 라우트가 변경되는 경우 기존의 라우트 계획의 효율성이 낮아지고 이는 드론이나 차량의 운행거리를 증가시킬 수 있다. MOVDRPTW는 복잡도가 높기 때문에 라우트 계획의 효율성 역시 편차가 크다. 따라서 운행거리와 비례하는 운행비용의 증가에 따른 시간비용의 변동을 살펴봄으로써, 변동성에 있어서 더 민감한 운송수단을 확인할 수 있다.

Fig. 13은 드론혼용전략에서 드론과 차량 라우트 각각의 평균 운행비용과 시간비용을 보여주고 있다. 모든 시나리오에서 드론 라우트의 선형추정(y2) 기울기가, 차량 라우트의 선형추정(y1) 기울기에 비해 작은 값고, 선형추정의 절편 값 역시 더 작은 값을 가진다. 이는 드론 라우트의 경우 운행비용의 증가가 시간비용에 거의 영향을 미치지 않음을 보여준다.

한편, ‘Late’ 시나리오에서는 드론 라우트 평균의 시간비용이 음의 값을 가지는 것을 확인할 수 있다. 이는 드론이 많은 고객의 희망배송시간대를 만족시켰고, 빠른 배송을 원하는 소비자들에게는 물건을 더 빨리 배송하였음을 의미한다.

또 모든 시나리오에서 드론 라우트의 시간비용이 차량 라우트의 시간비용에 비해, 더 일정한 것을 확인할 수 있다. 이는 드론 라우트가 차량 라우트 보다 고객들이 원하는 시간에 배송하는 데에 있어

더 강건하다는 것을 의미한다. 드론은 고객과 차고지를 왕복하는 점대점 방식으로 운행되는데, 이는 운행계획의 복잡성을 감소시킴으로써 드론 라우트가 더 쉽게 최적의 라우트에 도달할 수 있게 한다. 차량 라우트 시간비용의 경우에는 운행계획의 최적화에 따라 많은 편차를 보이며, 이는 시간비용에 영향을 미침으로써 고객 체험 서비스 수준에 부정적인 영향을 미칠 수 있다.



A. Time and Operating Cost of Drone Route and Vehicle Route in the ‘Early Scenario’




Fig. 13-B. Time and Operating Cost of Drone Route and Vehicle Route in the ‘Middle Scenario’

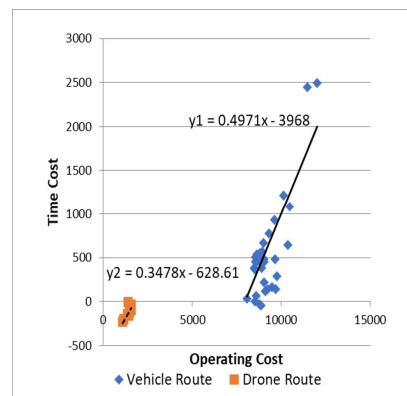


Fig. 13-C. Time and Operating Cost of Drone Route and Vehicle Route in the ‘Late Scenario’




Fig. 13-D. Time and Operating Cost of Drone Route and Vehicle Route in the 'All day Scenario'

Fig. 13. Time Cost and Operating Cost

## V. Limitation and Discussion

기존의 드론의 라우팅을 다룬 선행연구들에서는 차량 1대와 드론 1대의 운영을 통해 드론이 배송 차량과 함께 운영될 수 있음을 보이고자 했다면, 본 연구에서는 다수의 차량과 다수의 드론을 동시에 운영하는 보다 확장된 문제상황을 통해 다수의 차량과 드론을 함께 사용하는 상황을 살펴보고자 하였다. 또 드론을 차량과 함께 운영하는 것이 단순히 운행비용에 있어서 효과적일 뿐만 아니라, 배송 희망 시간대를 가지는 고객들의 배송 희망 시간대에 더 잘 부합함으로써 고객들의 입장에서 드론의 사용이 이득이 될 수 있음을 보이고자 하였다. 또 알고리즘에 있어서는 HMOEA를 통해 운행비용과 필요한 차량과 드론의 대수를 동시에 줄일 수 있는 해를 찾고자 하였다. 단목적식을 사용하였던 연구에서는 운행비용과 차량과 드론의 대수가 같은 선행결함으로 단일 목적식에 있었기 때문에 알고리즘이 운행비용이 증가하는 경우에도 차량의 대수를 우선적으로 줄이려는 경향을 보였다. HMOEA에서는 이를 파레토 최적과 틸 새 값 개념을 사용하여, 해결하고자 하였다. 또 기존의 연구들이 상대적으로 큰 인스턴스에 대해 취약한 알고리즘들을 사용하였다면, 본 연구에서는 인스턴스의 크기가 커지는 경우에도 빠른 시간 안에 답을 도출할 수 있는 진화알고리즘 계열의 HMOEA를 제안하고자 하였다.

하지만 드론을 이용한 배송은 여러 한계점도 가지고 있다. 드론을 차량과 비교하였을 때, 한정된 배터리로 인한 운행거리 제한이나 운송 가능한 화물의 무게 제한이 대표적이다. 때문에 단순히 경로를 계획하는 것 외에도 드론의 한계를 보완할 수 있는 방안에 대한 고려가 필요하다. 이와 관련해서는 드론의 중간기착지를 고려한 일정계획이나, 공중에서 체류하는 모션(Carrier)을 활용하는 것을 들 수 있다. 후속 연구에서는 새롭게 시도되고 있는 개념들을 도입한 문제상황이 사용되어야 할 것이다.

## VI. Conclusions

본 논문에서는 실제 도심지 물류 데이터를 이용하여, 드론과 차량을 같이 사용하는 드론혼용전략과 차량만을 사용하는 차량 전략을 비교해 보았다. 실험 결과, 배송 수요가 오전, 오후, 늦은 오후에 집중하는 시나리오와 하루 종일 균일하게 수요가 발생하는 시나리오 모두에서 드론혼용전략이 차량전략에 총비용적인 측면에서 평균적으로 30% 정도의 비용을 절감할 수 있음을 확인하였다. 실험결과에 보인 바와 같이 드론혼용전략의 비용우위는 운행비용은 드론의 초기도입비용 때문에 드론 도입을 망설이는 의사결정자들에게 드론 도입에 대한 긍정적인 요소로 작용할 수 있다. 또 드론혼용전략에서 고객 1인당 서비스 비용에 있어서도, 드론 라우트는 차량 라우트 대비, 운행 비용과 시간 비용 모두에서 더 적은 비용을 발생하였다. 이러한 고객 1인당 서비스 비용의 우위는 고객의 수요가 특정한 시간대에 집중되어 있는 경우인 'Early', 'Middle', 'Late' 시나리오에서 드론을 이용한 고객 1인당 서비스 비용이 차량을 이용한 고객의 1인당 서비스 비용에 비하여 56.7% 더 낮은 것을 통해 확인되었다. 'All day'에는 이러한 드론 라우트의 우위가 38.3%로 다른 시나리오에 비해 상대적으로 약해지는 경향을 확인할 수 있었다.

도심의 물류상황은 변화가 심하고, 운행계획은 복잡도가 높은 문제이기 때문에 라우트의 강건성은 중요한 요소이다. 이러한 드론 라우트의 강건성은 도심지역에서의 변화가 심한 현대 물류 환경에 적합한데, 배송 도중의 배송지 변경, 배송 시간 변경 등과 같은 갑작스러운 수요의 변화에 더 유연하게 대처할 수 있기 때문이다. 본 연구는 도심지의 물류 상황에서, 드론혼용전략의 효과를 여러 측면에서 살펴보고자 하였으며, 빠른 배송의 수요가 있는 도심지역에서 드론혼용전략은 차량전략에 비해 운행비용 측면과 필요한 운송 대수 측면에서 우위를 보이는 것을 확인하였다.

본 연구는 도심지의 배송지에 기반한 위치 데이터를 사용했지만 고객의 배송 수요에 대한 가상데이터를 이용하였다는 한계가 있다. 실제 물류시장의 빅데이터에 기반한 고객의 희망배송시간대와 빠른 배송 수요가 전제되었다면 좀더 실용적인 전략적 제안이 가능했을 것이라 생각된다. 후행 연구로는 도서 산간 지역과 같이 상대적으로 인구밀도가 낮은 지역에서 드론 혼용전략이 어떠한 영향을 미칠지를 살펴보는 것 역시 필요하다고 생각된다.

## REFERENCES

- [1] C. C. Murray and A. G. Chu, "The flying sidekick traveling salesman problem: Optimization of drone-assisted parcel delivery", *Transportation Research Part C: Emerging*

- Technologies, Vol. 54, pp. 86–109, 2015.
- [2] N. Agatz, P. Bouman, and M. Schmidt, “Optimization approaches for the traveling salesman problem with drone”, 2016.
- [3] Q. M. Ha, Q. Y. Deville, Q. D. Pham, and M. H. Hà, “Heuristic methods for the Traveling Salesman Problem with Drone”, arXiv preprint arXiv:1509.08764, 2015.
- [4] Q. M. Ha, Q. Y. Deville, Q. D. Pham, and M.H. Hà, “On the Min-cost Traveling Salesman Problem with Drone”. arXiv preprint arXiv:1509.08764, 2015.
- [5] Y. Chung, T. Park, and Y. Min, “Usefulness of Drones in the Urban Delivery System: Solving the Vehicle and Drone Routing Problem with Time Window”, Journal of the Korean Operations Research and Management Science Society, Vol.41 No.3 ,pp. 75–96, 2016.
- [6] T. Back, “Evolutionary algorithms in theory and practice: evolution strategies, evolutionary programming, genetic algorithm.”, Oxford university press, 1996.
- [7] G. Laporte, M. Gendreau, J. Y. Potvin, and F. Semet, “Classical and modern heuristics for the vehicle routing problem”, International transactions in operational research, Vol. 7, No. 4-5, pp. 285–300, 2000.
- [8] B. Ombuki, B. J. Ross, and F. Hanshar, “Multi-objective genetic algorithms for vehicle routing problem with time windows”, Applied Intelligence, Vol. 24, No. 1, pp. 17–30, 2006.
- [9] O. Bräysy, W. Dullaert, and M. Gendreau, “Evolutionary algorithms for the vehicle routing problem with time windows”, Journal of Heuristics, Vol. 10, No. 6, pp.587–611, 2004.
- [10] S. C. Hong, and Y. B. Park, “A heuristic for bi-objective vehicle routing with time window constraints”, International Journal of Production Economics, Vol. 62, No. 3, pp. 249–258, 1999.
- [11] K. Deb, “Multi-Objective Optimization Using Evolutionary Algorithms”, John Wiley & Sons, Inc., New York, NY, 2001.
- [12] E. Zitzler, M. Laumanns, and L. Thiele, SPEA2, “Improving the strength Pareto evolutionary algorithm”, 2001.
- [13] E. G. Talbi, “Metaheuristics: from design to implementation”, Vol. 74, John Wiley & Sons, 2009.
- [14] C. A. C. Coello, G. B. Lamont, and D. A. Van Veldhuizen, “Evolutionary algorithms for solving multi-objective problems”, (Vol. 5, New York: Springer, 2007.
- [15] J. Berger, and M. Barkaoui, “A hybrid genetic algorithm for the capacitated vehicle routing problem”, In Genetic and evolutionary computation conference, pp. 646–656. Springer Berlin Heidelberg, July 2003.
- [16] K. C. Tan, T. H. Lee, Y. H. Chew, and L. H. Lee, “A multiobjective evolutionary algorithm for solving vehicle routing problem with time windows”, In Systems, Man and Cybernetics, 2003. IEEE International Conference, Vol. 1, pp. 361–366. IEEE, October, 2003.
- [17] O. Bräysy, “Fast local searches for the vehicle routing problem with time windows”, INFOR: Information Systems and Operational Research, Vol. 40, No. 4, pp. 319–330, 2002.
- [18] E. Zitzler, and L. Thiele, “An evolutionary algorithm for multiobjective optimization: The strength pareto approach”, 1998.
- [19] W. Chaovalitwongse, D. Kim, and P. M. Pardalos, “GRASP with a new local search scheme for vehicle routing problems with time windows”, Journal of Combinatorial Optimization, Vol. 7, No. 2, pp. 179–207, 2003.
- [20] F. Glover, “New ejection chain and alternating path methods for traveling salesman problems”, Computer science and operations research, Vol. 449, pp. 491–507, 1992.

## Authors



algorithms.

Tae Joon Park received the M.S. degree in Business Administration from Yonsei University in 2017 and has been in Ph.D. degree program since 2017. He is interested in logistics optimization, new technologies for logistics, and machine learning



Yerim Chung received the B.S. degree in Business Administration from Yonsei University, Korea, in 2000. She received the M.S. and Ph.D. degree in Applied Mathematics and Computer Science from Paris 1 University, France, in 2004 and 2010, respectively. Dr. Chung joined the faculty of Business School at Yonsei University, Seoul, Korea, in 2011. She is interested in inverse optimization, transportation science and network effects.