



# Analysis of data aggregation for the design of a supply chain network: the case of the distribution of an automotive manufacturer

Suzanne Le Bihan

## ► To cite this version:

Suzanne Le Bihan. Analysis of data aggregation for the design of a supply chain network: the case of the distribution of an automotive manufacturer. Operating Systems [cs.OS]. Université Grenoble Alpes [2020-..], 2023. English. NNT : 2023GRALI036 . tel-04589990

**HAL Id: tel-04589990**

<https://theses.hal.science/tel-04589990>

Submitted on 28 May 2024

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

## THÈSE

Pour obtenir le grade de

### DOCTEUR DE L'UNIVERSITÉ GRENOBLE ALPES

École doctorale : I-MEP2 - Ingénierie - Matériaux, Mécanique, Environnement, Energétique, Procédés, Production

Spécialité : Génie Industriel : conception et production

Unité de recherche : Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble

### Étude de l'agrégation de données sur la conception d'un réseau logistique : cas de la distribution d'un constructeur automobile

### Analysis of data aggregation for the design of a supply chain network: the case of the distribution of an automotive manufacturer

Présentée par :

**Suzanne LE BIHAN**

Direction de thèse :

**Gülgün ALPAN-GAUJAL**

PROFESSEURE DES UNIVERSITES, Grenoble INP

Directrice de thèse

**Bernard PENZ**

PROFESSEUR DES UNIVERSITES, Grenoble INP

Co-encadrant de thèse

Rapporteurs :

**Ayse AKBALIK**

MAITRE DE CONFERENCES HDR, Université de Lorraine

**Nabil ABSI**

PROFESSEUR DES UNIVERSITES, Ecole Nationale Supérieure des Mines de Saint-Etienne

Thèse soutenue publiquement le **23 mai 2023**, devant le jury composé de :

**Gülgün ALPAN-GAUJAL**

PROFESSEUR DES UNIVERSITES, Grenoble INP

Directrice de thèse

**Van-Dat CUNG**

PROFESSEUR DES UNIVERSITES, Grenoble INP

Examinateur

**Bruno AGARD**

PROFESSEUR, Ecole Polytechnique de Montréal

Président

**Ramzi HAMMAMI**

CHERCHEUR HDR, Rennes School of Business

Examinateur

**Ayse AKBALIK**

MAITRE DE CONFERENCES HDR, Université de Lorraine

Rapporteure

**Nabil ABSI**

PROFESSEUR DES UNIVERSITES, Ecole Nationale Supérieure des Mines de Saint-Etienne

Rapporteur

Invités :

**Bernard PENZ**

PROFESSEUR DES UNIVERSITES, Grenoble INP

**Christian SERRANO**

INGENIEUR DOCTEUR, Renault Group

**Grégoire BOUSSU**

INGENIEUR, Thalès





# Remerciements

J'aimerais tout d'abord mentionner l'engagement sans faille de mes directeurs de thèse Gülgün Alpan et Bernard Penz. Sans eux et le pitch de motivation d'Alain Nguyen, je n'aurais probablement même pas considéré entreprendre un tel projet. Je les remercie sincèrement. Je tiens à remercier également mes encadrants industriels, Grégoire Boussu pour son engagement et ses conseils précieux et Christian Serrano pour sa disponibilité.

Je remercie les membres du jury d'avoir accepté d'évaluer ce travail : Ayse Akbalik et Nabil Absi, rapporteurs, et Van-Dat Cung, Bruno Agard et Ramzi Hammami, examinateurs.

Je souhaite aussi remercier les membres de l'équipe AI@SC pour leur accueil et leur bonne humeur. J'ai adoré faire partie de votre équipe, organiser des événements avec Alice et manger les crêpes d'Olivier. Évidemment, je souhaite tout le succès qu'ils méritent aux doctorants de la Direction Logistique et les remercie pour les discussions et leur soutien, en particulier, Adèle et Naila qui m'ont encouragée pendant ces trois années. Je remercie également les doctorants du laboratoire GSCOP pour leur accueil chaleureux à chacun de mes déplacements à Grenoble.

Je remercie les organismes financeurs de ce travail de thèse, à savoir l'ANRT<sup>1</sup>, la chaire MIAI<sup>2</sup> Grenoble Alpes et l'entreprise Renault Group. Je souhaite également remercier l'entreprise de m'avoir fourni un véritable serveur de calcul portatif, me permettant à l'occasion d'économiser un abonnement à la salle de sport. Enfin, j'aimerais mentionner les services de la SNCF, qui m'ont permis d'accomplir un nombre d'heures de rédaction considérable au calme avec la wifi gratuite des trains, la table de seconde classe pouvant tout juste accueillir mon serveur.

Sur une note plus personnelle, je remercie mes proches, famille et amis, de m'avoir soutenue pendant ces trois années et tout particulièrement Alex qui m'a aidée à de nombreuses reprises à avancer dans ce projet.

---

1. Association Nationale de la Recherche et de la Technologie

2. Multidisciplinary Institute in Artificial intelligence



# Table des matières

<b>Remerciements</b>	<b>iii</b>
<b>Table des matières</b>	<b>vii</b>
<b>Liste des acronymes</b>	<b>ix</b>
<b>Liste des tables</b>	<b>xii</b>
<b>Table des figures</b>	<b>xv</b>
<b>Introduction générale</b>	<b>1</b>
<b>1 Contexte et enjeux de l'étude</b>	<b>7</b>
1.1 Introduction . . . . .	7
1.2 Contexte industriel . . . . .	7
1.2.1 La logistique du constructeur Renault Group . . . . .	8
1.2.2 La distribution de véhicules chez Renault Group . . . . .	10
1.2.2.1 Les plateformes logistiques . . . . .	12
1.2.2.2 Les moyens de transports . . . . .	13
1.2.2.3 Les types de flux . . . . .	14
1.2.2.4 La gestion des demandes . . . . .	15
1.2.3 Le problème tactique de conception du réseau de distribution .	16
1.2.4 L'arrivée des problématiques orientées données . . . . .	17
1.2.4.1 La centralisation et la standardisation des données .	17
1.2.4.2 La problématique d'agrégation des données . . . . .	18
1.3 État de l'art . . . . .	18
1.3.1 L'agrégation de données pour les modèles d'optimisation . . .	19
1.3.1.1 L'agrégation de données . . . . .	19
1.3.1.2 L'agrégation de données pour les modèles d'optimisation	19
1.3.2 L'acceptation d'un modèle par les utilisateurs . . . . .	21
1.3.3 Conception de réseaux logistiques - problèmes stratégiques .	23
1.3.3.1 Le « Facility Location Problem » . . . . .	24
1.3.3.2 Le « Hub Location Problem » . . . . .	26
1.3.4 Conception de réseaux logistiques - problèmes tactiques . . .	28
1.3.4.1 Le « Network Design Problem » avec des coûts fixes .	29
1.3.4.2 Autres formulations particulières du coût de transport	30
1.3.4.3 Le « Network Design Problem » avec des coûts par lot	30

## TABLE DES MATIÈRES

---

1.4	Organisation et apports du travail de recherche . . . . .	32
	1.4.1 Problématique . . . . .	32
	1.4.2 Apports de la thèse . . . . .	33
1.5	Conclusion . . . . .	34
<b>2</b>	<b>Network design with batch cost</b>	<b>37</b>
2.1	Introduction . . . . .	38
2.2	Literature review . . . . .	39
	2.2.1 Fixed-cost network design . . . . .	40
	2.2.2 Other transportation costs formulations . . . . .	41
	2.2.3 Batch cost network design . . . . .	41
2.3	Problem description . . . . .	43
	2.3.1 The network structure of the BCNDP . . . . .	43
	2.3.2 The cost structure of the BCNDP . . . . .	46
	2.3.3 Input data . . . . .	46
	2.3.4 Variables . . . . .	47
2.4	Modeling and solving the BCNDP . . . . .	47
	2.4.1 MILP formulation for the BCNDP . . . . .	47
	2.4.2 A heuristic approach . . . . .	48
	2.4.3 Lower Bound . . . . .	49
2.5	Computational Experiments . . . . .	51
	2.5.1 Performances . . . . .	51
	2.5.2 Road transportation cost management . . . . .	52
	2.5.3 Network availability . . . . .	55
	2.5.4 Sensitivity study . . . . .	57
2.6	Conclusion . . . . .	58
<b>3</b>	<b>A quantitative study of data aggregation</b>	<b>61</b>
3.1	Introduction . . . . .	62
3.2	Literature review . . . . .	63
	3.2.1 Product type aggregation . . . . .	63
	3.2.2 Spatial aggregation . . . . .	64
	3.2.3 Temporal aggregation . . . . .	66
	3.2.4 Conclusion . . . . .	67
3.3	Problem description . . . . .	68
3.4	Methodology . . . . .	69
	3.4.1 Data aggregation . . . . .	70
	3.4.1.1 Product type aggregation . . . . .	72
	3.4.1.2 Spatial aggregation . . . . .	75
	3.4.1.3 Temporal aggregation . . . . .	76
	3.4.2 Solutions disaggregation . . . . .	76
	3.4.2.1 Disaggregating spatial aggregation . . . . .	77
	3.4.2.2 Disaggregating product type aggregation . . . . .	78
	3.4.2.3 Disaggregating temporal aggregation . . . . .	79
	3.4.3 Results evaluation . . . . .	80
3.5	Numerical experiments . . . . .	80
	3.5.1 Scope description and experimental conditions . . . . .	81

## TABLE DES MATIÈRES

---

3.5.2 Product type aggregation . . . . .	83
3.5.2.1 Order type aggregation . . . . .	83
3.5.2.2 Vehicle type aggregation . . . . .	85
3.5.3 Spatial aggregation . . . . .	86
3.5.4 Temporal aggregation . . . . .	88
3.5.5 Synthesis and managerial perspectives . . . . .	91
3.6 Conclusion . . . . .	92
 <b>4 Cost adjustment following input aggregation</b>	<b>95</b>
4.1 Introduction . . . . .	96
4.2 Description of the network design problem . . . . .	97
4.2.1 The batch cost network design problem . . . . .	98
4.2.2 Aggregated solutions . . . . .	99
4.2.3 Influence of input data aggregation on costs . . . . .	100
4.2.4 Disaggregated cost calculation . . . . .	101
4.3 Cost adjustment method . . . . .	101
4.3.1 Principles of the cost adjustment methods . . . . .	101
4.3.2 The model of the cost adjustment problem . . . . .	102
4.3.3 Method AM_CostType . . . . .	103
4.3.4 Method AM_Center . . . . .	104
4.3.5 Method AM_Section . . . . .	105
4.4 Method implementation . . . . .	105
4.4.1 Training the adjustment values . . . . .	105
4.4.2 Validation of the adjustment values . . . . .	106
4.5 Numerical experiments . . . . .	106
4.5.1 Performance of cost adjustment methods . . . . .	107
4.5.1.1 Product type aggregation . . . . .	108
4.5.1.2 Spatial aggregation . . . . .	110
4.5.1.3 Temporal aggregation . . . . .	111
4.5.1.4 Conclusion on the adjustment method . . . . .	112
4.5.2 Analysis per cost type . . . . .	113
4.5.2.1 Error on transportation cost . . . . .	113
4.5.2.2 Error on the handling cost . . . . .	118
4.5.2.3 Error on the inventory cost . . . . .	119
4.5.3 Performance comparison with a linear regression . . . . .	120
4.5.4 Sensitivity analysis of the training and validation sets distribution	123
4.6 Conclusion . . . . .	125
 <b>Conclusion générale</b>	<b>129</b>
Synthèse des contributions . . . . .	129
Perspectives . . . . .	130



# Liste des acronymes

<b>CLE</b>	Centre Livreur Expéditeur . . . . .	11
<b>CI</b>	Centre Intermédiaire . . . . .	12
<b>CDC</b>	Centre de Distribution Capillaire . . . . .	12
<b>ZG</b>	Zone Géographique . . . . .	12
<b>PD</b>	produit à la demande . . . . .	15
<b>PS</b>	produit pour stock . . . . .	15
<b>TI</b>	Technologie de l'Information . . . . .	21
<b>DSS</b>	Decision Support System . . . . .	96
<b>SAD</b>	Système d'Aide à la Décision . . . . .	22
<b>SCND</b>	Supply Chain Network Design . . . . .	96
<b>PLNE</b>	Programme Linéaire en Nombres Entiers . . . . .	29
<b>FLP</b>	Facility Location Problem . . . . .	23
<b>HLP</b>	Hub Location Problem . . . . .	23
<b>NDP</b>	Network Design Problem . . . . .	62
<b>3PL</b>	Third Party Logistics . . . . .	93
<b>BCNDP</b>	Batch Cost Network Design Problem . . . . .	97
<b>MILP</b>	Mixed-Integer Linear Programming . . . . .	97
<b>LP</b>	Linear Programming . . . . .	97
<b>CAP</b>	Cost Adjustment Problem . . . . .	101
<b>CRL</b>	Conception de réseaux logistiques . . . . .	129



# Liste des tableaux

1.1	L'agrégation pour des modèles de CRL . . . . .	20
1.3	FLP déterministes pour la distribution . . . . .	26
1.4	HLP déterministes pour la distribution . . . . .	28
1.5	Etudes de NDP multipériodes et multiproduits déterministes avec des coûts fixes . . . . .	29
1.6	Etudes de NDP multipériodes et multiproduits déterministes avec des coûts par lot . . . . .	31
2.1	Deterministic multi-period multi-product NDP with fixed-cost formulation	40
2.2	Deterministic multi-period multi-product NDP with batch cost formulation . . . . .	41
2.3	Performance tests designation . . . . .	52
2.4	Performance comparison between the $M_{BCNDP}$ and $H_{BCNDP}$ . . . . .	52
2.5	Tests designation for the performance of the batch cost relaxation . .	53
2.6	Performance comparison between $H_{BCNDP}$ and $R_{BCNDP}$ . . . . .	54
2.7	Impact of the demand volume multiplication on the cost difference between the solutions of the $R_{BCNDP}$ and $H_{BCNDP}$ . . . . .	54
2.8	Direct flow rate with $H_{BCNDP}$ and $R_{BCNDP}$ . . . . .	55
2.9	Tests designation for the impact of the network availability . . . . .	56
2.10	Performance comparison between $H_{BCNDP}$ with $ON$ and $NN$ . . . . .	56
2.11	Tests designation for the sensitivity study . . . . .	57
2.12	Performance comparison between $H_{BCNDP}$ with generated networks and $ON$ after variation applied on demand . . . . .	57
3.1	Literature on product type aggregation of a SCND model . . . . .	64
3.2	Literature on spatial aggregation of a SCND model . . . . .	66
3.3	Literature on temporal aggregation of a SCND model . . . . .	67
3.4	Input data structure . . . . .	72
3.5	Output data structure . . . . .	72
3.6	Two aggregation sub-dimensions for product type . . . . .	73
3.7	Synthesis of the impact of aggregation on the behavior of the model .	91
4.1	Errors resulting from input aggregation, the adjustment method, and the linear regression for product type aggregation . . . . .	121
4.2	Errors resulting from input aggregation, the adjustment method, and the linear regression for spatial aggregation . . . . .	121

4.3	Errors resulting from input aggregation, the adjustment method, and the linear regression for temporal aggregation . . . . .	122
4.4	$\mathcal{I}^t$ and $\mathcal{I}^v$ configurations . . . . .	123

# Table des figures

1.1	Implantations industrielles de Renault Group . . . . .	9
1.2	Flux et plateformes logistiques . . . . .	12
1.3	Exemple de remplissage d'un camion dans le cadre d'une négociation avec un transporteur . . . . .	14
1.4	Le compromis entre la précision et la difficulté de résolution d'un modèle lors de l'agrégation de données d'entrées . . . . .	18
1.5	Exemple de graph pour le FLP . . . . .	24
1.6	Exemple de graph pour le HLP . . . . .	27
2.1	Outbound supply chain network . . . . .	38
2.2	Outflow from node $(i, t)$ . . . . .	44
2.3	Single product BCNDP flow graph . . . . .	45
2.4	Trucks fill rate with $H_{BCNDP}$ according to the demand volume multiplication factor . . . . .	55
3.1	Network example . . . . .	68
3.2	Methodology . . . . .	69
3.3	Example of aggregation implications . . . . .	71
3.4	Constraint added in the $BCNDP + cstr(S_A)$ in $DM\_Route$ after spatial aggregation . . . . .	77
3.5	Constraint added in the $BCNDP + cstr(S_A)$ in $DM\_Quantity$ after spatial aggregation . . . . .	78
3.6	Constraint added in the $BCNDP + cstr(S_A)$ in $DM\_Quantity$ after vehicle type aggregation . . . . .	78
3.7	Example of a temporally unfeasible disaggregation for $DM\_Quantity$ . . . . .	79
3.8	Constraint added in the $BCNDP + cstr(S_A)$ in $DM\_Quantity$ after temporal aggregation . . . . .	80
3.9	Evaluation of the aggregation-disaggregation process . . . . .	80
3.10	Example for a box-and-whisker plot . . . . .	82
3.11	Integer variables . . . . .	83
3.12	$Opt\_proof\_Gap$ . . . . .	83
3.13	$Cost\_quality\_Gap$ . . . . .	84
3.14	Truck fill rate . . . . .	84
3.15	Direct flow rate . . . . .	84
3.16	Integer variables . . . . .	85
3.17	$Opt\_proof\_Gap$ . . . . .	85
3.18	$Cost\_quality\_Gap$ obtained with $DM\_Route$ . . . . .	85

3.19	<i>Cost_quality_Gap</i> obtained with <i>DM_Quantity</i> . . . . .	85
3.20	Truck fill rate obtained with <i>DM_Route</i> . . . . .	86
3.21	Truck fill rate obtained with <i>DM_Quantity</i> . . . . .	86
3.22	Used routes rate obtained with <i>DM_Route</i> . . . . .	86
3.23	Used routes rate obtained with <i>DM_Quantity</i> . . . . .	86
3.24	Integer variables . . . . .	87
3.25	<i>Opt_proof_Gap</i> . . . . .	87
3.26	<i>Cost_quality_Gap</i> obtained with <i>DM_Route</i> . . . . .	87
3.27	<i>Cost_quality_Gap</i> obtained with <i>DM_Quantity</i> . . . . .	87
3.28	Truck fill rate obtained with <i>DM_Route</i> . . . . .	88
3.29	Truck fill rate obtained with <i>DM_Quantity</i> . . . . .	88
3.30	Used centers rate obtained with <i>DM_Route</i> . . . . .	88
3.31	Used centers rate obtained with <i>DM_Quantity</i> . . . . .	88
3.32	Integer variables . . . . .	89
3.33	<i>Opt_proof_Gap</i> . . . . .	89
3.34	<i>Cost_quality_Gap</i> obtained with <i>DM_Route</i> . . . . .	89
3.35	<i>Cost_quality_Gap</i> obtained with <i>DM_Quantity</i> . . . . .	89
3.36	Truck fill rate obtained with <i>DM_Route</i> . . . . .	90
3.37	Truck fill rate obtained with <i>DM_Quantity</i> . . . . .	90
3.38	Used routes rate obtained with <i>DM_Route</i> . . . . .	90
3.39	Used routes rate obtained with <i>DM_Quantity</i> . . . . .	90
4.1	Obtaining $S_A$ and $C(S_{DISA})$ . . . . .	98
4.2	Graph example of the BCNDP . . . . .	99
4.3	Obtaining adjustment values . . . . .	106
4.4	Training and validation methodology . . . . .	106
4.5	Cost error on $\mathcal{I}^v$ instances with product type aggregation . . . . .	109
4.6	Mean cost error on $\mathcal{I}^v$ instances according to the product type aggregation level . . . . .	109
4.7	Cost error on $\mathcal{I}^v$ instances with spatial aggregation . . . . .	110
4.8	Mean cost error on $\mathcal{I}^v$ instances according to the spatial aggregation level with spatial aggregation . . . . .	111
4.9	Cost error on $\mathcal{I}^v$ instances with temporal aggregation . . . . .	111
4.10	Mean cost error on $\mathcal{I}^v$ instances according to the temporal aggregation level . . . . .	112
4.11	Cost types distribution . . . . .	113
4.12	$TError\_init$ and $TError\_adjust$ according to the product type aggregation level . . . . .	114
4.13	$t\epsilon$ according to the product type aggregation level . . . . .	114
4.14	error according to the $t\epsilon$ value with product type aggregation . . . . .	115
4.15	$TError\_init$ and $TError\_adjust$ according to the spatial aggregation level . . . . .	116
4.16	$t\epsilon$ according to the spatial aggregation level . . . . .	116
4.17	error according to the $t\epsilon$ value with spatial aggregation . . . . .	117
4.18	$TError\_init$ and $TError\_adjust$ according to the temporal aggregation level . . . . .	117
4.19	$t\epsilon$ according to the temporal aggregation level . . . . .	118

---

TABLE DES FIGURES

4.20 error according to the $t\epsilon$ value with temporal aggregation . . . . .	118
4.21 $PError\_init$ and $PError\_adjust$ according to the aggregation level	119
4.22 $TError\_init$ and $TError\_adjust$ with all $\mathcal{I}^t \mathcal{I}^v$ configurations . . .	124



# Introduction générale

Au sein de l'union européenne, l'industrie automobile représente 12.1 million de véhicules produits en 2021 soit 15.3% du marché mondial<sup>3</sup>. Cette même année, l'Europe dispose, tous constructeurs confondus, de plus de 50000 concessions automobiles<sup>4</sup>. Le réseau européen de distribution de véhicules est donc très étendu et concerne des volumes importants de produits à transporter.

Chaque constructeur, à partir de ses usines, doit acheminer les véhicules à ses concessionnaires pour satisfaire la demande client. Or, les véhicules sont des produits contraignant à transporter en comparaison à de simples cartons, à cause de leur poids, de leur forme, et pour certains à cause de leur batterie. Ainsi, un camion ne peut contenir qu'un nombre restreint de véhicules. Étant donné que les particularités du transport de véhicules sont très spécifiques, les flux retours des transports routiers ne peuvent contenir que d'autres véhicules. Or, un retour à vide est facturé au constructeur automobile. Par conséquent, les tarifs de transport dépendent de la complémentarité des flux de véhicules du marché. En conclusion, les coûts de la chaîne logistique de la distribution de véhicule sont importants et ont une structure complexe. Les négociations avec les sociétés prestataires de transport, Third Party Logistics (3PL), pour la contractualisation des tarifs et des capacités de transports sur chaque route sont cruciales pour les constructeurs automobiles. À chaque fin de contrat sur une région géographique les négociations reprennent. Le réseau ainsi que les transporteurs sont alors remis entièrement en question. De plus, les récentes crises successives (de 2020 à 2022) impactent le fonctionnement de la distribution de véhicules. Ainsi la pandémie du Covid19, la crise des composants électroniques et le conflit en Ukraine ont engendré notamment la mise en arrêt d'usines et des changements brutaux dans les ventes de véhicules neufs. Tous ces événements, au-delà des variations de la demande, et du lancement de nouveaux véhicules contraignent les constructeurs à revoir régulièrement l'utilisation du réseau de distribution contractualisé.

L'objectif de la distribution des véhicules est donc de minimiser les coûts d'utilisation des routes, les coûts de passages sur les plateformes logistiques, et les coûts de stockage, pour acheminer les véhicules jusqu'aux concessions automobiles. Pour les raisons évoquées précédemment, le réseau de transports est complexe, d'autant plus que les transports routiers sont facturés par aller-retour de camions entiers, indépendamment du nombre de véhicules qu'ils transportent. La minimisation des coûts de transport passe donc par la densification des volumes dans les camions. Cependant, le stockage de véhicules dans les plateformes qui permet d'améliorer ces densifications est

---

3. ACEA 2022 <https://www.acea.auto/figure/key-figures-eu-auto-industry/>

4. ICDP 2022 <https://www.icdp.net/data-services>

également coûteux. Certaines économies de coût se font donc au détriment d'autres, ce qui rend ce problème difficile à résoudre. La gestion de la distribution de véhicules est donc un problème à fort enjeu pour les constructeurs.

La conception d'un réseau de distribution est une étape fondamentale. Elle permet aux entreprises du secteur automobile d'optimiser la distribution de véhicules en minimisant les coûts, et donc de rester compétitives. Les modèles mathématiques d'optimisation sont de puissants outils pouvant être employés pour aider à concevoir ces réseaux. Le problème central est celui de la **Conception de réseaux logistiques (CRL)**. Plus précisément, le problème est de déterminer les ouvertures de centres intermédiaires (plateformes logistiques) et de routes (trajets entre les usines, les centres et les concessionnaires) qui minimisent le coût total du réseau, généralement composé de coûts fixes d'ouverture de centres et de coûts variables d'utilisation de routes. Ces décisions stratégiques doivent être complétées régulièrement en intégrant des décisions tactiques comme la gestion des flux et le stockage des produits. Notre étude de cas se focalise sur un problème tactique dont les décisions principales portent sur l'utilisation de routes et le transit par des plateformes logistiques.

Les modèles de CRL sont difficiles à résoudre, surtout pour des problèmes de taille industrielle. Une étape fondamentale à la création d'un tel modèle est de déterminer le niveau de détail des données d'entrée du modèle en concordance avec l'objectif poursuivi. La principale motivation industrielle de cette thèse est ainsi de créer une méthodologie applicable pour les projets de conception de réseaux logistiques, afin de préconiser un bon niveau de détail des données d'entrée dans l'outil d'aide à la décision.

Le choix judicieux du niveau de détail d'un outil d'aide à la décision pour la conception de réseaux peut en effet permettre de nombreuses économies : des économies de ressources de calculs, d'effort de développement de méthode de résolution plus performantes et de récupération de données. En outre, simplifier le niveau de détail des données d'entrées permet de réduire la taille d'un problème et ainsi simplifier sa résolution sans avoir à augmenter les capacités de résolution de nos ressources de calculs ou de développer une méthode de résolution plus performante. De telles simplifications sont intéressantes à considérer lorsque des niveaux de décisions stratégiques et tactiques sont en jeu. En effet, de tels problèmes ne nécessitent pas forcément un modèle qui prend en entrée des données brutes (souvent de niveau de décision opérationnelle) pour obtenir de bonnes solutions. Ces données peuvent être agrégées. Cependant, l'agrégation des données doit être choisie pour garantir des solutions exploitables par les décideurs. Enfin, les problèmes de CRL sont alimentés par différentes données (coûts et temps de transport, taille des véhicules...) et la précision de chacune de ces données impacte différemment la forme des solutions. Les simplifications apportées aux données peuvent engendrer des biais au sein des solutions proposées. Il est donc nécessaire de comprendre la façon dont chaque dimension de données impacte les variables de décisions du modèle et à quelle échelle.

En résumé, l'objectif de la thèse est d'apporter une méthodologie pour établir le bon niveau de précision des modèles de CRL, en particulier l'état d'**agrégation des**

**données d'entrées**, et d'analyser l'impact de l'agrégation sur le comportement des modèles. Enfin, la crédibilité de ces modèles doit être renforcée auprès des utilisateurs par la mise à disposition d'estimations de coût des solutions les plus précises possibles.

Pour mener à bien ce projet de recherche une convention CIFRE<sup>5</sup> a été mise en place entre le constructeur automobile Renault Group et le laboratoire GSCOP<sup>6</sup>. Nos travaux se sont déroulés au sein de la Direction Logistique Renault. Une nouvelle structure d'organisation établie en 2021 a permis la création de l'équipe Intelligence Artificielle à la Direction Logistique, regroupant les compétences en science et analyse des données, ainsi qu'en recherche opérationnelle. Cette équipe est un véritable catalyseur de projets orientés sur les données et a déjà produit de nombreux outils d'aides à la décision pour la direction.

Les trois études complémentaires suivantes ont été menées afin d'apporter des éléments quant à notre objectif :

1. La définition d'un cas d'étude (et d'un modèle), à savoir un problème tactique de conception de réseau logistique pour la distribution de véhicules, et l'analyse du modèle ;
2. L'étude de l'impact de l'agrégation de données (dimensions et niveaux) sur les solutions du modèle ;
3. Une étude de l'acceptation de notre solution par les utilisateurs, à savoir l'analyse et la réduction de l'erreur sur le coût des solutions obtenues après l'agrégation de données.

Du point de vue académique, différentes contributions scientifiques sont apportées, à savoir la définition d'un modèle original d'un problème de CRL appliqué à l'industrie automobile. Une analyse quantitative de l'influence de l'agrégation des données d'entrée sur le modèle est apportée avec en conclusion des recommandations d'agrégation pour les décideurs. Enfin, une méthode de réajustement du coût des solutions agrégées permet de pallier le biais induit sur le coût par les agrégations.

Ce manuscrit est divisé en quatre chapitres. Un chapitre de présentation du contexte et de la problématique, et trois chapitres de contributions scientifiques, correspondant à trois articles soumis dans des revues internationales.

Le **chapitre 1** présente tout d'abord le contexte industriel de l'étude. Ensuite, un état de l'art est proposé, traitant de l'impact des agrégations de données sur un modèle d'optimisation, et présentant les modèles classiques de CRL pour la distribution et plus particulièrement les modèles proches de notre cas d'étude. Enfin, la problématique et les questions de recherche sont décrites.

Le **chapitre 2** comporte la description du problème de CRL pour la distribution de véhicules. Une formulation d'un modèle de Programme Linéaire en Nombres Entiers (PLNE) est proposée et ses particularités sont analysées.

---

5. Convention Industrielle de Formation par la REcherche

6. Laboratoire des Sciences pour la Conception, l'Optimisation et la Production de Grenoble

Dans le **chapitre 3**, nous étudions l'impact de l'agrégation des données d'entrée sur le comportement de notre modèle de CRL. Des dimensions et niveaux d'agrégation sont catégorisés. Les solutions agrégées sont comparées aux solutions obtenues sans agrégation. Les éléments suivants nous permettent de qualifier la valeur des agrégations testées : la difficulté de résolution du problème et le maintien des caractéristiques des solutions.

Finalement, le **chapitre 4** contient une analyse de l'erreur d'estimation du coût des solutions obtenues par les agrégations de données. En effet, la qualité de l'estimation du coût des solutions est un facteur important pour garantir l'acceptation du modèle par les utilisateurs. Pour réduire cette erreur, nous proposons une méthode de réajustement du coût. Les résultats obtenus nous permettent de quantifier et d'expliquer les biais induits par les agrégations sur le coût des solutions dans le but d'améliorer la confiance dans le modèle proposé.

Nous concluons ce manuscrit par une synthèse de nos contributions, ainsi qu'une discussion sur les perspectives de recherche de ce travail.

Ce travail a fait l'objet des publications soumises et communications suivantes :

- Publications dans des revues internationales à comité de lecture
  - Suzanne Le Bihan, Gülgün Alpan, Bernard Penz, Multi-period multi-product network design with batch costs : a case of automotive industry.  
Soumis pour publication (2023).
  - Suzanne Le Bihan, Gülgün Alpan, Bernard Penz, A quantitative study of data aggregation for a network design problem.  
Soumis pour publication (2023).
  - Suzanne Le Bihan, Gülgün Alpan, Bernard Penz, Cost adjustment in a supply chain decision support system using aggregated input.  
Soumis pour publication (2023).
- Communication dans une conférence nationale
  - Suzanne Le Bihan, Gülgün Alpan, Bernard Penz et Grégoire Boussu. A supply chain network design problem for the RENAULT vehicle distribution.  
*Congrès annuel de la ROADEF*, Lyon, France, 2022.
  - Suzanne Le Bihan, Gülgün Alpan, Bernard Penz et Christian Serrano. Une étude quantitative de l'agrégation des données d'un modèle de Supply Chain Network Design.  
*Congrès annuel de la ROADEF*, Rennes, France, 2023.



# Chapitre 1

## Contexte et enjeux de l'étude

### 1.1 Introduction

L'objectif de ce chapitre est de présenter le contexte de ce travail de recherche. Nous décrivons, dans un premier temps, le contexte industriel de la logistique automobile du constructeur Renault Group et plus particulièrement le cas de la distribution de véhicules. Nous détaillons comment la digitalisation de la Direction Logistique du groupe a conduit à la proposition d'un sujet de recherche orienté sur les données.

Dans un deuxième temps, nous présentons un état de l'art en lien avec notre problématique de recherche. Nous commençons par décrire les différentes études que nous avons rencontrées qui analysent l'impact de l'agrégation de données d'entrée sur le comportement de modèle d'optimisation combinatoire. Ensuite, nous nous intéressons aux modélisations de Conception de réseaux logistiques (CRL) pour la distribution avec une attention particulière portée sur les modèles multipériodes. Les modèles possédant des caractéristiques similaires à notre problème tactique sont également présentés.

Enfin, nous expliquons la façon dont ce sujet s'est construit et amenons la problématique et les questions de recherches. Les contributions scientifiques sont pour finir décrites.

### 1.2 Contexte industriel

De nombreux constructeurs automobiles sont présents sur la scène internationale. Renault Group en fait partie. Nous exposons dans cette section, les principaux défis auxquels cette industrie et en particulier l'entreprise Renault Group font face. Le fonctionnement de la logistique aval pour la distribution de véhicules est ensuite détaillée. Au cours de cette sous-partie, nous évoquons différents enjeux pour la conception de cette chaîne logistique. Finalement, les outils d'aide à la décision pour la conception de réseaux logistiques n'auraient pas vu le jour sans les nouvelles capacités de stockages et d'exploitations de données dans l'industrie. C'est le développement de cette industrie 4.0 qui a mené à l'apparition de nouvelles problématiques dont celle présentée dans ce mémoire.

### 1.2.1 La logistique du constructeur Renault Group

En 2021 pas moins de 750 sites de production automobile existent dans le monde tous constructeurs confondus. Les plus grandes marques automobiles sont présentes sur le marché mondial. De plus, l'industrie automobile étant une industrie d'assemblage, les fournisseurs des constructeurs sont multiples. La dispersion des sites de productions, des fournisseurs et des sites de ventes crée des réseaux logistiques complexes, souvent à l'échelle des continents. De plus, les volumes de véhicules concernés occasionnent de formidables possibilités d'économies d'échelles. En effet, plus de 82 millions de véhicules ont été vendus en 2021 dans le monde toutes marques confondues<sup>7</sup>. La négociation avec les entreprises prestataires de transport et l'optimisation des réseaux sont donc cruciales pour que les constructeurs automobiles restent compétitifs.

Renault Group a observé la vente de près de 2,7 millions de véhicules en 2021 dont 180 mille véhicules électriques. Implanté dans plus de 130 pays, le groupe est la première marque automobile française dans le monde en 2021 et le leader historique du secteur des véhicules électriques en Europe. On trouve des sites de productions en Europe, Asie, Afrique et Amérique du Sud (voir la Figure 1.1). Le groupe contient quatre marques (Renault, Dacia, Alpine et Mobilize) et tente de tirer parti de leurs différents marchés pour optimiser ses flux. Cependant, accorder les flux des différentes marques n'est pas une tâche anodine. Par exemple, les technologies de gestion des chaînes logistiques diffèrent au sein de l'alliance Renault-Nissan-Mitsubishi, sans même considérer les divergences culturelles.

Une particularité des chaînes logistiques du groupe est qu'elles sont contractualisées à différents niveaux. Le département logistique est par conséquent fréquemment en négociation avec les sociétés prestataires de transport afin de les mettre en compétition et obtenir les meilleurs tarifs. Des outils d'aide à la décision permettent dans ce contexte de choisir les offres qui proposent les meilleures économies d'échelles en considérant les volumes des flux du groupe, mais aussi de mettre au défi les transporteurs en tentant de trouver de meilleures solutions que celles exposées par ces prestataires. Le processus de négociation est décrit dans la Section 1.2.2.

---

7. OICA 2022 <https://www.oica.net/category/sales-statistics/>

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

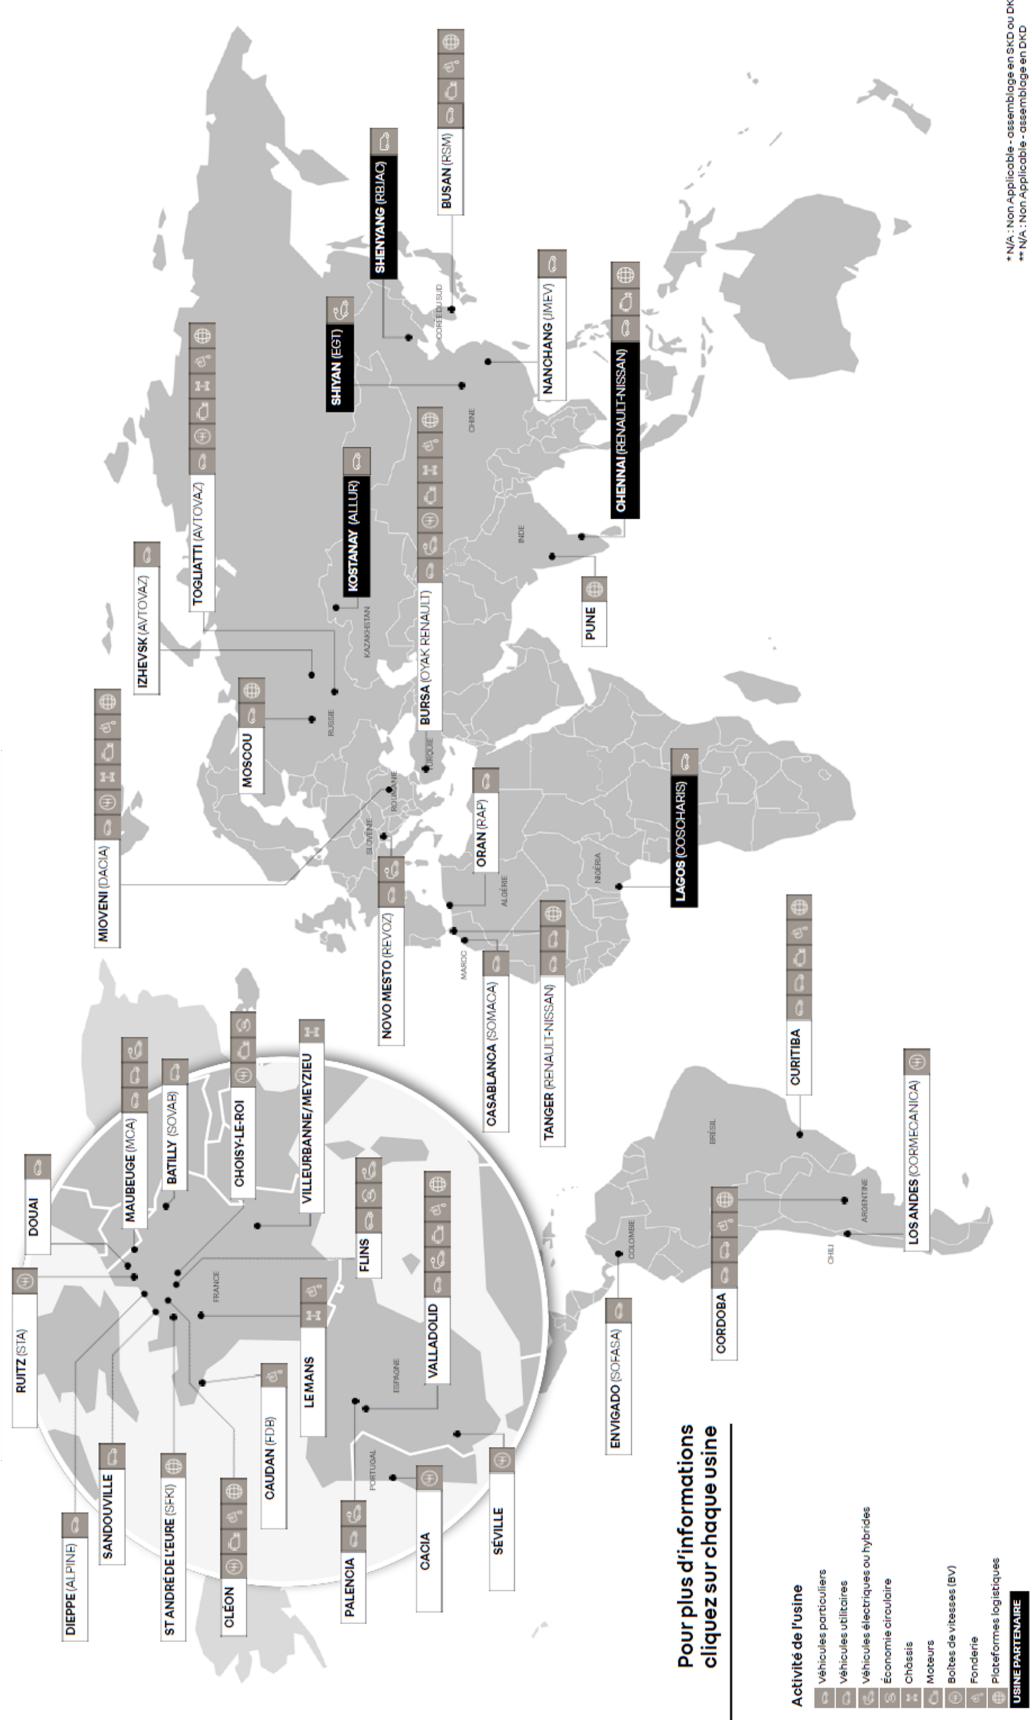


FIGURE 1.1 – Implantations industrielles de Renault Group

La chaîne logistique est aussi sujette à de nombreuses perturbations et doit à la fois être robuste et résiliente pour maintenir la compétitivité du groupe. Les normes naissantes sur la réglementation des émissions de CO<sub>2</sub> poussent à repenser les moyens de transport, d'autant plus que le groupe s'est engagé à avoir un impact neutre en CO<sub>2</sub> d'ici 2050 (2040 en Europe). Concernant la logistique, un plan d'action de réduction de 30% des émissions du transport et des plateformes logistiques d'ici 2030 est actuellement mis en application dans le cadre de la démarche FRET21<sup>8</sup>. Concrètement, cela implique de contractualiser des sociétés de prestation de transports routiers utilisant des énergies moins émettrices, déployer davantage le moyen de transport ferroviaire qui est cependant très contraignant, optimiser les kilomètres parcourus et réduire le poids des emballages de produits. La contractualisation des chaînes logistiques complexifie d'autant plus la réalisation de ces objectifs.

Les récentes crises ont aussi prouvé l'importance de l'adaptabilité des chaînes logistiques automobiles. La pandémie du Covid19 a fait chuter les ventes de véhicules pendant le confinement du printemps 2020 et a poussé à réinventer une organisation en télétravail. Suite à cela, la pénurie de composants électronique qui sévi depuis 2021 engendre encore aujourd'hui des fermetures d'usines. Enfin, les conflits en Ukraine en 2022 ont forcé le groupe à geler les activités de son usine en Russie pour finalement la nationaliser par l'Etat Russe et ainsi perdre son implantation dans ce pays.

### 1.2.2 La distribution de véhicules chez Renault Group

Avec 24 sites de production de véhicules dans le monde et 22000 points de ventes présents dans 130 pays, la distribution de véhicules est la chaîne logistique la plus étendue du groupe. C'est aussi la chaîne logistique ayant le niveau de contractualisation le plus élevé.

Concrètement la négociation des transports et de l'utilisation des plateformes logistiques se déroulent à une fréquence fixée. Les concepteurs du réseau lancent une nouvelle étude sur une région géographique de livraison lorsque les contrats précédents arrivent à leur terme. Cependant, les transports pouvant être impactés par de nombreuses perturbations à certaines périodes, les concepteurs aimeraient pouvoir lancer des négociations avant la fin de ces contrats. Par exemple, la pénurie de conducteur de camion qui sévie depuis quelques années a, en cette fin d'année 2022, des répercussions importantes sur les coûts de transport, et engendre également des saturations de la capacité de plateformes logistiques. Il serait bénéfique pour les deux parties (constructeur automobile et transporteur) de revoir la négociation des contrats en prenant en compte les risques sur les capacités de transport actuelles.

Chaque négociation passe par plusieurs phases d'échanges d'information entre les deux parties. Ces informations s'affinent au cours du processus de négociation. Dans une première phase, les concepteurs du réseau du constructeur automobile mettent à jour les plateformes logistiques existantes qui sont géographiquement potentiellement intéressantes pour livrer la région en question, puis mettent à jour les sections de

---

8. Label officiel des donneurs d'ordres pour une logistique écoresponsable

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

---

routes et éliminent celles qui semblent aberrantes. Le coût de transport étant largement supérieur au coût d'utilisation des plateformes, la négociation se focalise surtout sur l'optimisation de l'utilisation des routes. Une étude est faite pour sélectionner les routes les plus intéressantes pour satisfaire les demandes et estimer un coût de transport. Les demandes à l'année sur chaque section sont partagées à différentes sociétés prestataires de transport pour mettre leurs solutions tarifaires en concurrence. Cette étape est importante, car la connaissance sur les volumes transportés permet aux transporteurs de proposer des tarifs plus intéressants sur les flux où la demande est conséquente, notamment des flux directs. Dans une deuxième phase, les transporteurs fournissent leurs tarifs et délais de livraison. Les concepteurs réalisent une deuxième étude en prenant en compte les nouveaux coûts des fournisseurs pour sélectionner les routes les plus intéressantes. La liste des sections et routes est ainsi affinée. Finalement, lors d'une troisième phase, une proposition de tarification plus précise est demandée aux transporteurs sélectionnés. Les transporteurs s'engagent sur les tarifs et les temps de transport proposés, ainsi que sur les quantités que peuvent contenir chaque transport (information validée par le constructeur automobile). Le constructeur automobile s'engage de son côté à envoyer des volumes minimum sur certaines des routes principales.

Sur un second plan, des processus similaires sont appliqués pour négocier les coûts d'ouverture et d'utilisation des plateformes logistiques. Des coûts de passages par les plateformes logistiques, pour de simples répartitions de véhicules dans des moyens de transport, sont négociés en fonction de la quantité de flux de véhicules qui y transite. De plus, un coût et une capacité de stockage sont aussi négociés dans le cas où certains véhicules devraient attendre le prochain départ d'un moyen de transport ou dans le cas de plateforme logistique tampon à proximité de zones de livraisons.

Les différentes phases du processus de négociation peuvent être appuyées par un modèle de CRL. Cependant, les niveaux de détail des modèles ne sont pas les mêmes pour chaque phase. En effet, les premières phases brassent des informations beaucoup plus larges et imprécises. Elles contiennent donc des problèmes plus grands et plus durs à résoudre, mais elles ne nécessitent pas le même niveau de détail que les suivantes. Dans ce contexte, un modèle simple avec des données simplifiées pourrait mieux convenir. Il serait donc bénéfique d'adapter à chaque phase de négociation le choix du niveau de détail des données d'entrée des modèles utilisés.

Notre étude se concentre sur la dernière phase du processus, lorsque les coûts de transports finaux sont précisés et que l'on souhaite minimiser les coûts de transports en utilisant ce nouveau réseau. Les entreprises prestataires de transport optimisent les flux avec les demandes réelles du groupe et celles du reste de son marché en limitant au maximum leurs retours à vide. Un camion doit théoriquement réaliser des allers-retours sur une section de route. Du point de vue de Renault, les retours sont des retours à vide.

Le réseau négocié peut comporter des flux routiers, des flux maritimes et des flux ferroviaires. Ces flux contiennent les véhicules produits dans des usines à destination des concessions automobiles. Chaque usine approvisionne un Centre Livreur Expéditeur (CLE) en véhicules. Un véhicule peut ensuite aller directement à une concession

présente dans une Zone Géographique (ZG) ou passer par un ou plusieurs Centre Intermédiaire (CI). La dernière plateforme logistique traversée avant d'atteindre une concession est un Centre de Distribution Capillaire (CDC). La Figure 1.2 montre les types de flux et les différentes plateformes logistiques présents dans le réseau aval.

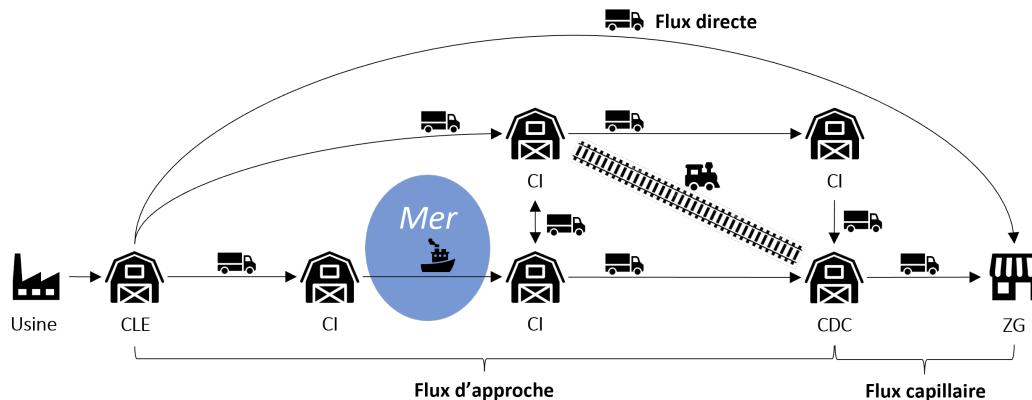


FIGURE 1.2 – Flux et plateformes logistiques

### 1.2.2.1 Les plateformes logistiques

Un CLE est un centre tampon dédié au stockage des véhicules en sortie d'usine en attente de la prise en charge par un transporteur. Il existe donc un CLE par usine et celui-ci est généralement à proximité de son usine pour limiter les transports en sortie de chaîne de production. Les coûts de maintenance et de stockage de ces centres sont bien moindres que ceux des autres plateformes logistiques, car les CLE sont gérés par le groupe. Il n'est donc pas rare que des véhicules y soient stockés notamment pour densifier des départs de flux. Le dédouanement des véhicules à destination de pays étrangers peut se faire dès le passage dans ces centres.

Un CI est une plateforme logistique gérée par un sous-traitant, dans laquelle il est possible de faire transiter ou réorganiser la répartition de véhicules dans des moyens de transport. Ils n'ont pas pour vocation de supporter des stocks sur le long terme mais uniquement le stockage nécessaire pour la bonne densification des flux dans des moyens de transport. Les coûts de passages sont composés principalement de la manutention des véhicules.

Les CI basés sur une zone portuaire ont des modes de fonctionnement particuliers. Ils font généralement le lien entre un transport routier et un transport maritime. Leur coût de passage est composé de la manutention des véhicules pour changer leur moyen de transport et souvent du dédouanement des véhicules, car ce sont des lieux de stockage en amont ou aval de routes internationales. Les coûts de stockage y sont relativement bas. En effet, un stock de véhicule peut rapidement s'accumuler dans un port en raison de la fréquence des transports maritimes qui est plus basse que celle des transports routiers, d'autant plus pour les transports maritimes de longue distance. Pour rester concurrentiel face au transport terrestre et pallier aux temps de stockages importants aux ports, les coûts de stockage y sont plus bas que dans d'autres plateformes logistiques.

Certains véhicules doivent nécessairement passer par un sous-groupe de centres avant d'atteindre leur destination finale. Nous y reviendrons plus en détail dans les paragraphes sur les types de flux et gestion des demandes. Ces centres sont appelés CDC car ce sont les derniers centres visités avant de réaliser les tournées finales de camions vers les concessions automobiles. Ce sont des plateformes logistiques gérées par des sous-traitants. Ces centres peuvent servir de stockage à plus long terme. Ainsi, il n'est pas rare que les premiers jours de stockages n'y soient pas facturés. Les coûts de passage et de stockages sont sensiblement les mêmes que dans un CI, mis à part que certaines prestations supplémentaires peuvent y être chargées, comme la préparation ou le dédouanement de véhicule avant l'arrivée au concessionnaire.

Afin de simplifier les négociations avec les sociétés prestataires de transport lors de la conception globale du réseau, les concessions automobiles sont agrégées en ZG. Une tournée vers les concessions d'une ZG est tarifée et considérée lors de l'optimisation du réseau comme un aller-retour d'un centre vers une ZG. Ainsi, les sections de transport vers ces zones sont organisées comme pour les autres flux. C'est-à-dire que du point de vue de Renault Group, une section vers une ZG est empruntée par des camions qui réalisent des allers-retours (retours à vide). Les tournées de camions vers les concessions sont en réalité organisées par les entreprises prestataires de transport. Pour donner une idée de la superficie de ces zones, en France un département représente une ZG.

### 1.2.2.2 Les moyens de transports

Le transport routier est très largement utilisé, notamment puisque c'est le seul moyen de transport qui permet d'atteindre certaines plateformes de stockage et la plupart des concessions automobiles. Environ 2000 camions par jour sont utilisés pour livrer les véhicules du groupe. Les tarifs négociés sur chaque section de route sont chargés par camion entier. Ces tarifs dépendent majoritairement du temps de transport, des normes salariales, de la réglementation sur les dimensions des camions et du prix du fuel des pays traversés, et évidemment de la quantité de camions qui doit être utilisée sur la section. Le temps de transport dépend des caractéristiques géographiques de la région, des normes concernant les pauses du chauffeur et de la distance à effectuer. Un autre facteur impactant les négociations est la compatibilité du flux avec les autres demandes du marché qui permettent aux entreprises prestataires de transport de limiter les retours à vide. C'est notamment à cause de ce facteur qu'il est difficile de prédire la tarification d'une section. Un autre facteur à négocier est le nombre de véhicules que peuvent contenir les camions. Des tests sont réalisés par les deux parties (Renault Group et le(s) transporteur(s)) pour négocier les meilleures combinaisons de véhicules pour remplir un camion. Les combinaisons de véhicules dans les camions sont contraintes par les régulations des pays traversés comme la hauteur, la longueur et le poids du camion (voir le test de remplissage de la Figure 1.3). Enfin, le poids transporté pouvant affecter la consommation de carburant des camions, il est nécessaire de négocier le tarif du transport en même temps que le remplissage des camions.



FIGURE 1.3 – Exemple de remplissage d'un camion dans le cadre d'une négociation avec un transporteur

Le transport maritime est notamment utilisé pour les transports internationaux. Une partie des usines se trouvant au Maroc et en Turquie et le marché européen étant le premier marché du groupe, le transport maritime est largement employé pour traverser la mer Méditerranée. Ces transports ont lieu à une fréquence moins élevée que les transports routiers, puisqu'un bateau possède une plus grande capacité de transport et se remplit avec le reste de la demande du marché. Cette fréquence est plus élevée pour les trajets de courte distance (en mer par exemple). Le coût de transport maritime dépend majoritairement de la consommation de carburant du bateau, du salaire des employés du transporteur et d'un coût fixe d'utilisation de ports. La taille du bateau impacte la consommation et la capacité du bateau ainsi que le salaire des employés. Le temps de traversée impacte la consommation du bateau et le salaire des employés. Ce temps peut très largement varier car le bateau peut faire divers arrêts pour récupérer ou livrer d'autres produits. Chaque arrêt engendre un temps d'attente conséquent. Ce temps d'attente dépend aussi du caractère court ou longue distance de la route à parcourir par le bateau. En résumé, il existe de fortes variations du coût et de la capacité de transport maritime à cause notamment de l'incertitude sur la demande du marché. Des coûts et capacités de transports doivent être négociés avec le transporteur.

Le transport ferroviaire est assez peu utilisé et se concentre sur des sections stratégiques à fortes demandes. Les transports ferroviaires sont négociés au cas par cas parce qu'ils sont soumis à de fortes contraintes. Un nombre de wagons est facturé. Cependant, les arrêts supplémentaires pour compléter un train avec d'autres produits (Renault Group ou autre) engendrent des coûts de gardiennage très importants afin de garantir la sécurité des véhicules présents dans les wagons. Il est donc dans la pratique plus intéressant de payer un train entier que de payer les frais de gardiennage pour des arrêts supplémentaires permettant d'inclure d'autres wagons avec d'autres produits. En résumé, le coût de transport ferroviaire contient les coûts de manutention des véhicules, des infrastructures (sections et terminaux) et des wagons, de la consommation de fuel et la marge du transporteur.

#### 1.2.2.3 Les types de flux

Comme évoqué dans la section sur les plateformes logistiques, il existe plusieurs types de flux. Un véhicule peut aller d'un CLE vers une ZG avec un flux direct. Dans le cas contraire, ce véhicule va d'abord utiliser un flux d'approche en passant par des CI ou non. Le flux d'approche se termine à l'arrivée à un CDC. Enfin, ce véhicule est

amené à sa ZG finale via un flux capillaire.

Il est possible de réaliser des flux directs entre un CLE et une ZG. Souvent un transporteur demande que ces flux directs soient empruntés par des volumes minimaux de véhicules par semaine. Dans ce cas, il est intéressant d'essayer d'optimiser les regroupements des concessions automobiles dans des ZG afin de maximiser le nombre de flux respectant la contrainte de volumes minimum pour l'ouverture d'un flux direct. Évidemment, la possibilité de flux directs dépend aussi des contraintes géographiques du terrain (par exemple la présence d'un océan ou une mer entre un CLE et une ZG).

Tous les flux entre les CLE et CDC sont considérés comme des flux d'approche. Ces flux consistent à amener les véhicules à une plateforme logistique (CDC) à proximité de son lieu de livraison final. Ce sont les flux les plus denses, car on compte moins de CDC que de ZG et évidemment bien moins que de concessions automobiles. Ce sont les principaux types de flux qui peuvent comporter des moyens de transport maritime ou ferroviaire. Dans le cadre de la décarbonation de la chaîne logistique, de nombreux sujets de comparaison de coût de transports routier et ferroviaire voient le jour concernant certains flux d'approche. En effet, même si le transport ferroviaire est plus contraignant, lorsque les volumes concernés sont suffisants, il peut être autant, voir plus avantageux, que le transport routier. Dans le cas où il ne l'est pas, la perte de gains est confrontée aux économies sur les émissions de CO<sub>2</sub>.

Un flux entre un CDC et une ZG sont appelés flux capillaires. Leur nom découle du fait qu'ils délivrent de nombreux points de ventes. Les flux indirects étant d'abord condensés dans des flux d'approches pour ensuite exploser dans des flux capillaires beaucoup moins denses, on observe une forme de réseau en étoile au départ des CLE. Normalement, les flux capillaires sont des flux routiers, puisqu'ils permettent d'atteindre les concessions automobiles. Cependant, à cause de l'organisation du regroupement des concessions en ZG, il existe des cas particuliers où un flux capillaire peut être transporté par voie maritime. Dans le cas où une ZG est sur une île et que cette île est approvisionnée par un CDC sur un continent, le transport est considéré comme mixte maritime et routier. La thèse de doctorat de Kchaou-Boujelben (2013) contient une analyse de la chaîne logistique aval et notamment des flux capillaires de Renault Group. Elle remet en cause l'organisation des ZG par département et propose une nouvelle structure dans laquelle les tournées de camions vers les concessions sont optimisées avec une heuristique hiérarchique. Cela permet de quantifier les gains que peut apporter la création de regroupements de concessionnaires plus complexes. Mais ces résultats permettent aussi de mettre au défi les sociétés prestataires de transports, si les solutions trouvées sont plus performantes que celles proposées.

### 1.2.2.4 La gestion des demandes

Il existe deux modes de production pour répondre aux demandes de véhicules : produit à la demande (PD) et produit pour stock (PS). La proportion de demandes satisfaites en PD est généralement supérieure à celle de demandes satisfaites en PS, cependant ce rapport varie très fortement selon l'année, le pays de destination, le modèle de véhicule et surtout la demande.

Les demandes issues de commandes déjà réalisées par une concession automobile connue sont gérées en PD. Ces demandes ne sont pas destinées à être stockées avant leur arrivée à leur concession, sauf dans le cas d'attente d'un moyen de transport ou de son remplissage. La ZG est donc connue avant la sortie d'usine et aucun stockage de proximité n'est demandé par la concession automobile. Ce type de demande est le seul qui peut être transporté par flux direct pour des raisons fiscales. En effet, le dédouanement peut être directement réalisé au CLE si l'usine de départ et la ZG destinataire sont dans des pays différents.

Les produits gérés en PS doivent être stockés à un CDC avant livraison finale en concession. Plusieurs raisons peuvent donner lieu à de tels stockages. Un véhicule peut être approché dans une zone sans que le concessionnaire final ne soit connu afin de réduire les délais de livraison. Dans ce cas de figure, une demande gérée en PS est perçue comme une précommande réalisée par un groupe de concessionnaire sur une région (qui comporte généralement plusieurs ZG) afin de réduire les délais de livraison. Dans les études de conception de réseaux, la position du CDC est optimisée grâce à des outils de prédiction de la demande finale basés sur un historique. De cette façon, les coûts de livraison finaux peuvent être minimisés en choisissant le CDC le plus proche des ZG probablement plus consommatrices. Un concessionnaire peut également faire une demande de stockage en CDC car il n'a pas la capacité de le faire sur place. C'est un deuxième cas de figure traité comme une demande satisfaite en PS lors de la conception du réseau de distribution. Tout produit géré en PS, s'il est destiné à un autre pays que celui de son usine de départ, est sujet à des contraintes fiscales. En effet, ces demandes ne peuvent pas être stockées dans un autre pays que leur pays de destination. Par conséquent, le CDC dans lequel cette demande est stockée doit respecter cette condition.

### **1.2.3 Le problème tactique de conception du réseau de distribution**

Le problème tactique de la distribution de véhicules est un « Network Design Problem (NDP) » multipériode et multiproduct. L'objectif est d'optimiser et planifier le flux de véhicules des usines jusqu'aux concessions en satisfaisant la demande et minimisant le coût total de la solution. Les coûts compris sont des coûts de transport, de passage et de stockage. La formulation du coût de transport représente à la fois l'originalité du problème et la source de la difficulté de sa résolution. Un transport est soit routier soit maritime. Dans le cas, d'un transport maritime, le coût est dû par véhicule transporté. Pour un transport routier, le coût est dû par camion. Le nombre de camions est estimé par le nombre de chaque de type de véhicule et le taux de remplissage d'un camion moyen par ces types de véhicule. Nous appelons cette formulation particulière un coût par lot.

### 1.2.4 L'arrivée des problématiques orientées données

La digitalisation des processus du groupe s'est énormément développée en quelques décennies. Les enjeux de la digitalisation sont l'amélioration de la connectivité des entités du groupe, des capacités de calcul, de la centralisation et mise à disposition des données et de la cybersécurité. Plus particulièrement la digitalisation de la chaîne logistique automobile doit permettre d'étendre son réseau logistique mondialement, d'améliorer la visibilité du terrain, de standardiser et automatiser les processus, de se rapprocher des autres parties prenantes (transporteur, fournisseur...), d'augmenter sa résilience et de favoriser l'innovation à travers l'implémentation de nouvelles technologies (Farahani et al., 2017). L'alliance entre Renault et Nissan en 1999 n'aurait pas pu aussi bien tirer profit des synergies entre les deux groupes sans la globalisation des systèmes permise par la digitalisation.

La création de la « Digital Factory » en 2011, un pôle de compétence digitale, représente une avancée majeure en termes d'innovation. En interne, la création de réseaux sociaux du groupe et de plateformes de formation en ligne en 2013 a grandement participé à la connectivité, à la sensibilisation du personnel aux nouvelles technologies et au développement des compétences informatiques. La mise en place d'une organisation agile à partir de 2016 a permis de standardiser et accélérer le déploiement de projets. L'objectif de cette transformation digitale était de recueillir et exploiter des données en temps réel, simplifier les outils et réaliser des prédictions. Plus récemment, l'hyperconnectivité du groupe a permis au collaborateur de passer d'un mode de travail en présentiel avec des jours de télétravail occasionnels à une organisation à 100% en distanciel (à l'exception des lignes de production) du jour au lendemain à l'annonce du confinement national de mars 2020 pendant la pandémie du Covid19.

#### 1.2.4.1 La centralisation et la standardisation des données

Aujourd'hui, à la direction logistique, l'ensemble des données a été centralisé et stockée en ligne dans des serveurs. Suite à ce déploiement, plus de 200 outils d'analyses et gestion de données appuyant les décisions de la logistique au quotidien ont pu être mis en place. La récente création d'une équipe regroupant des compétences en science et gestion des données ainsi qu'en recherche opérationnelle favorise l'injection de nouvelles informations dans les serveurs qui centralisent les données et la création de nombreux outils d'aide à la décision. L'accès et l'analyse des données ainsi facilités permettent par exemple de minimiser les pertes de profits liées à la pénurie de composants électroniques actuelle. La centralisation des données profite donc à l'amélioration de la résilience de la chaîne logistique. De plus trois des objectifs de la direction logistique de 2021 ont pu être atteints concernant la réduction du temps de livraison véhicule, des stocks de véhicules et de rejet de CO<sub>2</sub>, en grande partie grâce à l'accès aux informations du terrain en temps réel. Les prochains défis consistent à associer les données de la logistique avec celles des autres directions comme le commerce afin de créer des outils d'aide à la décision prenant en compte des besoins complémentaires.

### 1.2.4.2 La problématique d'agrégation des données

Dans ce contexte, de nombreux outils d'aide à la décision qui sont alimentés par ces données voient le jour. Cependant, les données recueillies sont des données brutes qu'il faut souvent retravailler avant de pouvoir les exploiter dans ces outils. Il est probable que certaines données soient uniquement disponibles à un niveau de détail opérationnel. Or, de nombreuses décisions de niveaux moyen et long terme ont aussi besoin d'être appuyées par des outils d'aide à la décision. Utiliser les données disponibles avec leur niveau de détail d'origine peut mener à des problèmes trop grands que l'on ne peut pas résoudre avec les capacités de calcul à disposition. Il est possible d'obtenir des problèmes plus petits et donc plus faciles à résoudre en agrégeant les données d'entrées de ce problème. Cependant, cette action peut avoir un impact sur la précision des résultats. Un compromis doit être trouvé entre la précision et la difficulté de résolution du problème (voir Figure 1.4). C'est pour cela que des problématiques telles que le choix du niveau d'agrégation des données en concordance avec le caractère global des décisions ont commencé à apparaître. En l'occurrence, la conception de réseaux logistiques soulève typiquement ce genre de questions. En effet, l'optimisation de la conception d'un réseau concerne souvent des problèmes de grande taille avec des contraintes industrielles complexes. De ce fait, de la même manière qu'il faut définir le niveau de détail d'un modèle lors de son développement, s'intéresser à l'impact de l'agrégation des données sur la précision des résultats est tout aussi fondamental. Les travaux de recherche menés lors de cette thèse s'insèrent dans cette problématique d'agrégation des données.

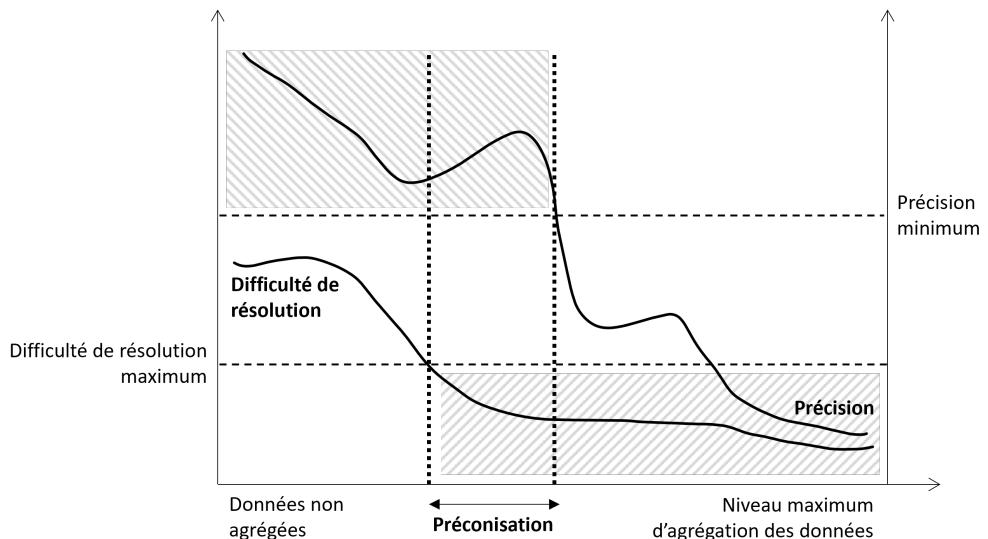


FIGURE 1.4 – Le compromis entre la précision et la difficulté de résolution d'un modèle lors de l'agrégation de données d'entrées

## 1.3 État de l'art

Dans cette section, nous proposons un état de l'art des publications en lien avec notre problématique de recherche. Dans un premier temps, nous nous intéressons à

l'impact de l'agrégation des données d'entrée sur les modèles d'optimisation combinatoire dans la littérature. L'agrégation de données d'entrée peut engendrer des biais dans un modèle et par conséquent impacter la confiance des utilisateurs envers le modèle. Pour cette raison, nous évoquons dans un second temps la littérature concernant l'acceptation des outils d'aide à la décision basés sur un modèle d'optimisation. Enfin, nos études quantitatives sont réalisées sur un problème tactique multipériode et multiproduit de conception de réseau. Dans un troisième temps, nous présentons donc les articles traitant de CRL et plus particulièrement les modèles comportant des similitudes avec notre cas d'étude.

### 1.3.1 L'agrégation de données pour les modèles d'optimisation

L'étude de l'impact de l'agrégation de données d'entrée sur le comportement d'un modèle apparaît dans plusieurs domaines de recherche. Nous présentons les différents domaines qui considèrent naturellement l'agrégation de données et détaillons un peu plus les études comportant des modèles de conception et planification de réseaux logistiques.

#### 1.3.1.1 L'agrégation de données

Suite au développement de la récupération et de la mise à disposition massive de données, la question de l'exploitation de ces données émerge. Or, l'agrégation est une pratique à forts enjeux pour exploiter des données. Un exemple très présent dans la littérature est l'utilisation de séries chronologiques. L'analyse de ces séries diffère selon le niveau temporel d'agrégation de ces dernières. Granger & Siklos (1995) propose une étude fondatrice sur cette problématique. Les applications sont dès lors multiples : prévision de demandes, modèles de croissance économique, traitement analytique en ligne, réseau de capteurs. Nous ajoutons à cette liste le « Energy System Model » qui est aujourd'hui incontournable pour la transition énergétique. Par exemple, Hoffmann et al. (2022) proposent une des études les plus récentes sur une méthode performante pour agréger temporellement ces modèles. Holz et al. (2020) rassemblent dans une revue de la littérature les études sur le choix du niveau d'agrégation temporelle et spatiale pour ces modèles. Suite à ces observations, nous nous étonnons du manque d'études dédiées à l'analyse de l'impact d'agrégations temporelles sur les modèles d'optimisation combinatoire multipériode. Azaiez (2009) conceptualise la notion d'agrégation et propose une série de cas d'applications dans lesquels ils déterminent si une agrégation parfaite est possible (i.e. une agrégation permettant d'obtenir les mêmes décisions qu'avec les données non agrégées).

#### 1.3.1.2 L'agrégation de données pour les modèles d'optimisation

Nous avons recensé un certain nombre de modèles d'optimisation combinatoire auxquels ont été appliquées des agrégations afin de réduire la taille de ces derniers.

L'agrégation de types de produit est assez caractéristique des problèmes de CRL étant donné qu'ils impliquent le transport de marchandises. À notre connaissance, Geoffrion (1977) analyse l'impact de l'agrégation de types de produit sur un problème

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

---

de planification logistique. Kazemi et al. (2021) proposent une agrégation partielle des types de produit sur une sous-partie du réseau pour limiter l'impact d'une agrégation complète sur les résultats d'un problème de CRL possédant des coûts fixes d'ouverture de section.

Des agrégations spatiales (agrégation d'entités géographiques) ont été appliquées au « Covering Problem » (Jang & Lee, 2015), au « Traveling Salesman Problem » (Campbell, 2006) et à de nombreux problèmes de localisation. La revue de littérature proposée par Francis et al. (2009) contient les études de l'erreur induite par l'agrégation spatiale de données d'entrée sur des modèles de localisation. La Table 1.1 recense les autres articles étudiant l'impact d'agrégations spatiales sur des problèmes de CRL.

L'étude de l'impact d'agrégations temporelles (agrégation de périodes) est naturellement appliquée aux problèmes de planification comme les problèmes de « Production Planning » (Jain & Palekar, 2005) et de « Forest Planning » (Andersson & Eriksson, 2007).

	Complexité		Dimension d'agrégation			Application industrielle
	Produit	Période	Type de produit	Spatiale	Temporelle	
Cette étude	multi	multi	*	*	*	industrie automobile
Geoffrion (1977)	multi	mono	*			
Zipkin (1982)	mono	mono		*		
Mulvey & Vladimirov (1991)	mono	multi			*	
Horner & O'Kelly (2005)	mono	mono			*	
Francis et al. (2009)	mono	mono			*	
Gavriliouk (2009)	mono	mono			*	
Qi & Shen (2010)	mono	mono			*	
Klibi et al. (2016)	mono	multi			*	
Cebecauer & Buzna (2017)	mono	mono			*	
Ansari et al. (2018)	multi	multi			*	
Kazemi et al. (2021)	multi	mono	*			

TABLE 1.1 – L'agrégation pour des modèles de CRL

Nous avons rencontré d'autres dimensions d'agrégations adaptées à certains modèles d'optimisation. L'optimisation stochastique se prête à l'agrégation de scénarios. Medina-Gonzalez et al. (2020) cherchent à diminuer la taille d'un modèle de flux stochastique en réduisant le nombre de scénarios en entrée sans impacter les solutions. Pour cela, ils déterminent des scénarios types représentatifs de l'ensemble des scénarios

originaux.

Les problèmes d'ordonnancement de grande taille peuvent contenir un nombre très important de tâches à planifier. Certains chercheurs se sont donc penchés sur la question de l'agrégation de tâches en tâches globales. Ce type d'agrégation implique l'agrégation de périodes et de ressources ou d'opérations de façon corrélée. Váncza et al. (2004) réalisent une telle étude dans le but d'intégrer l'ordonnancement à la planification de la production. Fan et al. (2022) agrègent également les tâches d'un modèle d'ordonnancement appliqué à un réseau de satellite.

En conclusion, dans la littérature on peut trouver plusieurs études qui quantifient l'impact de l'agrégation des données d'entrées sur un modèle de CRL, ainsi que sur d'autres types de modèles typiquement de grande taille qui se prêtent aussi à l'agrégation. Les agrégations spatiales ont largement été étudiées. Cependant, les agrégations de produits ne sont que très peu considérées. De façon encore plus surprenante, nous n'avons pas trouvé de littérature sur l'impact d'agrégations temporelles malgré leur intérêt montré dans de multiples études de l'impact de l'agrégation de séries temporelles sur l'analyse de ces dernières. De plus, les études confrontant différentes dimensions d'agrégations sont rares. Nous cherchons donc à combler ce manque en confrontant trois dimensions d'agrégations et en analysant leurs différents impacts sur le comportement de notre modèle.

### 1.3.2 L'acceptation d'un modèle par les utilisateurs

L'acceptation de l'Technologie de l'Information (TI) a été largement étudiée dans la littérature, puisqu'elle assure un retour sur investissement concernant l'implémentation de nouvelles technologies au sein d'une entreprise. La première modélisation du comportement d'utilisateurs face à une technologie nouvelle a été définie par Davis et al. (1989) et Davis (1989). Le « Technology Acceptance Model » est le modèle le plus présent dans la littérature. Il prend en compte l'**utilité perçue** et la **facilité d'utilisation** comme paramètres. Le degré auquel une personne estime que l'utilisation d'une TI peut améliorer ses performances dans le cadre de ses missions définit l'utilité perçue de ce système (Davis, 1989).

Par la suite, de nombreuses études enrichissent ce modèle d'acceptation avec d'autres aspects. Taylor & Todd (1995) définissent le « Theory of Planned Behaviour », qui décompose plus finement les facteurs impactant le comportement des utilisateurs. On voit apparaître par exemple la **complexité perçue** comme facteur influençant l'acceptation. Bajaj & Nidumolu (1998) prouvent que l'usage antérieur d'une TI influence son acceptation en comparant trois modèles distincts. Venkatesh & Davis (2000) introduisent le « Social Cognitive Theory », une extension du « Technology Acceptance Model » dans laquelle la volonté d'utilisation est définie terme d'influence sociale. Les résultats montrent notamment que la **qualité et démontrabilité des résultats** ainsi que la **facilité d'utilisation** jouent un rôle décisif. Une revue des différentes théories jusqu'à 2003 est proposée par Venkatesh et al. (2003), ainsi que la définition du « Unified Theory of Acceptance and Use of Technology ». Ce modèle est une composition de plusieurs modèles dans lequel les facteurs suivants entrent

principalement en jeu : la performance attendue, l'effort d'utilisation et l'influence sociale. Ils confirment avec cette dernière théorie que la performance attendue est un critère prédominant pour l'acceptation d'une TI. Ensuite, Renaud & Van Biljon (2008) considèrent un nouveau « Technology Acceptance Model » destinée à une population âgée d'utilisateurs.

Les outils d'aide à la décision, qualifiés dans la littérature de Système d'Aide à la Décision (SAD), représentent un type d'TI particulier. Les théories sur l'acceptation de SAD se basent sur les mêmes modèles que pour l'acceptation d'TI. Lu et al. (2001) montrent que la volonté d'utiliser un SAD est une fonction du style cognitif, des croyances et de l'attitude de l'utilisateur. Leur résultat principal est que la probabilité qu'un utilisateur veuille utiliser un modèle mathématique dépend des préférences et de l'utilité perçue plutôt que de la facilité d'utilisation du modèle. Beynon et al. (2002) se concentrent sur la façon dont l'utilisateur interagit avec le SAD. Leur motivation réside dans le fait que, malgré la progression du nombre de SAD et leur amélioration, la question de leur usage n'a pas été assez considérée. Gönül et al. (2006) discutent du rôle de la durée et de la qualité d'explication en amont dans l'acceptation d'un SAD. Jeng & Tzeng (2012) considèrent le secteur médical et remettent en cause l'influence sociale sur l'utilisation de SAD affirmée par l'« Unified Theory of Acceptance and Use of Technology ». Les études montrant le rôle de la qualité de l'implémentation d'un SAD dans son acceptation sont nombreuses. Par exemple, on trouve des applications destinées aux pays en voie de développement (Elbeltagi et al., 2005) (Dulcic et al., 2012), pour l'industrie agricole (Mackrell et al., 2009) et la médecine (Shibl et al., 2013).

Concentrons-nous sur le cas du SAD basé sur un modèle. Power & Sharda (2007) donnent une revue de la littérature de la recherche et applications dans ce domaine et discutent notamment du cas particulier des modèles basés sur l'optimisation combinatoire. Selon cette étude, la recherche se focalise surtout sur la performance technique de leur résolution plutôt qu'au comportement des utilisateurs. Or, le déploiement de modèles dans l'industrie bénéficierait grandement d'avancées dans ce domaine. La notion de **transparence quant à l'incertitude** des résultats est mentionnée comme un des aspects principaux impactant l'acceptation d'un modèle. En ce qui concerne les exemples d'applications dans ce domaine, Kayande et al. (2009) exposent un cas d'acceptation d'un modèle pour l'industrie agricole.

Concernant le cas des modèles de CRL, nous nous référons à Reich et al. (2019). Ils considèrent que **l'incertitude et l'instabilité** sont des enjeux importants pour l'acceptabilité de tels SAD, car ils peuvent amener les utilisateurs à penser que le modèle est obsolète ou inefficace. La revue de littérature proposée par Keenan & Jankowski (2019) mentionne exclusivement les SAD pour les décisions impactant des aspects géographiques. Ce domaine est fortement corrélé aux modélisations de CRL, car ces modèles comportent majoritairement des caractéristiques géographiques.

En conclusion, agir sur l'incertitude des résultats d'un modèle est un facteur de performance influent sur la confiance envers un SAD et ce notamment pour les modèles de conception de réseaux. Dans notre étude, nous réalisons des agrégations de données

d'entrée sur un modèle de CRL. Or, l'agrégation de données peut réduire la précision d'un modèle. C'est une raison supplémentaire qui pourrait amener les utilisateurs à penser que l'incertitude et l'instabilité des résultats proposés par le modèle sont d'autant plus fortes. Dans ce sens, il est crucial de quantifier l'impact de ces agrégations sur ces facteurs pour qu'ils ne dégradent pas la confiance des utilisateurs envers le SAD (voir **Chapitre 3** et **Chapitre 4**).

En dehors de la performance, notons également l'influence de la facilité d'utilisation d'un SAD en tant que facteur d'acceptation d'un outil. Dans notre cas où nous appliquons des agrégations sur un modèle, la facilité d'utilisation passe aussi par la compréhension de la forme des données d'entrée. En effet, l'agrégation peut faciliter la récupération de données, tout comme elle peut dégrader leur sens physique et donc leur acceptation par les utilisateurs. Cela doit être pris en compte dans nos recommandations industrielles. Finalement, la facilité d'utilisation réside aussi dans la simplicité des méthodes de résolution proposées. Cet aspect influence (avec la performance) le choix de la méthode proposée (voir **Chapitre 4**).

### 1.3.3 Conception de réseaux logistiques - problèmes stratégiques

Le problème de CRL est un problème aspirant à guider la prise de décisions pour l'ouverture de centres et routes du moyen au long terme. Chopra (2003) et Ambrosino & Scutellà (2005) proposent des revues de la littérature traitant du problème de CRL pour la distribution. Dans cette seconde revue, les objectifs du problème de CRL sont énumérés : (1) localiser des plateformes logistiques, (2) allouer des clients à des plateformes logistiques, (3) organiser les tournées de transport et (4) planifier le stockage de produits.

Min & Zhou (2002) proposent une revue de la littérature sur les modèles de CRL. Il existe plusieurs sous-formalisations du problème de CRL. Nous ne considérons pas les problèmes qui optimisent les tournées de transport car notre étude quantitative ne s'y intéresse pas. Plus particulièrement, nous nous intéressons aux deux problèmes les plus mentionnés dans la littérature en tant que problème de CRL à savoir les sous-problèmes suivants : le « Facility Location Problem (FLP) » et le « Hub Location Problem (HLP) ». Meixell & Gargeya (2005) et Melo et al. (2009) considèrent que le FLP est un problème de CRL, dans lequel il existe un ordre d'utilisation des entités géographiques du réseau (par exemple : usine - plateforme logistique - client). Arabani & Farahani (2012) décrivent le HLP en tant que FLP ayant une structure en réseau, tandis que Klose & Drexl (2005) parlent de FLP particulier.

Les problèmes de CRL sont souvent difficiles à résoudre, car ils combinent la formulation de contraintes et objectifs à la fois de niveaux tactique et stratégique. Il n'est pas rare dans la pratique que ces différents niveaux de décisions soient corrélés. Ces particularités sont souvent recherchées dans des applications industrielles. Nous avons exclu de cet état de l'art, les articles traitant de problèmes de CRL robustes (stochastique, optimisation sous-incertitude), car nous ne nous sommes pas penchés

sur ces aspects.

Une autre particularité du problème de CRL est qu'il s'applique souvent à des problèmes de grande taille. En effet, il sert à la conception de réseau sur le moyen/long terme et par conséquent concerne souvent des chaînes logistiques mondialement déployées. Pour répondre à la complexité et la taille de certains problèmes de CRL, Gupta & Könemann (2011) proposent une revue de la littérature sur les algorithmes d'approximation pour faciliter la résolution du problème de CRL. Cependant, ils ne considèrent pas d'approximations comme l'agrégation de données d'entrée ou des heuristiques multiniveaux utilisant l'agrégation de données.

### 1.3.3.1 Le « Facility Location Problem »

L'objectif du FLP est d'optimiser l'ouverture de plateformes logistiques parmi des plateformes candidates. Pour ce faire, l'optimisation des flux de produits à travers le réseau de plateformes apparaît souvent comme un sous-objectif.

Les entités géographiques du réseau représentent les noeuds du graphe de flux du FLP. Si le problème est multipériode, le graphe est alors un graphe spatio-temporel et un noeud représente une entité géographique à une période donnée. Comme énoncé dans la section précédente, une particularité du FLP est que ses noeuds sont organisés en différents niveaux qui dépendent de leur rôle au sein du réseau. Un arc correspond à une possibilité de transport (orienté) entre deux noeuds, soit une section de route utilisée à une période donnée. Dans le cas de modèle multiproduit, les arcs sont différenciés par type de produit pour pouvoir suivre leur flux. Dans la plupart des cas, un arc démarre d'un noeud pour aller vers un autre noeud du niveau directement supérieur. Par exemple, un FLP d'une chaîne de distribution peut avoir trois niveaux : un niveau contenant des usines, un niveau contenant des centres (plateformes logistiques) et un niveau contenant des clients (voir la Figure 1.5). Un FLP à plusieurs niveaux est appelé multiniveau. Une revue sur les FLP multiniveaux est proposée par Ortiz-Astorquiza et al. (2018). Melo et al. (2009) donnent une revue de la littérature des modèles de FLP dans un contexte de gestion d'une chaîne logistique. Cette revue fait donc un parallèle avec le problème de CRL. Saldanha-da Gama (2022) complète cette revue et donne les perspectives de recherches pour les années à venir. Plus particulièrement, Klose & Drexl (2005) se focalisent sur la chaîne logistique de la distribution.

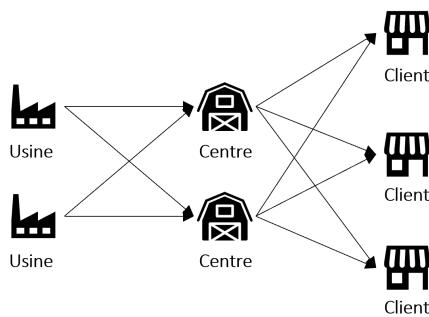


FIGURE 1.5 – Exemple de graph pour le FLP

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

---

Owen & Daskin (1998) proposent une revue de la littérature des études sur le FLP ayant un caractère stratégique. Selon eux, l'aspect stratégique du FLP se traduit par une modélisation dynamique ou stochastique du problème. Ils emploient l'aspect dynamique en tant que problème ayant des caractéristiques changeant dans le temps ou engageant les décisions sur un horizon de temps relativement long comme les problèmes multipériodes. Arabani & Farahani (2012) complètent cette revue en se concentrant sur le FLP multipériode. Finalement, Alarcon-Gerbier & Buscher (2022) mettent à jour les récentes contributions sur le FLP dynamique suite à la récente amélioration de la flexibilité de l'emploi de plateformes logistiques dans le temps.

La Table 1.3 regroupe les études sur des FLP multipériodes déterministes appliqués à la distribution de produits. La première colonne est marquée (\*) si le modèle étudié est multiproduit. Dans le cas contraire l'étude considère un flux de produits sans distinction. Étant donné qu'il n'existe pas de règle de précédence forte d'utilisation des plateformes logistiques de la distribution de véhicule de Renault Group, nous observons la relaxation de ces règles dans les études rencontrées grâce à la présence d'arcs intraniveau (par exemple un arc d'un centre vers un autre centre du même niveau) ou de saut de niveau (par exemple un arc d'une usine vers un client sans passer par un centre) dans les graphes considérés. Si ces colonnes sont vides, le modèle ne contient pas ces types d'arcs. La distribution de véhicules comporte des coûts de transports complexes qui ne sont pas simplement proportionnels au nombre de véhicules sur chaque route. C'est pourquoi, les formulations particulières de coût de transport sont aussi renseignées dans la table. Toutes les études possèdent au moins une formulation de coût de transport proportionnelle au nombre de produits. Cependant, les coûts supplémentaires de transports ayant une forme différente sont mentionnés dans cette colonne. « coût fixe sur les sections » signifie que le modèle étudié comporte des coûts d'utilisations de sections de routes. « coût par lot » signifie que le modèle comporte des coûts proportionnels à une certaine quantité de produits (par exemple, lorsque des camions entiers sont facturés). « économie d'échelle » signifie que le modèle comporte des coûts de transport par produit décroissants lorsque la quantité de produit augmente. Enfin, ce travail de recherche étant réalisé avec Renault Group, nous nous intéressons aux applications industrielles des autres travaux. Si la case « Application industrielle » est vide, cela signifie que soit l'étude concernée ne comporte pas d'application, soit l'application est réalisée avec des instances de la littérature ou générée.

	Produit	Intraniveau	Saut de niveau	Coût de transport	Application industrielle
Cette étude	*	*	*	coût par lot	industrie automobile
Melachrinoudis (1995)					gestion des déchets
da Gama & Captivo (1998)					
Nozick & Turnquist (1998)					industrie automobile

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

---

Current et al. (1997)				
Antunes & Peeters (2000)				transport scolaire
Antunes & Peeters (2001)				transport scolaire
Canel et al. (2001)	*			
Gue (2003)	*	*	coût fixe sur les sections	industrie militaire
Jr. et al. (2006)				
Dias et al. (2007)				
Hinojosa et al. (2008)	*			
Albareda-Sambola et al. (2009)				
Thanh et al. (2012)	*	*		
Melo et al. (2012)	*			
Correia et al. (2013)	*			
Ghaderi & Jabala- meli (2013)		*	coût fixe sur les sections	santé publique
Wu et al. (2015)			économie d'échelle	
Jena et al. (2016)	*			
Tang et al. (2016)			coût par lot	industrie horticole
Marufuzzaman et al. (2016)				
Correia & Melo (2016)				
Correia & Melo (2017)				
Fahimnia et al. (2018)	*	*		industrie du textile
Pearce & Forbes (2018)		*	coût fixe sur les sections	
Sauvey et al. (2020)				
de Oliveira et al. (2021)			coût fixe sur les sections	
Silva et al. (2021)				

---

TABLE 1.3 – FLP déterministes pour la distribution

### 1.3.3.2 Le « Hub Location Problem »

L'objectif du HLP est de déterminer les centres à ouvrir au sein d'un réseau de centres interconnectés, ainsi que d'allouer des demandes ou nœuds consommateurs à

ces centres.

Souvent le graphe de flux d'un HLP est un graphe complet de centres auquel sont connectés des noeuds sources et des noeuds consommateurs. La Figure 1.6 est un exemple de graphe avec quatre centres, un noeuds source (usine) et deux noeuds consommateurs (clients). Alumur & Kara (2008) proposent une classification des modèles de HLP. Kara & Taner (2011) complètent cette revue avec les auteurs et articles qui ont apporté des avancés dans le domaine. Farahani et al. (2013) donnent une revue sur les modélisations, méthodes de résolutions et applications. Enfin, Alumur et al. (2021) discutent des perspectives de recherches pour les prochaines années.

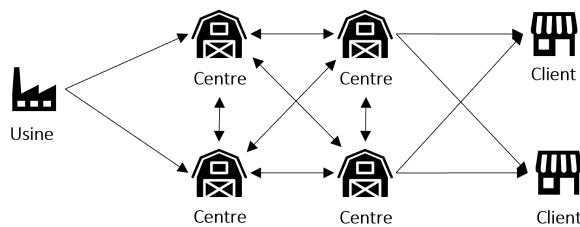


FIGURE 1.6 – Exemple de graph pour le HLP

Basallo-Triana et al. (2021) considèrent les modèles multipériode dans leur revue sur le HLP multimodal. Ils confirment que la recherche sur le HLP multipériode n'est pas très riche et qu'il n'y a pas d'étude de modèle à la fois multiproduit et multipériode parue avant décembre 2021.

La Table 1.4 regroupe les études sur des HLP multipériode déterministes appliqués à la distribution. Les colonnes « Produit », « Coût de transport » et « Application industrielle » fonctionnent de la même manière que dans le paragraphe précédent sur le FLP. Si un modèle prend en compte des quantités de produits, la colonne « Flux » est sélectionnée. Sinon, cela signifie que le modèle concerné prend en entrée des couples d'origine et destination sans information sur des quantités de produit. Sinon, uniquement les ouvertures de routes et/ou allocations de noeuds consommateurs à des centres sont considérées. Étant donné que la conception du réseau de distribution de Renault Group ne prend pas en compte les tournées vers les concessions automobiles, les modèles contenant des flux sortant de points consommateurs sont indiqués dans la colonne « Nœuds consommateurs ».

L'étude proposée par Mrabti et al. (2022) contient un modèle comprenant des caractéristiques similaires au modèle étudié dans cette thèse. Leur modèle comprend une flotte de camions hétérogène et l'objectif est de trouver le nombre de centres, leurs capacités et localisations, les liens entre les entités géographiques du réseau, les quantités transportées et stockées, les quantités retardées et le nombre et type de camions utilisés pour chaque période. Ce modèle contient davantage d'aspects stratégiques par rapport au nôtre. La résolution de larges instances (85 entités géographiques comprenant 15 usines, 15 centres intermédiaires, 15 centres de distribution et 40 clients) s'appuie sur un algorithme génétique. Notre problème comporte en

comparaison environ deux fois plus de centres et de clients.

	Flux	Produit	Nœuds consommateurs	Coût de transport	Application industrielle
Cette étude	*	*		coût par lot	industrie automobile
Ziliaskopoulos & Wardell (2000)					
Contreras et al. (2011)	*	*			
Ishfaq & Sox (2011)				économie d'échelle	
Shashin (2008)			*		
Alumur et al. (2015)	*				compagnie aérienne
Masaeli et al. (2018)	*			coût par lot et coût fixe sur les sections	forces aériennes
Monemi et al. (2021)	*		*	coût fixe sur les sections et coût par lot	aide humanitaire
Mrabti et al. (2022)	*	*		coût par lot	

TABLE 1.4 – HLP déterministes pour la distribution

En conclusion, le problème de CRL a été très largement étudié dans la littérature, ainsi que sa version multiproduit. Il est moins commun de croiser une étude à la fois multipériode et multiproduit. Pour ce qui est des problèmes considérés dans cet état de l'art (FLP et HLP), qui sont des problèmes plus stratégiques que le problème considéré dans ce manuscrit, quelques études considèrent des coûts de transports par lot comme nous le faisons.

### 1.3.4 Conception de réseaux logistiques - problèmes tactiques

Pour rappel, notre cas d'étude est un problème de CRL tactique contenant les objectifs suivants : (1) déterminer l'utilisation des plateformes et routes, (2) organiser des tournées (aller-retour sur une section) de moyens de transport et (3) planifier le stockage de produits. Notre problème ne contient donc pas de coûts fixes sur l'utilisation de centres ou l'allocation de clients à des centres, comme le ferait un problème stratégique. Ce problème plus tactique est appelé dans la littérature un NDP.

Le NDP est défini comme un problème stratégique ou tactique qui consiste à transporter des produits de nœuds sources jusqu'à des nœuds consommateurs à travers un réseau logistique, le tout en minimisant le coût de transport. Le réseau est composé d'un ensemble d'arcs entre plusieurs points géographiques. Magnanti & Wong (1984) donnent une revue de la littérature fondatrice sur les études de modèles de Programme Linéaire en Nombres Entiers (PLNE) pour le NDP et de leurs variantes pour la planification du transport. Minoux (1987) et Minoux (1989) proposent une revue sur le NDP avec une attention particulière sur sa version multiproduit. Crainic et al. (2022) proposent une revue récente sur le NDP multiproduit et multiniveau.

Notre modèle qui découle du problème de distribution de véhicules possède une formulation des coûts de transport particulière. Un transport sur une section de route à une période donnée est réalisé soit par transport routier soit par transport maritime. Dans la majeure partie des cas, ce sont des transports routiers. Ces transports sont facturés par camion et non par véhicule. Un camion peut être rempli avec différents véhicules et les véhicules ont chacun un taux de remplissage d'un camion de taille moyenne. Nous formulons donc le coût de transport routier avec un coût par lot de produit, le lot de produit étant le nombre de camion entier estimé sur la section de route et à la période concernée.

#### 1.3.4.1 Le « Network Design Problem » avec des coûts fixes

Une variante classique, proposée en premier par Hirsch & Dantzig (1968), est le NDP avec des coûts fixes. Un coût fixe est dû lorsqu'une section de route est utilisée, peu importe le flux sur cette section. Ce problème a été très largement étudié, en particulier sa version multiproduit. Cependant, peu d'études considèrent une formulation multipériode et multiproduit. La Table 1.5 contient les articles qui s'adressent à ce type de problème. Nous renseignons également les particularités suivantes. Un réseau peut inclure des capacités de transport sur les sections de route en tant que contrainte dure. Les articles considérant ces capacités sont indiqués par une (\*) dans la colonne « Capacité ». La colonne « Flux de service » est indiquée par une (\*) si le modèle considéré inclut un flux de moyen de transport en plus du flux de produit. Finalement, la colonne « Application industrielle » contient le domaine d'application du modèle dans le cas où des expérimentations numériques sont réalisées sur des données réelles.

	Capacité	Flux de service	Application industrielle
Fragkos et al. (2017)	*		
Nishi et al. (2019)	*		entreprise de transport
Fragkos et al. (2021)	*		expansion de réseau
Jiang et al. (2022)	*	*	

TABLE 1.5 – Etudes de NDP multipériodes et multiproduits déterministes avec des coûts fixes

Nishi et al. (2019) considèrent un coût fixe et des capacités sur les sections de route d'un NDP, sachant que si une section est utilisée, elle l'est sur l'entièreté de l'horizon temporel. Leur étude est motivée par un cas d'étude de conception de systèmes de véhicules guidés et automatisés.

Fragkos et al. (2017) proposent un NDP avec des coûts fixes sur l'ouverture des sections de route. Une fois qu'une section est utilisée, elle est ouverte sur le reste de l'horizon temporel. Le coût d'ouverture est décroissant au cours du temps. Ils proposent une version avec et une version sans capacités de flux. Fragkos et al. (2021) continuent ces travaux en considérant une étude de cas pour la conception d'un réseau ferroviaire à grande vitesse pour la distribution des marchandises.

Jiang et al. (2022) considèrent un coût fixe sur l'utilisation d'une section de route à chaque période d'utilisation dans un « Service Network Design Problem » stochastique. Le « Service Network Design Problem » est un NDP contenant une contrainte de respect du flux physique supplémentaire sur les moyens de transport, par exemple, le flux de camions à travers le réseau.

### 1.3.4.2 Autres formulations particulières du coût de transport

Il existe d'autres formulations particulières du coût de transport. Par exemple, une fonction concave peut simuler des économies d'échelles réalisées lorsqu'un flux de produits est suffisamment important (Balakrishnan & Graves, 1989). Cependant, cette section ne contient que les études proposant des coûts de transport dépendant de flux d'entités (produits, camions) entières.

Certaines études considèrent un « Loading Network Design Problem » dans lequel des capacités de sections doivent être déterminées. Le but de tels problèmes est d'optimiser les capacités. La capacité choisie sur une section de route doit être supérieure à la quantité de flux dans les deux directions sur cette section, ce qui diffère de notre problème. Lai & Shih (2013) élaborent un « Loading Network Design Problem » multipériode et multiproduit avec un coût fixe sur l'utilisation de différents types de capacités sur chaque section et chaque période pour déterminer les besoins en capacités de réseaux ferrés.

### 1.3.4.3 Le « Network Design Problem » avec des coûts par lot

Notre formulation de coût de transport par lot peut être catégorisée en tant que fonction croissante par pallier prenant comme argument un vecteur contenant le nombre de chaque type de véhicule sur une section de route à une période donnée. La Table 1.6 contient les études qui proposent des formulations de coûts par lot. La colonne « Taille de produit » est indiquée (\*) si la taille du lot dépend de la taille des types de produit transportés.

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

	Capacité	Flux de service	Taille de produit	Application industrielle
Haghani & Oh (1996)	*	*		aide humanitaire (instances générées)
Tepaz et al. (2010)	*	*		flotte de service
Wang & Wallace (2016)	*			
Wang et al. (2019)	*			
Wang & Qi (2019)	*	*		
Medina et al. (2019)		*		
Scherr et al. (2020)		*		réseau routier
Xiang et al. (2022)				société de transport
Cette étude			*	industrie automobile

TABLE 1.6 – Etudes de NDP multipériodes et multiproduits déterministes avec des coûts par lot

Haghani & Oh (1996) proposent un modèle multimodal avec des fenêtres de temps pour un réseau d'aide humanitaire. Wang & Wallace (2016) et Wang & Qi (2019) proposent un « Service Network Design Problem » déterministe, ainsi que sa version stochastique.

D'autres formulations prennent en compte une variable de décision entre 0 et 1 et multiplient cette variable par la quantité de produit demandée pour modéliser le flux de produits. Tepaz et al. (2010) étudient un « Service Network Design Problem » qui maximise un profit pour l'optimisation d'une flotte de véhicules (camions) destinée à transporter des produits. Le flux de chaque véhicule est planifié, et un coût fixe est payé sur chaque section à chaque période d'utilisation par un véhicule. Chaque véhicule a une capacité.

Medina et al. (2019) proposent aussi un « Service Network Design Problem » avec des fenêtres de temps et comparent deux formulations. Une formulation organise les transports : les camions font des aller-retours sur une section de route à une période donnée donc il n'est pas nécessaire de le modéliser. Une deuxième formulation organise les tournées des camions.

Scherr et al. (2020) modélisent un « Service Network Design Problem » pour l'optimisation d'une flotte de véhicules (camions) semi-automatisés. Deux types de véhicules ont des capacités différentes.

Rappelons que le but du constructeur automobile est d'optimiser les flux de produits et de quantifier le besoin capacitaire en moyens de transport. Au contraire, le transporteur souhaite optimiser sa flotte de camions ou bateaux en prenant en compte l'entièreté de sa demande du marché. Les coûts par lot sont relativement communs dans les modèles de « Service Network Design Problem » ou « Vehicle Scheduling Problem », puisqu'ils optimisent des flottes de moyens de transport pour satisfaire

des transports de produit. Cependant, ces problèmes diffèrent du nôtre en incluant souvent la modélisation des flux des moyens de transport.

Une seconde caractéristique de notre problème est sa taille et son niveau décisionnel tactique. Tous les articles mentionnés plus haut utilisent des horizons temporels plus courts (par exemple 8 heures) et des périodes plus fines (par exemple 30 minutes), ce qui implique que nous considérons un problème ayant un impact plus long terme (un mois) avec un niveau décisionnel plus haut.

Enfin, aucun des articles cités ci-dessus ne prend en compte des tailles de produits pour quantifier les lots à transporter. La variable (entre 0 et 1) multipliée par la demande qui caractérise le flux dans certaines formulations peut ressembler à notre formulation prenant en compte des tailles de types de produit. Cependant, nous considérons des flux de produits entiers comme variables de décisions. Ensuite, nous multiplions ces quantités par la taille des produits pour estimer le nombre de camions entiers sur une section de route à une période donnée.

En conclusion, nous observons que malgré de nombreuses publications de modèles contenant des formulations avec des coûts de transport particuliers depuis les années 1980, il existe très peu de versions multipériodes et multiproduits. Ensuite, seulement quelques rares articles mentionnent des applications industrielles et encore moins utilisent des données industrielles réelles. Notons que les formulations les plus complexes de coût de transport se trouvent dans les études basées sur un cas industriel. Ce domaine de recherche gagnerait donc à s'étoffer pour répondre à un besoin visible de la part des industries.

## 1.4 Organisation et apports du travail de recherche

Dans cette section, nous décrivons l'encadrement industriel de la thèse, nous rappelons également la problématique et décrivons les apports de chacun des chapitres qui vont suivre.

### 1.4.1 Problématique

Depuis environ une décennie, la Direction Logistique tente de s'équiper d'outils d'aide à la décision pour la conception de ses réseaux logistiques. De nombreux appels d'offres ont été formulés auprès d'entreprises externes spécialisées en recherche opérationnelle appliquée à la logistique afin de répondre au besoin. Plusieurs thèses ont été menées dans le but d'analyser ce besoin et d'y répondre en interne, comme la thèse de Kchaou-Boujelben (2014). De plus en plus les modèles doivent être adaptables aux changements organisationnels des chaînes logistiques. C'est la raison pour laquelle, la direction générale cherche à mettre en place des solutions flexibles, modifiables par des experts. En 2020 les concepteurs du réseau de distribution des véhicules ont mentionné le besoin de développer un outil d'aide à la décision tactique plus flexible. Ce problème était donc un cas d'étude intéressant pour réaliser un modèle de CRL.

L'optimisation de la distribution tactique de véhicules est un problème de taille conséquente qui concerne des décisions sur le moyen terme. Lors de la modélisation de ce problème, il est alors naturel de remettre en question le niveau de détail des données d'entrée. Une étude de l'impact d'agrégations sur les données d'entrée du modèle permet en ce sens de déterminer s'il est possible de réduire la taille du modèle sans affecter la qualité des solutions. Les problèmes de conception de réseaux engendrant de manière générale ces mêmes enjeux, la méthodologie proposée doit être applicable à d'autres problèmes de CRL.

Enfin, comme le fonctionnement de l'optimisation combinatoire n'est pas toujours compréhensible par les utilisateurs de l'outil, il est courant de réaliser de nombreux scénarios de tests et de fournir un effort particulier de vulgarisation afin de faciliter l'acceptation de l'outil. Or, ce travail est d'autant plus important lorsque les données d'entrée sont altérées comme dans le cas d'agrégations. L'acceptation d'outils basés sur une modélisation comportant une optimisation combinatoire est grandement influencée par la qualité de l'estimation de la fonction objectif du modèle, à savoir l'estimation du coût des solutions du problème de CRL dans notre cas. L'analyse et la réduction de l'erreur engendrée par l'agrégation sur l'estimation du coût sont donc des enjeux majeurs.

Avec tout cela à l'esprit, nous formulons la problématique suivante :

### **Comment établir une méthode d'agrégation des données d'entrée pour les modèles de conception de réseaux de distribution automobile ?**

Cette problématique soulève les questions suivantes :

1. Comment modéliser le problème tactique de conception du réseau de la distribution ? Est-il avantageux de modéliser les coûts de transport par lot ? Les résultats du modèle peuvent-ils contribuer à l'amélioration du réseau réel ?
2. Quelle méthode appliquer pour préconiser des agrégations de données d'entrée appropriées pour un modèle de conception d'un réseau logistique ? Quelles sont les possibilités d'agrégations (dimensions et niveaux) ? Comment caractériser la performance d'une agrégation ? Quel est l'intérêt d'une telle étude pour un modèle de CRL ?
3. Comment quantifier, interpréter et réajuster l'erreur induite par les agrégations sur la fonction objectif du modèle ?

#### **1.4.2 Apports de la thèse**

Pour répondre à la problématique et aux questions posées, des travaux de recherche ont été menés. Ils ont conduit à trois articles constituant les trois chapitres de ce mémoire. Les contributions scientifiques de chaque chapitre sont maintenant présentées.

##### **Chapitre 2 : Network design with batch cost**

Dans ce chapitre, nous présentons le cas d'étude de la distribution de véhicules, un problème décisionnel d'un niveau tactique. Nous proposons un modèle de PLNE pour concevoir le réseau, ainsi qu'une heuristique et une méthode de calcul de borne inférieure pour répondre à la difficulté de résolution de ce modèle. Nous proposons donc un nouveau problème de CRL qui inclut des contraintes industrielles peu étudiées dans la littérature (coût par lot).

### Chapitre 3 : A quantitative study of data aggregation

Dans ce chapitre, nous proposons une analyse de l'impact de l'agrégation des données d'entrée pour les modèles de CRL. Une étude quantitative permet d'appliquer cette analyse à notre cas d'étude détaillé dans le **Chapitre 2**. Tout d'abord, nous énumérons les possibilités d'agrégations par dimensions et niveaux d'agrégations et proposons une définition systématique du niveau d'agrégation maximal. Pour être en mesure de comparer les solutions obtenues avec les différentes agrégations et les solutions obtenues avec le niveau de détail initial, deux méthodes de désagrégation sont proposées. Cette étude nous permet d'observer l'intérêt de considérer l'agrégation de données d'entrée pour les problèmes de conception de réseau. De plus, grâce à cette analyse, nous pouvons réaliser des préconisations d'agrégations pour le cas d'étude. Cette méthodologie est utilisable pour d'autres problèmes de CRL.

### Chapitre 4 : Cost adjustment following input aggregation

Dans ce chapitre, nous reprenons l'étude réalisée dans le **Chapitre 3**. Mais cette fois, nous nous intéressons à un indicateur qui impacte grandement l'acceptation d'outils d'aide à la décision basés sur des modèles mathématiques par leurs utilisateurs, à savoir la qualité de l'estimation du coût des solutions. En effet, agréger les données d'entrée d'un modèle peut engendrer une erreur d'estimation du coût final des solutions. Nous proposons une méthode de réajustement des coûts afin de réduire davantage cette erreur. Concernant notre cas d'étude, toutes les dimensions et niveaux d'agrégations montrent des estimations de coût de solutions satisfaisantes. C'est-à-dire que le coût d'une solution agrégée est proche du coût de sa solution équivalente désagrégée. Cependant, le moindre biais a un impact important sur le coût. La méthode d'ajustement du coût des solutions permet d'améliorer davantage l'estimation du coût des solutions agrégées.

## 1.5 Conclusion

En résumé, toutes nos analyses sont réalisées avec des données réelles et sont des cas d'étude de l'industrie automobile. Nous proposons tout d'abord un modèle de CRL pour la distribution tactique de véhicule du constructeur automobile Renault Group. Une contrainte originale de coût de transport par lot est formulée. L'utilisation de ces coûts particuliers pour favoriser les densifications de flux est aussi une nouveauté pour la conception du réseau de l'entreprise.

## CHAPITRE 1. CONTEXTE ET ENJEUX DE L'ÉTUDE

---

Ensuite, nous analysons l'impact de différentes dimensions d'agrégations sur notre cas d'étude à la fois sur les décisions mais aussi sur la qualité des solutions (si les décisions diffèrent). Nous n'avons pas rencontré d'autres études dans la littérature comparant l'impact de différentes dimensions d'agrégations sur les solutions d'un modèle mathématique.

Enfin, lors de la création d'un outil d'aide à la décision, l'effort du développeur est majoritairement orienté sur l'amélioration de la technicité de l'outil et ce sont souvent ces aspects qui sont valorisés dans l'industrie. Dans la littérature, les études concernant l'acceptation de SAD basés sur un modèle sont tout aussi rares. Cependant, le développement de cet outil représente une perte de ressources si les utilisateurs ne l'acceptent pas. Or, la confiance dans un modèle peut d'autant plus diminuer si nous détériorons la précision des données d'entrée de ce modèle avec des agrégations. Nous réalisons donc une étude orientée sur l'acceptation de notre solution en analysant le biais des agrégations sur le coût des solutions et proposant une méthode originale de réajustement du coût.



# Chapitre 2

## Multi-period multi-product network design with batch costs : a case of automotive industry

### Abstract

Motivated by a case study from the automotive industry, we describe a tactical multi-period multi-product network design problem with batch transportation costs for vehicle distribution. This problem involves planning the product flow through routes and warehouses and the inventory strategy to satisfy client demands while minimizing the overall cost. The road transportation cost is negotiated per truck with the transportation providers, which results in a batch cost formulation for road transportation. This « batch cost » structure of the transportation cost leads to a new network design problem. The difficulty in solving this problem encouraged us to develop a heuristic to reach solutions faster and to calculate a lower bound to analyze the quality of the solutions. Numerous experiments show the advantage of batch cost formulation compared to transportation cost per product and qualify the performances of the different solution methods. We observe consistent solutions and solution costs thanks to a sensitivity analysis of demand variation.

### Keywords

Logistics, Transportation, Supply chain network design, Automotive industry, Vehicle distribution.

## 2.1 Introduction

Today automotive constructors provide vehicles worldwide. Their outbound supply chain network is highly developed and complex. Improving flow coordination in this network increases the margin of a company in such a competitive market. In addition, strategic and tactical decisions are strongly correlated in logistics management. With this in mind, optimization models for the Supply Chain Network Design (SCND) problem are powerful tools that can combine and support decisions on multiple managerial levels (Jabbour et al., 2020), such as network design and flow planning.

In this paper, we describe a case study of the outbound supply chain of a car manufacturer and propose a new multi-period, multi-commodity SCND model. Costs include road and sea transportation costs, facility handling costs, and facility inventory costs. The objective is to minimize the total cost by planning the flow of products on the roads and intermediate centers from the production site to the dealers.

Figure 2.1 shows the transportation flows in the distribution network. The vehicles (products) leave a plant and go through a dispatch center nearby. Then they either reach car dealers (customers) by direct flow or through intermediate centers. The last center of an indirect flow is named a capillary distribution center.

There exist two different product management strategies : built-to-order and built-to-stock. Since the dealer of a built-to-stock product is unknown, we estimate its destination dealer based on historical sales data. These products go through a center within a sub-set of the capillary distribution centers before reaching their dealer.

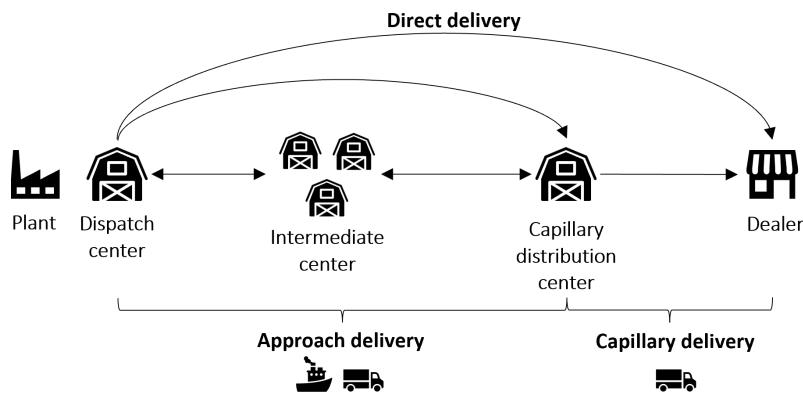


FIGURE 2.1 – Outbound supply chain network

The product delivery is outsourced to Third Party Logistics (3PL). Transportation costs are negotiated for several months, depending on quantities and frequencies, for each source-destination transport. Ship transportation cost is incurred per product. Road transportation cost is incurred by truck. A truck carries several products, but the number of products transported depends on their load factor. Even if the truck is not complete, the transportation cost is fixed. As road transportation costs are not proportional to product quantity, one reasonable approach is to optimize the truck fill rate. Filling trucks, however, may induce waiting for some products to come and thus

increase inventory costs. We refer to these phenomena as « economies of density ». Economies of density are described by Shashin (2008) as « when the cost of service is reduced due to the increase in the demand density rather than the distributed demand and lower density ». Thus, we call this problem the Batch Cost Network Design Problem (BCNDP).

The contributions of this article are as follows : We propose a new multi-period multi-product Network Design Problem (NDP) with batch transportation cost. This problem is derived from a real industrial problem from the automotive industry, but it is relevant for all companies that negotiate regular shipments with 3PL. We develop optimal and heuristic solution methods that we test on industrial instances. Numerical results show the relevance of the batch cost modeling and the difficulty of finding optimal solutions in a reasonable time.

The rest of the paper is organized as follows. In Section 2.2, we outline the state of the art of multi-period and multi-product NDP and draw a comparison with the previously described particularities of the BCNDP. Section 2.3 gives a formal description of the BCNDP. We propose a Mixed-Integer Linear Programming (MILP) formulation of the problem in Section 2.4. Since the problem is difficult to solve, a simple heuristic and a lower bound calculation are also given in this section for the resolution of the BCNDP. Finally, in Section 2.5, several numerical experiments are performed to highlight the problem's computational complexity and the influence of modeling road transportation as a batch cost instead of per product. An analysis of the impact of demand variation on the solutions and a comparison of the solutions when including more routes in the available network are also provided in this section. A conclusion section ends up the paper with some outlines and perspectives.

## 2.2 Literature review

Decisions belonging to the SCND problem are generally the location of facilities, the assignment of suppliers or customers to facilities, routing, and inventory strategy (Ambrosino & Scutellà, 2005). It is appropriate for combining strategic and tactical decisions. One can find multiple reviews about SCND models. Min & Zhou (2002) focused on modeling methods for the SCND problem. Chopra (2003) and Ambrosino & Scutellà (2005) tackle the distribution NDP and give incentives on the factors influencing the network. Gupta & Könemann (2011) review approximation algorithms to cope with the complexity of industrial SCND problems. Let us note that multi-period SCND problems are less present in the literature than single-period problems (Fattahi et al., 2015).

The NDP is a strategic or tactical problem that involves transporting products from source nodes to sink nodes through a logistic network, a set of route sections from one location to another, minimizing transportation costs. Magnanti & Wong (1984) give a founding review on studies of the network design MILP models and specific variants for transportation planning. Minoux (1987) and Minoux (1989) propose a survey of NDP with particular attention on multi-commodity (multi-product) problems.

Crainic et al. (2022) give a recent survey about multi-layers and multi-commodity NDP.

The problem studied in this article, BCNDP, has a specific transportation batch cost formulation. A network route section corresponds to road or sea transportation. In most cases, it is road transportation. The transportation costs are calculated per truck, not per product. A truck can be filled up with different products, each of which has a load factor (*i.e.* based on the number of products that can be loaded on a standard truck). We call this cost a batch cost. The batch is the number of necessary integer trucks on the road section at a specific period. In the network design literature, we observe various cost structures. In the following, we present the relevant literature for this study from the cost-structure point of view.

### 2.2.1 Fixed-cost network design

A classical variant, first proposed by Hirsch & Dantzig (1968), is the fixed-cost NDP that involves a fixed cost on the used route sections. This problem has been widely studied, especially its multi-commodity form. Few of them considered a multi-period multi-commodity model formulation. Table 2.1 lists the articles that address this type of problem. The column “Capacity” contains a (\*) when the model is capacitated (as a strong constraint) and is empty otherwise. The column “Service flow” contains a (\*) if milk-run flows or paths of transportation mode are considered. In the column “Industrial application”, the field of application is mentioned if industrial data are used in the computational experiments.

	Capacity	Service flow	Industrial application
Fragkos et al. (2017)	*		
Nishi et al. (2019)	*		transport company
Fragkos et al. (2021)	*		network expansion
Jiang et al. (2022)	*	*	

TABLE 2.1 – Deterministic multi-period multi-product NDP with fixed-cost formulation

Nishi et al. (2019) consider a fixed-cost on used route section for the capacitated NDP, knowing that if a section is used, it is for the entire time horizon. Their study is motivated by a real case study for automated guided vehicle systems design with 101 geographical entities, 371 route sections, 10 pick-ups, 10 delivery points, and 60 periods. Our case study contains, in comparison, 8 times more delivery points and almost 3 times more route sections.

Fragkos et al. (2017) propose a fixed cost on used routes sections for a capacitated and uncapacitated version of a NDP. Once a route section is activated, it can be used during the entire time horizon. The fixed cost depends on the activation period and gets smaller over time. They solve a model containing up to 80 periods, 20 geographical entities, and 80 product types. Fragkos et al. (2021) continue this previous analysis

by solving a real high-speed rail network design for cargos distribution case study of similar characteristics.

Jiang et al. (2022) consider a fixed cost on the used sections at each period within a stochastic service network design problem with unsatisfied demand minimization. Their instances contain 5 periods and 30 geographical entities.

## 2.2.2 Other transportation costs formulations

Other interesting works consider a specific transportation cost formulation. For example, a concave cost function can simulate economies of scale realized when the product flow is condensed (Balakrishnan & Graves, 1989).

Some papers propose a loading problem where section flow capacities must be determined. The goal of the loading problem is to optimize capacities. The chosen capacity of one route section must be superior to the flow in both directions on this route section, which differ from our problem. Lai & Shih (2013) formulate a multi-period multi-commodity loading network design and design a fixed cost on the used capacity on each section at each period to design railroads capacity.

## 2.2.3 Batch cost network design

Our batch cost formulation can be categorized as an increasing step function since the transportation cost on a route section is a step-cost function of the product flow vector on this section. Table 2.2 gathers papers containing multi-period multi-product NDP with batch costs. The column “Product size” contains a (\*) if the product types’ size influences the batch number.

	Capacity	Service flow	Product size	Industrial application
Haghani & Oh (1996)	*	*		disaster relief (generated instances)
Teypaz et al. (2010)	*	*		service fleet
Wang & Wallace (2016)	*			
Wang et al. (2019)	*			
Wang & Qi (2019)	*	*		
Medina et al. (2019)		*		
Scherr et al. (2020)		*		street network
Xiang et al. (2022)				courier company
This paper		*		automotive industry

TABLE 2.2 – Deterministic multi-period multi-product NDP with batch cost formulation

Haghani & Oh (1996) propose a multi-period multi-product multi-modal network design model formulation with time windows for an industrial case study of disaster relief operations. Wang & Wallace (2016) and Wang & Qi (2019) propose deterministic and stochastic multi-period multi-commodity service network design models with batch cost.

Some models consider a flow decision variable between 0 and 1 to characterize the product flow rate and multiply it by the demand to quantify the flow. Teypaz et al. (2010) study a service network design model that maximizes profit for a real freight transportation application. The flow of each vehicle (truck) is planned, and a fixed cost is due on each period of use of a section by these vehicles. Each vehicle has a capacity. Our model is more tactical as we do not handle trucks and products individually, as is the case in Teypaz et al. (2010). The instances are also more refined than ours. They contain 480 periods for a planning horizon of one week, 40 terminals (all geographical entities), and 3 vehicle (truck) types. The biggest vehicle type can contain up to 140 products.

Medina et al. (2019) also propose a service network design model with time windows and analyze the benefit of two formulations. One formulation organizes transportation with round trips, and another with truck milk runs. They solve instances of up to 200 commodities (product) and up to 10 terminals (intermediate centers).

Scherr et al. (2020) also solve a service network design model for a mixt-autonomous vehicle fleet. They consider two vehicle (truck) types with different capacities. This problem involves a temporal horizon of 8 hours.

Let us recall that the automotive manufacturer's purpose in our study is to optimize the product flow and quantify the needed transportation capacity. On the other hand, the transport service provider must optimize the flows of its fleet with the knowledge of all its clients' demands. Batch costs are relatively common in service network design problems or vehicle scheduling problems since they aim at optimizing a transportation mode fleet while satisfying a product flow demand. However, these problems differ slightly from ours since they often involve transportation mode flow constraints.

A second characteristic of our problem is its size and its tactical level of decision. All the mentioned articles used shorter time horizons and thinner periods than us, which implies that we are considering more long-term tactical decisions. The same applies to formulations with fixed costs.

Finally, none of the above-mentioned studies consider product types' sizes in their batch cost formulation. The products usually have a unique size since they formulate a unique truck capacity (per truck type if multiple).

In conclusion, despite the publication of numerous network design models with specific cost formulations starting from the 80s, multi-period and multi-product versions are scarce in the literature. Second, only a few papers mention real industrial applications. Within those, even fewer use real instances for their computational experiment. Besides, the only industrial applications are usually studies proposing the

most complex transportation cost formulation. The industries could benefit from more complex formulations in the research field.

## 2.3 Problem description

### 2.3.1 The network structure of the BCNDP

The BCNDP can be described by a multi-flow time-space graph. Nodes represent a plant, a center, or a car dealer at a given period  $t \in T$  (day in this industrial problem). Plant  $i \in P$  produces vehicles. It can also serve as an intermediate center called center in the following. Each plant can send vehicles to each center  $i \in W$ , and a flow can exist between two centers (or plants). For a dealer  $i \in D$ , the vehicles received can come from centers or plants. However, only the route sections whose transportation cost is in the input can be used. A section is not in the input if the transportation is physically impossible or if it has been judged too expensive during the negotiation of the cost with the transporter. Notations of the sets are as follows :

- $P$  is the set of plants
- $W$  is the set of centers
- $D$  is the set of dealers
- $N$  is the set of entities ( $N = P \cup W \cup D$ )
- $A_R$  is the set of route sections representing road transportation
- $A_S$  is the set of route sections representing sea transportation
- $A$  is the set of route sections ( $A = A_R \cup A_S$ )
- $T$  is the set of periods (days in this industrial problem)

A product  $k \in K$  is characterized by the model type and, therefore, its load factor  $o^k$  (the space it occupies on a truck) and the management type (built-to-order or built-to-stock). Due to fiscal constraints, built-to-stock vehicles must pass through a center (within a sub-set of centers) before being delivered to a dealer.

We define the following sets to characterize the two main vehicle categories :

- $K_{BTO}$  is the set of built-to-order vehicles
- $K_{BTS}$  is the set of built-to-stock vehicles
- $K$  is the set of all vehicles ( $K = K_{BTO} \cup K_{BTS}$ )

We define  $p_i^{k,t}$  as the number of product  $k$  produced at plant  $i$  at period  $t$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$ .

Dealer demand can be satisfied directly from the plant for the built-to-order vehicles or through the network of centers. For built-to-stock vehicles, delivery is only possible through the network of centers. As we are in a production-driven push approach, *i.e.* vehicles are sent to dealers as they are produced, the demand  $d_i^k$  is the number of product  $k$  requested by dealer  $i$ ,  $\forall i \in D$ ,  $\forall k \in K$ . This demand is for the horizon considered, not for a specific period  $t$ .

Because of the travel distance between two entities  $i$  and  $j$ , we need to define  $\tau_{i,j}$

as the travel time (in periods) from  $i$  to  $j$ ,  $\forall(i, j) \in A$ . More precisely, if a truck (or a ship) leaves entity  $i$  at  $t$ , it arrives at  $t + \tau_{i,j}$  at  $j$ .

The main flow variables of the BCNDP are defined as follows and explained in Figure 2.2 :

- $x_{i,j}^{k,t}$  is the number of product  $k$  leaving node  $(i, t)$  toward the node  $(j, t + \tau_{i,j})$ ,  $\forall(i, j) \in A, \forall k \in K, \forall t \in T$
- $s_i^{k,t}$  is the inventory quantity of product  $k$  at plant or center  $i$  between period  $t$  and  $t + 1$ ,  $\forall i \in P \cup W, \forall k \in K, \forall t \in T$ ,  $s_i^{k,-1}$  being the initial stock

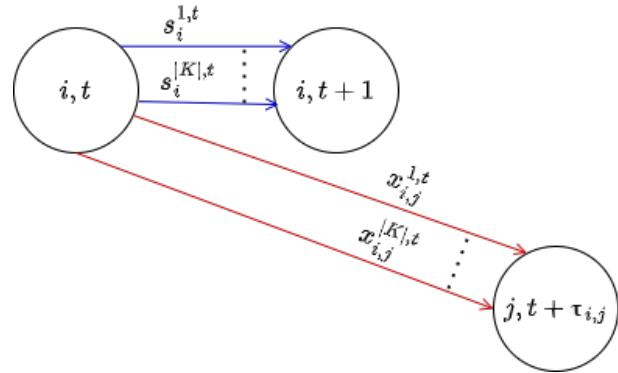


FIGURE 2.2 – Outflow from node  $(i, t)$

For simplification matter, we add the following variables :

- $l_i^{k,t}$  is the number of product  $k$  leaving node  $(i, t)$ ,  $\forall i \in P \cup W, \forall k \in K, \forall t \in T$
- $a_i^{k,t}$  is the number of product  $k$  arriving to node  $(i, t)$ ,  $\forall i \in P \cup W \cup D, \forall k \in K, \forall t \in T$

The resulting graph is referred to in the literature as a multi-flow time-space graph. Figure 2.3 gives an example of the graph for a single product configuration. The horizontal axis shows the time dependency, and the vertical axis gathers the different geographical entities. Plant nodes are supplied by a dummy source node denoted  $s$  at different periods. Red, orange, and yellow arcs represent transportation. Blue arcs represent inventory flows. Since the demand is independent of the period and for the sake of the graph simplicity, these product quantities finally reach a sink node denoted  $t$  at the last period.

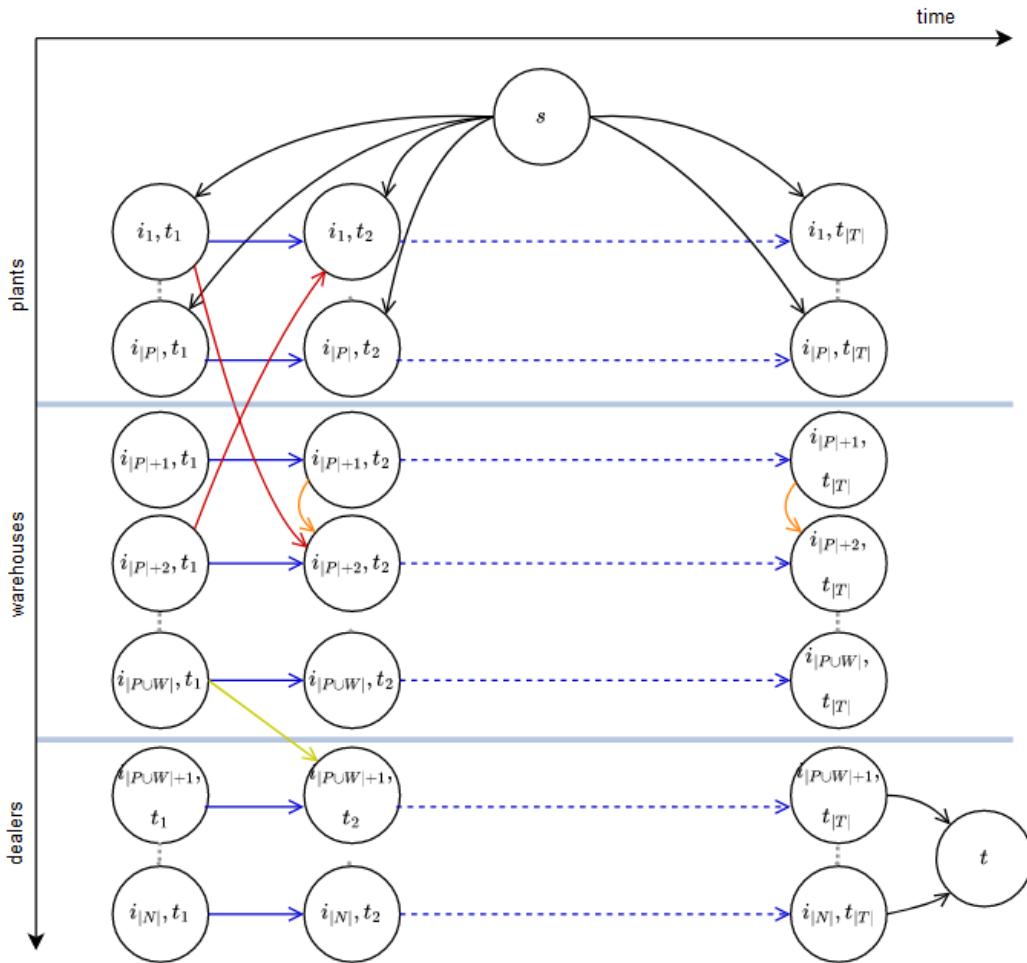


FIGURE 2.3 – Single product BCNDP flow graph

The following rules limit our graph network.

- Regarding nodes : as dealers cannot be used like centers, there exists no outflow arc from dealers. Thus, in Figure 2.3, one can only see inventory flow (horizontal flow in blue) and entering flow (from node  $(i_{|P|+|W|}, t_1)$  to  $(i_{|P|+|W|+1}, t_2)$  in yellow).
- Regarding arcs : Theoretically, all arcs between plant nodes and center nodes are possible. However, without loss of generality, we consider the following rules inherent to our industrial case :
  - Only the arcs for which the transportation cost is known are included. These routes are determined during the negotiation between the automotive constructor and the transportation service provider. For example, in Figure 2.3, exchanges between plant  $i_1$  and warehouse  $i_{|P|+2}$  are possible, and the transportation duration is of a period of one day (illustrated by red arcs).
  - Due to financial regulations, arcs between a center and a dealer in different countries do not exist for built-to-stock products.
  - Sea transportation may not be available at the period size frequency. In this case, only the arcs starting at a period containing a ship departure are

created. For instance, in Figure 2.3, there are no ship departures in the first period from warehouse  $i_{|P|+1}$  to warehouse  $i_{|P|+1}$ . The first arc leaves  $i_{|P|+1}$  only at period 2 and realizes a sea journey within one period (illustrated by an orange arc).

### 2.3.2 The cost structure of the BCNDP

We consider three costs : the transportation costs by road and sea and the handling and inventory costs at plants and centers.

Considering road transportation, the automotive company negotiates truck costs and load factors per vehicle model with the transporters for every road section. We define the load factor in the MILP as the fill rate of one vehicle in a truck and denote it  $o^k$ , the load factor of product  $k$  in an average-sized truck,  $\forall k \in K$ . The truck quantity between two nodes is estimated as the upper integer value of the sum, for all products, of the product load factor multiplied by the product flow quantity. Concerning sea transportation, transportation costs are proportional to the vehicle quantity.

For the sake of simplicity, we create a variable representing the charged quantities on every arc : the truck quantity for a road transportation arc and the product quantity for a sea transportation arc. We denote it  $z_{i,j}^t$  the charged quantity from node  $(i, t)$  to entity  $j$ ,  $\forall (i, j) \in A, \forall t \in T$ .

The handling cost through centers is mainly composed of maintenance and handling costs. These costs are gathered into a single handling cost per vehicle unit for organizational reasons. The handling cost can influence path choices, as it differs for all centers.

The final cost impacting the network design decision is the inventory cost. This cost is incurred for each vehicle stored per period in a center and differs for all centers. The inventory cost impacts network design decisions, as it is opposed to center handling costs, flow densifications, and waiting time at departure ports.

Summing up, the costs are defined as follows :

- $tc_{i,j}$  is the transportation cost (per truck for road transportation arcs and per product for sea transportation arc) from entity  $i$  to  $j$ ,  $\forall (i, j) \in A$
- $pc_i$  is the handling cost per product through plant or center  $i$ ,  $\forall i \in P \cup W$
- $sc_i$  is the inventory cost per product and per period at plant or center  $i$ ,  $\forall i \in P \cup W$

### 2.3.3 Input data

- $P$  is the set of plants
- $W$  is the set of distribution centers
- $D$  is the set of dealers

- $N$  is the set of entities ( $N = P \cup W \cup D$ )
- $T$  is the set of periods
- $A_R$  is the set of route sections representative of road transportation
- $A_S$  is the set of route sections representative of sea transportation
- $A$  is the set of route sections ( $A = A_R \cup A_S$ )
- $K_{BTO}$  is the set of products intended for built-to-order
- $K_{BTS}$  is the set of products intended for built-to-stock
- $K$  is the set of products ( $K = K_{BTO} \cup K_{BTS}$ )
- $tc_{i,j}$  is the transportation cost per unit from entity  $i$  to  $j$ ,  $\forall(i,j) \in A$
- $pc_i$  is the handling cost per product through plant or center  $i$ ,  $\forall i \in P \cup W$
- $sc_i$  is the inventory cost per product and per period at plant or center  $i$ ,  $\forall i \in P \cup W$
- $p_i^{k,t}$  is the quantity of product  $k$  produced at entity  $i$  at period  $t$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $d_i^k$  is the quantity of product  $k$  asked by dealer  $i$ ,  $\forall i \in D$ ,  $\forall k \in K$
- $s_i^{k,-1}$  is the initial inventory of product  $k$  at plant or center  $i$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$
- $o^k$  is the load factor of product  $k$  in an average sized truck,  $\forall k \in K$
- $\tau_{i,j}$  is the transportation time from entity  $i$  to  $j$ ,  $\forall(i,j) \in A$

### 2.3.4 Variables

- $x_{i,j}^{k,t}$  is the quantity of product  $k$  leaving node  $(i, t)$  toward the entity  $j$ ,  $\forall(i,j) \in A$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $l_i^{k,t}$  is the quantity of product  $k$  leaving node  $(i, t)$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $a_i^{k,t}$  is the quantity of product  $k$  arriving to node  $(i, t)$ ,  $\forall i \in P \cup W \cup D$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $s_i^{k,t}$  is the inventory quantity of product  $k$  at plant or center  $i$  between period  $t$  and  $t + 1$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $z_{i,j}^t$  is the charged unit quantity from node  $(i, t)$  to entity  $j$ ,  $\forall(i,j) \in A$ ,  $\forall t \in T$

## 2.4 Modeling and solving the BCNDP

We first give a MILP model formulation of BCNDP that will be solved by a commercial solver. We also propose a heuristic and the computation of a lower bound.

### 2.4.1 MILP formulation for the BCNDP

The MILP formulation for BCNDP, called  $M_{BCNDP}$  is as follows :

$$\text{Minimize} \quad \sum_{t \in T} \sum_{(i,j) \in A} tc_{i,j} \times z_{i,j}^t + \quad (0.0)$$

$$\sum_{t \in T} \sum_{i \in P \cup W} pc_i \sum_{k \in K} a_i^{k,t} + \quad (0.1)$$

$$\sum_{t \in T} \sum_{i \in P \cup W} sc_i \sum_{k \in K} s_i^{k,t} \quad (0.2)$$

s.t.

$$\sum_{i \in P \cup W | t - \tau_{i,j} \geq 0} x_{i,j}^{k,t-\tau_{i,j}} = a_j^{k,t} \quad \forall j \in N, \forall k \in K, \forall t \in T \quad (1.0)$$

$$l_i^{k,t} = \sum_{j \in N} x_{i,j}^{k,t} \quad \forall i \in P \cup W, \forall k \in K, \forall t \in T \quad (1.1)$$

$$p_i^{k,t} + a_i^{k,t} + s_i^{k,t-1} = l_i^{k,t} + s_i^{k,t} \quad \forall i \in P \cup W, \forall k \in K, \forall t \in T \quad (2.0)$$

$$\sum_{t \in T} a_i^{k,t} = d_i^k \quad \forall i \in D, \forall k \in K \quad (2.1)$$

$$\sum_{k \in K} o^k \times x_{i,j}^{k,t} \leq z_{i,j}^t \quad \forall (i,j) \in A_R, \forall t \in T \quad (3.0)$$

$$\sum_{k \in K} x_{i,j}^{k,t} \leq z_{i,j}^t \quad \forall (i,j) \in A_M, \forall t \in T \quad (3.1)$$

$$x_{i,j}^{k,t} \in \mathbf{Z}^+ \quad \forall (i,j) \in A, \forall k \in K, \forall t \in T \quad (4.0)$$

$$l_i^{k,t}, s_i^{k,t}, a_i^{k,t} \in \mathbf{R}^+ \quad \forall i \in N, \forall k \in K, \forall t \in T \quad (4.1)$$

$$z_{i,j}^t \in \mathbf{Z}^+ \quad \forall (i,j) \in A, \forall t \in T \quad (4.2)$$

The objective is to minimize the sum of transportation costs (0.0), handling costs (0.1), and inventory costs (0.2). Constraints (1.0) and (1.1) channel the variables. Constraint (2.0) is the flow conservation constraint. The demand of dealers is necessarily satisfied by the end of the temporal horizon (2.1). The truck number between two nodes is the upper integer value of the sum for all the corresponding product flows of the product quantity multiplied by their load factor (3.0). Sea transportation cost is proportional to the product quantity (3.1). Finally, constraints (4.0), (4.1), and (4.2) ensure that the product and truck units remain integers throughout the network.

## 2.4.2 A heuristic approach

The difficulty with the BCNDP comes from the formulation of batch transportation costs and the many variables present in multi-period and multi-product problems. Therefore, in this section, we describe a simple heuristic ( $H_{BCNDP}$ ) which will be evaluated in the Section 2.5.

The proposed  $H_{BCNDP}$  works as follows :

1. Solve the single period version of the  $M_{BCNDP}$  ( $P_{SP}$ ) and save the arcs present in the optimal solution (or the best solution found within a predefined time limit) ;
2. Solve  $M_{BCNDP}$  while constraining the flow to use the saved arcs exclusively in Step 1.

The MILP formulation of the  $P_{SP}$  is the following :

- $X_{i,j}^k$  is the quantity of product  $k$  leaving entity  $i$  toward the entity  $j$ ,  $\forall(i, j) \in A$ ,  $\forall k \in K$
- $L_i^k$  is the quantity of product  $k$  leaving entity  $i$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$
- $A_i^k$  is the quantity of product  $k$  arriving to entity  $i$ ,  $\forall i \in P \cup W \cup D$ ,  $\forall k \in K$
- $Z_{i,j}$  is the required truck quantity from entity  $i$  to entity  $j$ ,  $\forall(i, j) \in A$

$$\begin{aligned} \text{Minimize} \quad & \sum_{(i,j) \in A} tc_{i,j} \times Z_{i,j} + (0.0)_{SP} \\ & \sum_{i \in P \cup W} pc_i \sum_{k \in K} A_i^k + (0.1)_{SP} \end{aligned}$$

s.t.

$$\begin{aligned} \sum_{i \in P \cup W} X_{i,j}^k &= A_j^k \quad \forall j \in N, \forall k \in K \quad (1.0)_{SP} \\ L_i^k &= \sum_{j \in N} X_{i,j}^k \quad \forall i \in P \cup W, \forall k \in K \quad (1.1)_{SP} \\ P_i^k + A_i^k &= L_i^k \quad \forall i \in P \cup W, \forall k \in K \quad (2.0)_{SP} \\ \sum_{k \in K} o^k \times X_{i,j}^k &\leq Z_{i,j} \quad \forall (i, j) \in A_R \quad (3.0)_{SP} \\ \sum_{k \in K} X_{i,j}^k &\leq Z_{i,j} \quad \forall (i, j) \in A_M \quad (3.1)_{SP} \\ X_{i,j}^k &\in \mathbf{Z}^+ \quad \forall (i, j) \in A, \forall k \in K \quad (4.0)_{SP} \\ L_i^k, A_i^k &\in \mathbf{R}^+ \quad \forall i \in N, \forall k \in K \quad (4.1)_{SP} \\ Z_{i,j} &\in \mathbf{Z}^+ \quad \forall (i, j) \in A \quad (4.2)_{SP} \end{aligned}$$

In this heuristic, we solve a simpler problem through a graph reduction (Morgan & Razouk, 1987) to find the most interesting arcs in the network, and we then use these interesting arcs exclusively to reduce the size of the problem.

We chose the single period version of the BCNDP as a simplification of the problem since this problem allows for preserving the economies of density. It may actually overestimate this effect since the aggregation of periods into a single one induces denser flows.

### 2.4.3 Lower Bound

In this section, we demonstrate that the  $P_{SP}$  solution represents a lower bound of the  $M_{BCNDP}$ . Let us note  $S(BCNDP)$  and  $S(P_{SP})$ , respectively, the optimal solution of the problems BCNDP and  $P_{SP}$ . We want to show that :

$$S(P_{SP}) \leq S(BCNDP).$$

First, we must relax the  $M_{BCNDP}$  model such that each constraint depends only on the sum for all periods of the variables. Summing temporally constraints (1.0), (1.1), (2.0), (3.0), (3.1), (4.0), (4.1) and (4.2) imply the following new constraints :

$$\sum_{t \in T} \sum_{i \in P \cup W | t - \tau_{i,j} \geq 0} x_{i,j}^{k,t-\tau_{i,j}} = \sum_{t \in T} a_j^{k,t} \quad \forall j \in N, \forall k \in K \quad (1.0)'$$

And as  $x_{i,j}^{k,t} = 0 \forall (i,j) \in A | t + \tau_{i,j} < 0$

$$\text{Then, } \sum_{i \in P \cup W} \sum_{t \in T} x_{i,j}^{k,t} = \sum_{t \in T} a_j^{k,t} \quad \forall j \in N, \forall k \in K \quad (1.0)'$$

$$\sum_{t \in T} l_i^{k,t} = \sum_{j \in N} \sum_{t \in T} x_{i,j}^{k,t} \quad \forall i \in P \cup W, \forall k \in K \quad (1.1)'$$

$$\sum_{t \in T} (p_i^{k,t} + a_i^{k,t} + s_i^{k,t-1} - s_i^{k,t}) = \sum_{t \in T} l_i^{k,t} \quad \forall i \in P \cup W, \forall k \in K \quad (2.0)'$$

And as  $s_i^{k,-1} = s_i^{k,|T|} = 0 \forall i \in P \cup W, \forall k \in K$

$$\text{Then, } \sum_{t \in T} p_i^{k,t} + \sum_{t \in T} a_i^{k,t} = \sum_{t \in T} l_i^{k,t} \quad \forall i \in P \cup W, \forall k \in K \quad (2.0)'$$

$$\sum_{k \in K} o^k \times \sum_{t \in T} x_{i,j}^{k,t} \leq \sum_{t \in T} z_{i,j}^t \quad \forall (i,j) \in A_R \quad (3.0)'$$

$$\sum_{k \in K} \sum_{t \in T} x_{i,j}^{k,t} \leq \sum_{t \in T} z_{i,j}^t \quad \forall (i,j) \in A_M \quad (3.1)'$$

$$\sum_{t \in T} x_{i,j}^{k,t} \in \mathbf{Z}^+ \quad \forall (i,j) \in A, \forall k \in K \quad (4.0)'$$

$$\sum_{t \in T} l_i^{k,t}, \sum_{t \in T} a_i^{k,t} \in \mathbf{R}^+ \quad \forall i \in N, \forall k \in K \quad (4.1)'$$

$$\sum_{t \in T} z_{i,j}^t \in \mathbf{Z}^+ \quad \forall (i,j) \in A \quad (4.2)'$$

Due to the absence of constraints on the variables representing the inventory level, and since the objective function minimizes the inventory cost (among the overall cost), variables  $s_i^{k,t}$ , as well as the inventory cost, are null in the optimal solution. Hence, we can simplify the objective function as follows :

$$\text{Minimize } \sum_{(i,j) \in A} tc_{i,j} \times \sum_{t \in T} z_{i,j}^t + \quad (0.0)'$$

$$\sum_{i \in P \cup W} pc_i \sum_{k \in K} \sum_{t \in T} a_i^{k,t} + \quad (0.1)'$$

Now, let us call  $P'$  this new MILP model.  $P'$  is a relaxed problem of the BCNDP. Consequently,  $S(P') \leq S(BCNDP)$ .

Finally, let us consider the variables  $X_{i,j}^k = \sum_{t \in T} x_{i,j}^{k,t} \forall (i,j) \in A, \forall k \in K$ ,  $A_i^k = \sum_{t \in T} a_i^{k,t}$  and  $L_i^k = \sum_{t \in T} l_i^{k,t} \forall i \in N, \forall k \in K$  and  $Z_{i,j} = \sum_{t \in T} z_{i,j}^t \forall (i,j) \in A$ , and  $P_i^k = \sum_{t \in T} p_i^{k,t} \forall i \in P \cup W$  the production at the node  $i$  of product  $k$ . For every solution of  $P'$ , we can find a solution of  $P_{SP}$  applying these variables' channeling. In conclusion, the optimal solution of the problem  $P'$  is necessarily a solution to the problem  $P_{SP}$ . Consequently,  $S(P_{SP}) \leq S(P')$ .

Now,  $S(P_{SP}) \leq S(P') \leq S(BCNDP)$ . So, the cost of the optimal solution of the described single-period model is a lower bound of the cost of the optimal solution of  $M_{BCNDP}$ . We denote this lower bound  $LB$  in the next section.

## 2.5 Computational Experiments

All the following experiments are computed with CPLEX 12.9 as a MILP solver using its Java API and run on an Intel Core i7-8850H CPU, 2.60GHz, and 64GB of RAM. All the data sets are industrial real-case scenarios from the automotive industry.

**Geographical scope** We consider all demands from car dealers in Italy. All centers in Europe and boarding the Mediterranean sea are candidate centers. Let us specify that the plants supplying Italy are in this geographical area. In brief, there are 13 plants, 57 centers, and 90 car dealers.

**Temporal scope** Demand data set comes from the demand in Italy in January 2019. We design 4 instances from this data set : 3 instances of 10 days of demand and 1 for the entire January demand, respectively called  $TD1$ ,  $TD2$ ,  $TD3$ , and  $M1$ . The temporal horizon is from 40 to 70 periods depending on the instance.

**Commodities scope** All demanded models of vehicles, both built-to-order and built-to-stock, by dealers in the geographical scope and during the temporal scope are in the product scope. 22 different models and thus 44 product types appear in the BCNDP (one built-to-order and one built-to-stock product by model).

In this section, we perform several numerical analyses :

First of all, the  $M_{BCNDP}$  and  $H_{BCNDP}$  performances are compared. The method showing the best performances is applied in the remaining tests.

Second, we analyze the impact of using batch road transportation cost in the BCNDP to examine the difficulty brought by this cost structure and verify the relevance of considering a batch cost rather than a classical transportation cost per product.

As a result of the negotiation with transportation service providers, the current management of the automotive constructor employs a sparser network than the network used in this paper. As a third group of experiments, we explore the impact of considering a denser network on the overall cost of the supply chain network design. We use in our numerical experiments an extended network whose costs are estimations (denoted  $ON$  standing for the original network).  $ON$  is the reference network for the experiments in this section.

Lastly, as the demand knowledge evolves over time, we are interested in the variability of our solution network when the demand fluctuates.

In this section, we denote  $C(<Method>)$  the cost of the solution of a method  $<Method>$  and the following gaps :

- ❖  $GAP(<Method>) = \frac{C(<Method>)-LB}{C(<Method>)} ;$
- ❖  $GAP(<Method\_1>, <Method\_2>) = \frac{C(<Method\_1>)-C(<Method\_2>)}{C(<Method\_1>)} .$

### 2.5.1 Performances

In this section, we want to select the best method to solve the BCNDP. Therefore, we compare the performances of the  $M_{BCNDP}$  with the  $H_{BCNDP}$ . Due to the difficulty

to solve the problem, we could not find solutions within a reasonable computation time. We run both methods for 1 hour of CPU.

Demand	Network	Method
$[TD1, TD2, TD3, M1]$	$ON$	$M_{BCNDP}$
		$H_{BCNDP}$

TABLE 2.3 – Performance tests designation

Table 2.3 shows the tests performed. Concerning the  $H_{BCNDP}$ , Step 1 runs for 30 minutes of CPU, and Step 2 for 30 minutes of CPU. The lower bounds found with the first step of  $H_{BCNDP}$  within the 30 minutes are better for all the instances compared to the lower bounds found by the commercial solver within one hour of search ( $-1.34\%$  better on average). Consequently, the lower bound considered in this section is  $LB$  for both methods  $M_{BCNDP}$  and  $H_{BCNDP}$ . Let us recall that  $LB$  is the lower bound found with the first step of  $H_{BCNDP}$  (single period version of the  $M_{BCNDP}$  for 30 minutes of computation time).

In Table 2.4, the  $GAP(M_{BCNDP})$  and  $GAP(H_{BCNDP})$  shows the performance of the two methods. We compare the solution quality of both approaches with  $GAP(M_{BCNDP}, H_{BCNDP})$ , see Table 2.4.

Instance	$GAP(M_{BCNDP})$	$GAP(H_{BCNDP})$	$GAP(M_{BCNDP}, H_{BCNDP})$
$TD1$	7.01%	5.16%	-1.99%
$TD2$	7.83%	4.96%	-3.12%
$TD3$	6.48%	5.61%	-0.93%
$M1$	7.02%	6.64%	-0.42%

TABLE 2.4 – Performance comparison between the  $M_{BCNDP}$  and  $H_{BCNDP}$

$H_{BCNDP}$  outperforms  $M_{BCNDP}$  with all instances and the  $H_{BCNDP}$  solutions are on average  $2.72\%$  better than the  $M_{BCNDP}$  ones. Moreover,  $LB$  shows better performances than the lower bound of the used solver and stands between  $4.96\%$  and  $6.64\%$  from  $C(H_{BCNDP})$ . In the rest of this paper, the applied method is the  $H_{BCNDP}$  since it reveals better performances than the  $M_{BCNDP}$ .

Let us note that in the instances, the transportation cost represents  $86.7\%$  of the total cost on average and without variation, followed by the handling cost representing  $12.6\%$  of the total cost and the inventory cost representing  $0.8\%$ . Consequently, the transportation cost most impacts the decisions. In the next section, we analyze how the transportation cost formulation influences the solutions.

### 2.5.2 Road transportation cost management

The automotive company's supply chain tends to consider road transportation costs calculated per vehicle type to make network design decisions, which brings us back to a more classical NDP in the literature. We refer to this case as  $R_{BCNDP}$  since it is a relaxation of the  $M_{BCNDP}$ . Since the actual cost is however charged per truck,

the current organization does not benefit from economies of density in trucks when making network design decisions. Therefore, we want to answer the three following questions :

- Does the complexity of the  $M_{BCNDP}$  come from its batch road cost formulation ?
- Could however the  $R_{BCNDP}$  be a good approximation of the  $M_{BCNDP}$  ?
- Can we use the  $R_{BCNDP}$  method to find a satisfying lower bound for the  $M_{BCNDP}$  ?

Besides, if in case of an increase in demand, we are interested in observing the evolution of the accuracy of the  $R_{BCNDP}$ . Therefore, we run similar tests raising product volumes by a factor of 2 and 3 (in an attempt to maintain the integer nature of products). We call these instances on demand variation respectively  $2\_TD1, 2\_TD2, 2\_TD3, 2\_M1, 3\_TD1, 3\_TD2, 3\_TD3$  and  $3\_M1$ . Summing up, we compare the performances of the  $H_{BCNDP}$  and  $R_{BCNDP}$  (see Table 2.5).

Network	Demand	Method
$ON$	$[TD1, TD2, TD3, M1]$	$H_{BCNDP}$
		$R_{BCNDP}$
	$[2\_TD1, 2\_TD2, 2\_TD3, 2\_M1]$	$H_{BCNDP}$
		$R_{BCNDP}$
	$[3\_TD1, 3\_TD2, 3\_TD3, 3\_M1]$	$H_{BCNDP}$
		$R_{BCNDP}$

TABLE 2.5 – Tests designation for the performance of the batch cost relaxation

The  $R_{BCNDP}$  is built from the  $M_{BCNDP}$  with the following alteration : the integer variable  $z_{i,j}^t$ , corresponding to the number of trucks from  $i$  to  $j$  at period  $t$ , is relaxed into a real number. Thus, road transportation cost  $\sum_{t \in T} \sum_{(i,j) \in A_R} tc_{i,j} \times z_{i,j}^t$  is equal to  $\sum_{t \in T} \sum_{(i,j) \in A_R} tc_{i,j} (\sum_{k \in K} o^k \times x_{i,j}^{k,t})$ . As a result, road transportation cost depends on product quantities. We run the  $R_{BCNDP}$  until optimal solutions are reached.

Table 2.6 gathers different indicators to discuss the relevance of the  $R_{BCNDP}$  compared to the  $H_{BCNDP}$ . On the one hand, we compare the computation time of the  $R_{BCNDP}$  with  $GAP(H_{BCNDP})$  to establish the solving difficulty contrast between both methods. On the other hand, to confront the quality of the solutions, the real costs of the  $R_{BCNDP}$  solutions are simulated and compared with  $C(H_{BCNDP})$ . Finally, we compare  $C(R_{BCNDP})$  (which represents a lower bound of the  $M_{BCNDP}$ ) with the value of our lower bound  $LB$  in Section 2.4.3.

Instance	Quality of the solution $GAP(\text{Real cost } R_{BCNDP}, H_{BCNDP})$	Quality of the lower bound $GAP(R_{BCNDP}, LB)$	Difficulty of the method	
			$GAP(H_{BCNDP})$	$R_{BCNDP}$ CPU (min)
TD1	+13.06%	-10.74%	5.16%	2
TD2	+9.74%	-4.23%	4.96%	11
TD3	+8.51%	-3.86%	5.61%	9
M1	+6.21%	-1.50%	6.64%	31

 TABLE 2.6 – Performance comparison between  $H_{BCNDP}$  and  $R_{BCNDP}$ 

As expected,  $R_{BCNDP}$  converges quicker to optimal solutions than  $H_{BCNDP}$ . CPLEX solves it in less than 15 minutes for the 10 days sized instances and in about 30 minutes for the instance of one entire month’s demand.

Nevertheless, the real costs of the solutions found with  $R_{BCNDP}$  are 6.21% to 13.06% higher than  $C(H_{BCNDP})$ . Hence, the  $M_{BCNDP}$  results in a better estimation of the field.

Lastly, as the  $R_{BCNDP}$  is a relaxation of the BCNDP, the cost of the solutions of the  $R_{BCNDP}$  represents lower bounds of the  $M_{BCNDP}$ . However, as  $C(R_{BCNDP})$  happen to be 1.50% to 10.74% lower than the value of  $LB$ ,  $LB$  appears to remain the best lower bound.

In the rest of Section 2.5.2, we attempt to understand the behavior disparities between the two methods.

First, we wonder if the  $R_{BCNDP}$  could be a satisfying approximation of the  $M_{BCNDP}$  under the assumption of a sufficient flow. Indeed, higher volumes imply fuller trucks and consequently less need for economies of density. Therefore, we conduct the following theoretical experiment : running the same tests but multiplying the demand of the dealers by two and three, see Table 2.5.

Table 2.7 gives  $GAP(\text{Real cost } R_{BCNDP}, H_{BCNDP})$  for the original, double, and triple demand. In brackets, we precise the impact of the volume multiplication for the same instance on this indicator (percent decrease compared to the optimal demand case).

Instance	Demand	$2 \times \langle \text{Instance} \rangle$	$3 \times \langle \text{Instance} \rangle$
TD1	+13.06%	+5.17% (-60.38%)	+2.65% (-79.70%)
TD2	+9.74%	+3.92% (-59.70%)	+2.36% (-75.79%)
TD3	+8.51%	+3.78% (-55.55%)	+2.08% (-75.59%)
M1	+6.21%	+1.87% (-69.96%)	+1.42% (-77.08%)

 TABLE 2.7 – Impact of the demand volume multiplication on the cost difference between the solutions of the  $R_{BCNDP}$  and  $H_{BCNDP}$ 

Table 2.7 shows that  $GAP(\text{Real cost } R_{BCNDP}, H_{BCNDP})$  reduces on average by 61% when the demand doubles and by 77% when the demand triples. A possible explanation is that, as the truck fill rate increases in the solutions, the  $R_{BCNDP}$  becomes a better approximation of the BCNDP (see Figure 2.4).

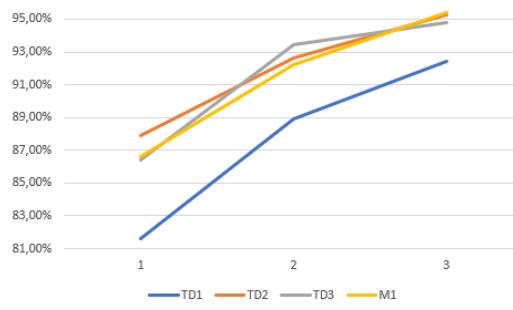


FIGURE 2.4 – Trucks fill rate with  $H_{BCNDP}$  according to the demand volume multiplication factor

Second, we wonder if the flow densification incentive in our problem increases the use of indirect flows. Therefore, we compare the rate of flow quantity reaching a dealer by direct flow in the solutions of both methods. Table 2.8 is built the same way as Table 2.7 considering the direct flow rate in solutions.

Instance	Demand	$2_{<Instance>}$	$3_{<Instance>}$
TD1	+6.12%	+3.06% (-50.00%)	+2.45% (-60.00%)
TD2	+2.15%	+0.91% (-57.55%)	+0.81% (-62.26%)
TD3	+2.47%	+1.01% (-59.09%)	+0.94% (-62.12%)
M1	+1.11%	+0.36% (-67.86%)	+0.30% (-72.62%)

TABLE 2.8 – Direct flow rate with  $H_{BCNDP}$  and  $R_{BCNDP}$

Table 2.8 reveals that demand volume multiplication reduces the rate of direct flows disparities between the solutions of the two methods and that the solutions of the  $H_{BCNDP}$  systematically contain less direct flows than the solutions of the  $R_{BCNDP}$ . In conclusion, the realized tests show a correlation between the flow densification incentive and the rise of the indirect flow rate.

### 2.5.3 Network availability

The industrial use of the BCNDP resolution includes the evaluation of new routes and centers to improve the supply chain network. However, the network employed in the automotive company is composed of negotiated real costs and routes (called *NN* standing for negotiated network). This network contains 9.5% fewer arcs than *ON*. It potentially gathers the most relevant arcs since they have been selected during previous network design studies by the automotive company as routes of high potential to negotiate. Does the size of the network impact nevertheless the behavior of the model ?

Demand	Network	Method
$[TD1, TD2, TD3, M1]$	$ON$	$H_{BCNDP}$
	$NN$	$H_{BCNDP}$

TABLE 2.9 – Tests designation for the impact of the network availability

In this section, we compare the solutions of the  $H_{BCNDP}$  method using  $ON$  and  $NN$  (see Table 2.9). Table 2.10 contains the gap between the costs of the solutions of the  $H_{BCNDP}$  using the  $ON$  and the  $NN$ . Since the BCNDP with the  $NN$  corresponds to the BCNDP with the  $ON$  with additional constraints on the network, the  $NN$  input cannot lead to better optimal solutions than the  $ON$ . It might however lead faster to some satisfying solutions, as it implies fewer variables in the model. As the lower bounds of both network configurations differ, comparing the performance of  $H_{BCNDP}$  under  $ON$  and  $NN$  is interesting.

Instance	$GAP(H_{BCNDP} \text{ with } NN, H_{BCNDP} \text{ with } ON)$	$GAP(H_{BCNDP} \text{ with } NN) - GAP(H_{BCNDP} \text{ with } ON)$	New arcs use rate with $H_{BCNDP}$ and $ON$
$TD1$	+1.91%	-1.51%	8.37%
$TD2$	+0.04%	-1.47%	3.55%
$TD3$	+0.44%	-0.72%	2.61%
$M1$	+1.74%	+0.92%	1.62%

 TABLE 2.10 – Performance comparison between  $H_{BCNDP}$  with  $ON$  and  $NN$ 

Given the results in Table 2.10, using  $ON$  leads to  $C(H_{BCNDP})$  on average 1.03% better compared with the use of the  $NN$ . Given this relatively small improvement, the preselection of arcs in the  $NN$  appears sufficient. The results show that the expert judgment in selecting arcs in  $NN$  is efficient. In addition, since the problem with  $NN$  contains fewer variables than with the  $ON$ , we also observe a slightly better  $GAP(H_{BCNDP})$ .  $GAP(H_{BCNDP})$  is, on average, improved by 0.70% using the  $NN$ .

Finally, we are interested in the rate of products going through the new arcs that are absent in  $NN$  but are present in  $ON$  (see the last column of Table 2.10). These rates, varying between 1.62% and 8.37%, represent the percentage of products transported through the new arcs. We observe that the smaller the planning horizon is, the higher the rate of products going through the new arcs. Yet, we cannot determine any correlation between these rates and the improvement in  $C(H_{BCNDP})$  with  $ON$ .

However, even though the cost savings are not very important in the case of  $ON$ , the results are interesting for the company to observe alternative routes. As a managerial implication, we recommend using a network as complete as possible in the first negotiation phase with transporters in order to see all the route opportunities. In the subsequent phases, when route costs are refined, reducing the number of routes (removing unbeneficial routes) might be advantageous to converge faster to the best solutions.

### 2.5.4 Sensitivity study

The demand can fluctuate over time (demand quantities and built-to-order mix). Yet, is the network proposed by  $H_{BCNDP}$  applicable despite variations in demand and the product mix ?

In order to answer that question, we first gather networks in the solutions of our instances ( $TD1$ ,  $TD2$ ,  $TD3$ , and  $M1$ ). Let us note that  $H_{BCNDP}$  may give a different network for each instance. We denote these networks, respectively  $GN\_TD1$ ,  $GN\_TD2$ ,  $GN\_TD3$ , and  $GN\_M1$  standing for generated network. In the case of the industrial application, the generated network will be used to transport the products from manufacturing plants to dealers, regardless of daily fluctuations in demand or the product mix.

To simulate the demand variation between the moment we set the network and the moment we realize the flow, we assign random modifications on the demand quantity (bound to more or less 25% of the quantity) and random substitutions between built-to-order and built-to-stock management (with a 25% of chance). We denote the new demand instances  $V\_TD1$ ,  $V\_TD2$ ,  $V\_TD3$ , and  $V\_M1$ .

First, we run  $H_{BCNDP}$  using these new instances with  $ON$  to observe the solutions when the network is not previously set. Second, we constrain  $H_{BCNDP}$  to use the generated networks with the new instances. Thus, we obtain the number of products that go through each route on the generated network. Finally, we compare the cost of the solutions to both problems in order to observe the variability of the generated networks against the variations in demand's quantity and mix. The gap between the cost of the solutions and the lower bounds is also compared.

Table 2.11 shows the different input settings for this section and Table 2.12 summarizes the results of the numerical tests.

Demand	Network	Method
$[V\_TD1, V\_TD2, V\_TD3, V\_M1]$	$ON$	$H_{BCNDP}$
	$[GN\_TD1, GN\_TD2, GN\_TD3, GN\_M1]$	$H_{BCNDP}$

TABLE 2.11 – Tests designation for the sensitivity study

Instance	$GAP(H_{BCNDP} \text{ with generated networks}, H_{BCNDP} \text{ with } ON)$	$GAP(H_{BCNDP} \text{ with generated networks}) - GAP(H_{BCNDP} \text{ with } ON)$
$V\_TD1$	-0.06%	-0.84%
$V\_TD2$	-0.38%	-0.78%
$V\_TD3$	-0.43%	-0.87%
$V\_M1$	+0.34%	+0.17%

TABLE 2.12 – Performance comparison between  $H_{BCNDP}$  with generated networks and  $ON$  after variation applied on demand

Table 2.12 shows that  $C(H_{BCNDP})$  using  $ON$  remains relatively similar when presetting the generated networks. It even reduces the cost of the solutions of  $TD1$ ,

$TD2$ , and  $TD3$ . Indeed, the generated networks imply fewer variables in the problems than  $ON$ , thus allowing better solutions within the computation time limit. Consequently, despite demand fluctuation, the action to preset generated networks does not negatively impact the cost of the solutions within the computation time limit. Thus, the obtained network with  $H_{BCNDP}$  remains a good solution despite possible demand fluctuation. Lastly, the gap between the cost of the solutions and  $LB$  improves by 0.58% on average when using the generated networks.

## 2.6 Conclusion

The production and demand of the automotive industry evolve constantly. The recent semiconductor shortage and the Covid19 pandemic crisis intensified this effect. Automotive companies thus need powerful and adaptable tools to organize their supply chain network design. SCND problems are complex problems that support network design decisions while considering interrelated tactical and strategic objectives.

We study a multi-product multi-period NDP with a specific transportation cost structure. We introduce this new problem as the Batch Cost Network Design Problem (BCNDP). The BCNDP is adapted to the automotive constructor's industrial requirements involving complex transportation cost estimation. We use real data from real industrial scenarios. We propose a MILP formulation of the problem. To tackle the solving difficulty induced by the transportation cost, we also create a simple heuristic and a lower bound based on the equivalent single period BCNDP.

The heuristic reaches better solutions than the MILP formulation. The lower bound is an improvement over the best estimate found by the used commercial solver within the considered computation time. The road transportation cost formulation needs to remain proportional to the number of trucks. Indeed, a version where the cost is proportional to the number of vehicles yields less satisfying solutions. We prove that using a denser network leads to better solutions and highlights new road opportunities. We, therefore, advise the automotive constructor to use a denser network compared to the sparse network that is currently in place. Finally, a sensitivity study shows that the obtained network is robust when the demand fluctuates.

The automotive company would benefit from incorporating additional aspects. For instance, integrating lead times would allow studying the trade-off between cheaper but slower transportation paths and the maximum lead times tolerated by customers. One of the challenges in the coming years is to decarbonize the supply chain of the automotive constructor. Adding this cost to the problem would be profitable as costing carbon emissions becomes achievable. Lastly, introducing transportation mode choices and including rail transportation can be a promising area for improvement. Rail transportation has great potential due to environmental benefits and its capacity to endorse economies of scale.

Regarding solving methods, numerous metaheuristics are proven effective for solving complex SCND problems (Gupta & Könemann, 2011) and could improve the quality

of the solutions. On the other hand, further research focuses on evaluating the right data precision level. In fact, the problem's difficulty could be addressed by studying the right level of aggregation of the input data for a particular problem and thus reducing the size of this problem.



# Chapitre 3

## A quantitative study of data aggregation for a network design problem

### Abstract

This paper proposes a systematic analysis of the impact of data aggregation for a multi-product multi-period supply chain network design problem. This optimization problem aims to design the vehicle distribution network of an automotive manufacturer. Due to the size of the problem and complex industrial constraints, aggregation of input data is a natural way to help solution methods to converge towards good solutions. Three aggregation dimensions are considered : product type, spatial, and temporal, and for each of them, different levels. We propose an aggregation-disaggregation methodology to study the impact of these aggregations on the quality of the obtained solutions. Numerical experiments show the effectiveness and limitations of data aggregation for this type of problem.

### Keywords

Supply chain network design, Automotive industry, Input aggregation, Data-driven.

### 3.1 Introduction

Supply Chain Network Design (SCND) problems are known to be difficult to solve. In the last twenty years, solving these problems has become a real challenge due to the integration of more realistic industrial constraints (Gupta & Könemann, 2011). A natural way to cope with this difficulty is to reduce the model size by aggregating the input data. Data aggregation can also meet other objectives, such as addressing the absence of specific data or reducing uncertainty (Francis et al., 2009).

The aggregation of input data raises three major challenges : (a) which data to aggregate (b) to what extent, and (c) how to interpret solutions obtained using aggregated data.

To address the first challenge, we consider three aggregation dimensions : product type (product characteristics), spatial (geographical locations), and temporal (planning periods).

Addressing the second challenge requires an appropriate trade-off between the approximations resulting from the level of input aggregation and the ease of solving the model (Rogers et al., 1991). To find the right balance, we propose several aggregation levels for each aggregation dimension.

Finally, the third challenge highlights that the model with aggregated inputs may not return solutions representative of the original model (Rushton, 1989). Since the aggregation of the input introduces a loss of information, disaggregation methods must be used. This paper proposes two disaggregation methods that allow us to reconstruct feasible solutions to the original problem.

This systematic analysis of the impact of input aggregation is performed on a vehicle distribution problem of an automotive manufacturer. The problem consists of defining transport flows by road and sea to transport vehicles from plants to car dealerships. It is characterized as a multi-period multi-product Network Design Problem (NDP), with transportation costs per batch, a property that complicates its resolution considerably (see **Chapter 2**).

Input data aggregation is not a new technique. Many research studies use it, for example, spatial aggregation (Francis et al., 2009). Articles containing product type aggregation or temporal aggregation are more scarce. Most often, these studies use aggregation to ease the resolution of the problem or as a first phase of a resolution method. However, to our knowledge, none of them propose a detailed methodological approach to this problem (Ballou, 2001)(Francis & Lowe, 1992) or a systematic study of aggregation dimensions and levels. This paper attempts to fill this gap by proposing a methodology applicable to other types of problems and by providing concrete conclusions for the industrial case study.

This article is organized as follows. Section 3.2 presents a brief state-of-the-art on data aggregation to solve SCND problems. Section 3.3 describes the multi-

product, multi-period tactical NDP from an automobile manufacturer. The aggregation-disaggregation methodology is proposed in Section 3.4. In Section 3.5, the numerical experiments present a systematic analysis of aggregation levels and dimensions and show the effectiveness of some data aggregations and the approach's limitations. Section 3.6 concludes the paper and gives future perspectives.

## 3.2 Literature review

We present the literature review according to the three dimensions of aggregation considered in this study : product type, spatial and temporal.

### 3.2.1 Product type aggregation

We found few studies of the impact of product type aggregation on a SCND problem. Geoffrion (1977) analyzes the error induced by aggregation on the objective value of an inbound logistic planning problem. Kazemi et al. (2021) propose a partial product type aggregation over a subset of the network to limit the impact of aggregation on the precision of the results of a fixed-charge NDP. Various sizes of partial aggregation are considered in their study.

In Koca & Yıldırım (2012) a product type aggregation is used as a first step of a heuristic to solve a multi-commodity distribution problem with fixed assignment costs. They prove that the hierarchical heuristic outperforms the Mixed-Integer Linear Programming (MILP) formulation of their problem, notably when large instances are involved.

Using a different approach, Vanek (2001) looks for the right product type aggregation level for the spatial redistribution of freight distribution patterns. The inputs are initially on a high level of aggregation. Then, data disaggregation is applied, and the added value is characterized.

Table 3.1 gathers articles dealing with product type aggregations of SCND problems.

	Complexity		Objective of the study			
	Product	Period	Input aggregation	Heuristic	Model refining	Industrial application
Geoffrion (1977)	multi	mono	*			
Vanek (2001)	multi	mono			*	freight distribution
Koca & Yıldırım (2012)	multi	mono		*		automotive industry
Kazemi et al. (2021)	multi	mono	*			
This paper	multi	multi	*			automotive industry

TABLE 3.1 – Literature on product type aggregation of a SCND model

### 3.2.2 Spatial aggregation

A whole range of studies aims at quantifying the error induced by spatial aggregation on the objective value of a SCND problem. Usually, it concerns location problems. As spatial aggregation reduces the geographical size of a location problem, it has the potential to lead quickly to an optimal solution. Interested readers can refer to Francis et al. (2009) for a review of the literature published dealing with spatial aggregation error for location models. Gavriliouk (2009) estimate the maximum error induced by spatial aggregation on a hub location problem and integrate their result into a heuristic. Qi & Shen (2010) study the worst-case scenario of spatial aggregation for the euclidean p-median problem and prove the effectiveness of their “multi-pattern tiling” approach as aggregation strategy. Regarding research on stochastic location problems, Klibi et al. (2016) discuss, in their review of stochastic location-allocation models, the impact of spatial and temporal aggregation on the quality of the solution. Zipkin (1982), and Mulvey & Vladimirou (1991) study the impact of spatial aggregation on the robustness of the solutions. Moreover, the impact of spatial aggregation on robustness is addressed in continuous approximation models (Ansari et al., 2018). Finally, Horner & O’Kelly (2005) formulate the hierarchical assignment problem integrating spatial aggregation of the demand within the very model. Cebecauer & Buzna (2017) also propose a method integrating the choice of the aggregation level within the model. They apply this method to two location-allocation problems. To our knowledge, both these studies are relatively unique and differ from all the quoted papers in this literature review.

Numerous studies use spatial aggregations as part of a multi-step heuristic to solve a SCND problem. A common heuristic consists of applying spatial aggregations to set global decisions and afterward solving all the sub-problems. This method is, for example, efficient for solving the p-hub location problem, as it implies allocation decisions that can be set in the first clustering phase (Klincewicz, 1991). Kijmanawat & Ieda (2005) solve a large-sized multilevel hierarchical hub location problem thanks to a first clustering phase and a hybrid meta-heuristic to solve the sub-problems in a second phase. S. Esnaf & Küçükdeniz (2009) also present a two-phase method to

solve the multi-facility location problem. Customers are clustered to set the location of facilities in the first phase. Then sub-problems are solved in the second phase. Sheu & Lin (2012) show a three-phase clustering heuristic for the hierarchical network planning model for global logistics. Avella et al. (2012) spatially aggregate clients with facilities to reduce the size of instances within a heuristic.

Suárez-Vega et al. (2011) take an interest in the competitive network location problem and analyze the behavior of their model when using two different levels of spatial aggregation. They prove the benefit of using the refined input data since spatial aggregation significantly influences the shape of the solutions. McCormack & Coates (2015) estimate the distance error induced by the spatial aggregation in their vehicle fleet allocation and station location.

Table 3.2 gathers articles dealing with spatial aggregations of SCND problems.

	Complexity		Objective of the study			Industrial application
	Product	Period	Input aggregation	Heuristic	Model refining	
Zipkin (1982)	mono	mono	*			
Mulvey & Vladimirov (1991)	mono	multi	*			
Klincewicz (1991)	mono	mono		*		air transportation
Horner & O'Kelly (2005)	mono	mono	*			
Kijmanawat & Ieda (2005)	mono	mono		*		
Francis et al. (2009)	mono	mono	*			
S. Esnaf & Kügündeniz (2009)	mono	mono		*		construction industry
Gavriliouk (2009)	mono	mono	*	*		
Qi & Shen (2010)	mono	mono	*			
Suárez-Vega et al. (2011)	mono	mono			*	hypermarket location
Sheu & Lin (2012)	mono	mono		*		delivery company
Avella et al. (2012)	mono	mono		*		
McCormack & Coates (2015)	mono	multi			*	ambulance service
Klibi et al. (2016)	mono	multi	*			
Cebecauer & Buzna (2017)	mono	mono	*			
Ansari et al. (2018)	multi	multi	*			
This paper	multi	multi	*			automotive industry

TABLE 3.2 – Literature on spatial aggregation of a SCND model

### 3.2.3 Temporal aggregation

Klibi et al. (2016) refer to temporal aggregation in their literature review on stochastic location-allocation models, but no article deals directly with the impact of temporal aggregation of SCND problems.

Considering aggregation for heuristic purposes, Amiri-Aref et al. (2018) solve a multi-period location inventory problem with a two-step heuristic. They use the equivalent single-period problem to set open warehouses in the first step and determine the values of the remaining variables in the second step.

Studying the “value” of refining the temporal granularity of a SCND model is a

common practice. Due to the size explosion of multi-period models, developing a simple mono-period model and then looking at the advantage of refining the temporal aspects is an intuitive and usually efficient process. Alumur et al. (2012) apply this process to solve the reverse logistics network design. Meisel et al. (2013) study a combining production and intermodal transportation planning in a supply network and compare the solutions of the multi-period model with the equivalent single period model that is temporally sequentially disaggregated. Kchaou-Boujelben et al. (2016) show the impact of the demand seasonality on a facility location problem under multiple operational constraints for the automotive industry by comparing the solutions of a 4-period model with the solutions of a single period model.

Table 3.3 gathers articles dealing with temporal aggregations in SCND problems.

	Complexity		Objective of the study			Industrial application
	Product	Period	Input aggregation	Heuristic	Model refining	
Alumur et al. (2012)	multi	multi			*	household machine industry
Meisel et al. (2013)	multi	multi			*	chemical industry
Klibi et al. (2016)	multi	multi	*			
Kchaou-Boujelben et al. (2016)	multi	multi			*	automotive industry
Amiri-Aref et al. (2018)	mono	multi			*	
This paper	multi	multi	*			automotive industry

TABLE 3.3 – Literature on temporal aggregation of a SCND model

### 3.2.4 Conclusion

In the literature, we observe different uses of input aggregation for SCND problems. Some papers' objective is to study the impact of aggregation on a model. Our study belongs to this category. Other studies use input aggregation for different purposes than the size reduction of a SCND model. Input aggregation can be used as the first step of a heuristic to reach good solutions faster or to find an upper bound of the objective. Studies can also have a different approach, analyzing the “value” of refining the input of a model.

To our knowledge, articles containing analyses of the impact of different aggregation dimensions on a SCND problem are scarce. Only Klibi et al. (2016) discuss the demand granularity in terms of product types, clients, transportation, and periods for the stochastic location-allocation problem. Besides, most of the encountered studies

focus on spatial aggregations. Lastly, we did not encounter industrial applications whose purpose is to quantify the influence of input aggregation on a SCND problem. Regarding studies using input aggregation for heuristic purposes and different approaches attempting to refine the input detail, they do not implement more than one aggregation dimension and usually compare only two or three aggregation levels.

### 3.3 Problem description

We consider a tactical NDP in the automotive industry. It involves finding the least costly strategy to bring finished products (vehicles) from plants to car dealerships.

We refer to entities for the geographical plants, centers, or dealers. As shown in Figure 3.1, the plant produces different vehicles. Then products can be transported to a dealer via a direct flow (usually by road transportation). Lastly, dealers consume vehicles. It is possible to transport products via indirect flow. Overseas or road routes toward a center can be used as indirect flow to the final dealer. Theoretically, each section between two entities is possible except for the following cases : (1) The network is limited in some ways by the availability of the negotiated transportation costs, (2) the low frequency of sea transportation, (3) fiscal constraints, and (4) the fact that milk runs among dealers are not considered.

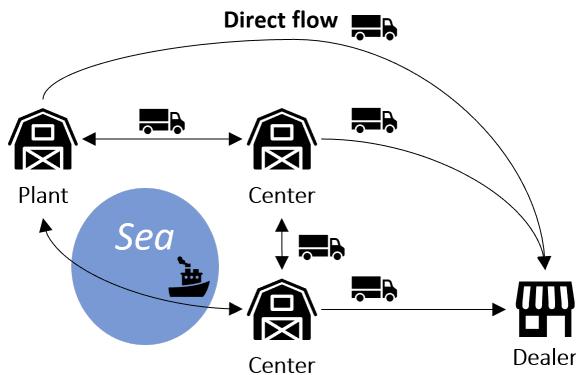


FIGURE 3.1 – Network example

The products are defined by vehicle type and order type. The vehicle type determines where the vehicle is produced and the truck fill rate of a product. The knowledge of the origin plant ensures the proper product to arrive at the right dealer. The fill rate is used to determine the number of trucks required between two entities and thus the road transportation cost. The order types are built-to-order or built-to-stock product management. Built-to-stock products are under fiscal constraints, meaning that they cannot use direct flows and can only use specific centers.

The objective is to choose the centers and routes to use and organize the product flow and inventory through the network. The objective is to minimize the cost of the flow solution. This cost contains :

- road transportation costs per truck,

- sea transportation costs per product,
- center handling costs per product,
- center inventory costs per product and per day.

The road transportation cost is a negotiated cost with transportation service providers. It is charged per truck and differs on each route section. The sea transportation cost is also negotiated for each sea route section and is charged per product. The center handling cost is a handling cost at the entry of each center. Lastly, the inventory cost is the negotiated cost for daily product storage.

A MILP model formulation to this problem is proposed in **Chapter 2**. It is referred as the Batch Cost Network Design Problem (BCNDP) in what follows.

### 3.4 Methodology

We now describe the methodology (see Figure 3.2). This methodology is applicable for data aggregation in other problems with product type, temporal, or spatial dimensions and in particular to the SCND problem.

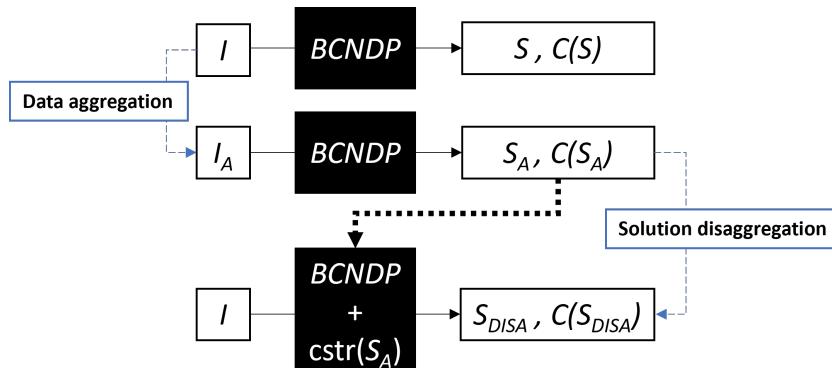


FIGURE 3.2 – Methodology

The original instance used as input of the BCNDP is noted  $I$ . The solution of the BCNDP obtained for instance  $I$  after a limited computation time  $TL$  is noted  $S$ . The cost of this solution is  $C(S)$ , and the corresponding lower bound given by the MILP model is denoted  $LB(S)$ .

We realize input aggregation on  $I$  leading to instance  $I_A$ . Solving BCNDP with instance  $I_A$  leads to solution  $S_A$  and its corresponding cost  $C(S_A)$ .

Solutions  $S$  and  $S_A$ , and therefore  $C(S)$  and  $C(S_A)$ , are not comparable, since we lose precision due to aggregation. A disaggregation method must be used for a fair comparison. The disaggregation method uses instance  $I$  and the BCNDP model to which we add the characteristics of  $S_A$  (a set of constraints  $cstr(S_A)$ ). We thus obtain a disaggregated solution  $S_{DISA}$  with cost  $C(S_{DISA})$ .  $S_{DISA}$  can now be compared with  $S$  since these solutions are obtained with the same input  $I$  and the same BCNDP

model, except that  $S_{DISA}$  results from an overconstrained version of the BCNDP model.

We describe, in this section, the aggregation process for product type, spatial, and temporal dimensions. We present two disaggregation methodologies. Lastly, we depict the evaluation of the impact of aggregation on the BCNDP model.

### 3.4.1 Data aggregation

The flow variable in the BCNDP model (see **Chapter 2**) is  $x_{i,j}^{k,t}$ , the quantity of products  $k$  leaving the facility  $i$  at period  $t$  to go to facility  $j$ ,  $\forall(i, j) \in N^2$ ,  $\forall k \in K$  and  $\forall t \in T$ . Input aggregation is, thus, a lever for reducing the size of the sets  $K$  for the product axis,  $N$  for the spatial axis, and  $T$  for the temporal axis, and as a result, simplifies the BCNDP model's resolution. Accordingly, we consider three aggregation dimensions : product type (product characteristics), spatial (geographical locations), and temporal (planning periods). From a network point of view, the product type dimension influences the flows (arcs), while the spatial and temporal aggregations modify the structure (nodes) of the network (see Figure 3.3).

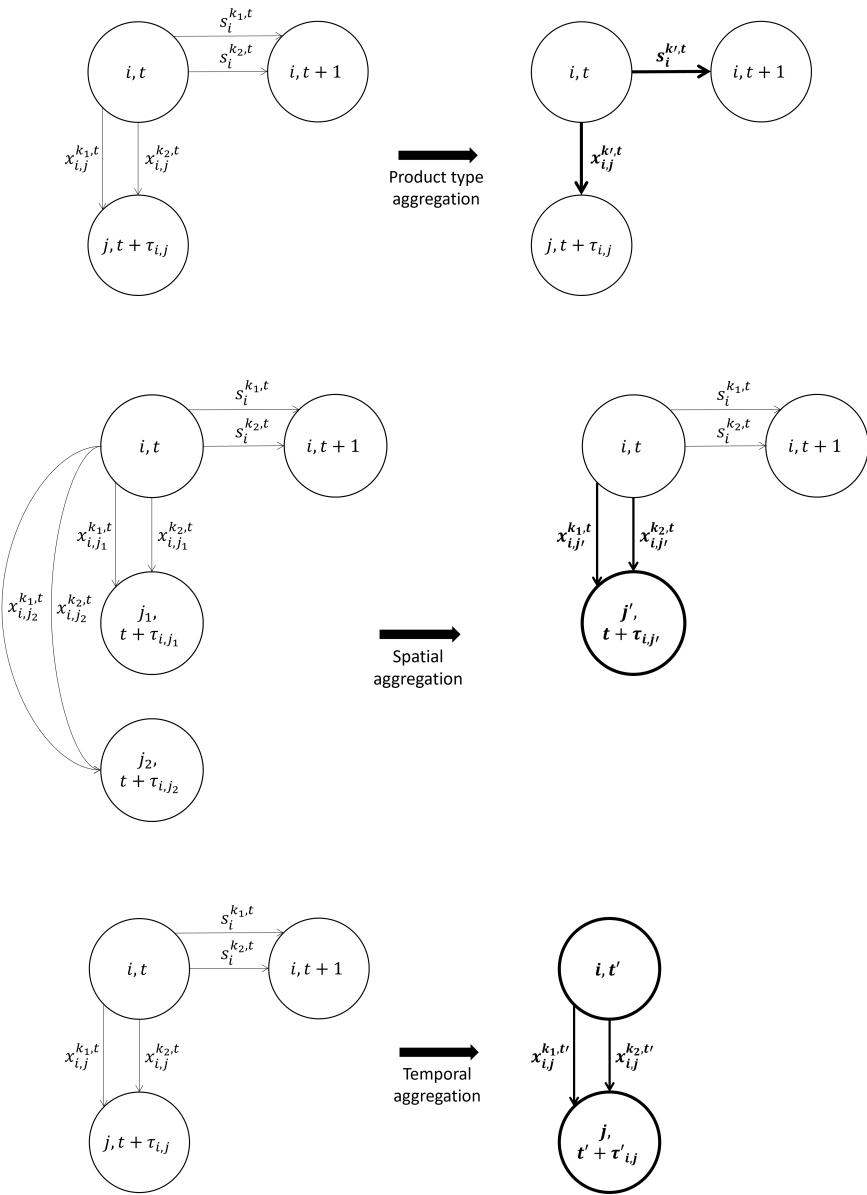


FIGURE 3.3 – Example of aggregation implications

If an aggregation dimension (product type, spatial, or temporal) causes alterations in these data, we precise the aggregated information that leads to data approximations (see Table 3.4 and 3.5).

Data	Product type	Spatial	Temporal
Transportation cost		Dealer	
Handling cost			
Inventory cost			Period
Produced quantity	Vehicle, order, period		Period
Demand quantity	Vehicle, order	Dealer	
Truck fill rate of a product	Vehicle		
Transportation duration		Dealer	Period
Sea transportation frequency			Period

TABLE 3.4 – Input data structure

Product type aggregation induces approximations of the produced and demand quantities and the truck fill rate. Spatial aggregation induces approximations of the transportation cost, the transportation duration, and the demand quantity. Finally, temporal aggregation induces approximations of the inventory cost, the produced quantity, transportation duration, and sea transportation frequency.

Data	Product type	Spatial	Temporal
Product quantity on an arc at one period	Vehicle, order, period	Dealer	Period
Product quantity stored at a center at one period	Vehicle, order, period		Period
Truck quantity on an arc at one period	Vehicle, period	Dealer	Period

TABLE 3.5 – Output data structure

Each aggregation dimension causes alterations in nearly all output data. Only stored quantities are not affected by spatial aggregation in our case study since only dealers are concerned with spatial aggregation, and dealers do not store products.

Some levels of aggregation are irrelevant, given the field applications. For example, excessive spatial aggregation might not be beneficial since the highest level of decision consists of defining centers and routes to use. So how can we define a maximum level of aggregation ? We suggest the following convention. The maximum aggregation level is the highest level of aggregation that guarantees the feasibility of  $S_{DISA}$  despite the additional constraints  $cstr(S_A)$  in the BCNDP. Some exceptions made in practice are explained in the following sections.

### 3.4.1.1 Product type aggregation

This aggregation dimension contains two sub-categories : the order type and the vehicle type.

Concerning the order type aggregation, only built-to-order products are aggregated into built-to-stock, because if we relax the fiscal constraint on built-to-stock products (direct flows allowed), the geographical feasibility of the solutions is not ensured.

Regarding levels of aggregation, we aggregate built-to-order products with the built-to-stock products vehicle type by vehicle type (see the vertical axis of Table 3.6). This strategy allows for controlling the reduction of the number of decision variables. For example, aggregating all the *CLIO* in built-to-order with the *CLIO* in built-to-stock enables us to have a single product in  $I_A$  to represent the *CLIO* type of vehicle instead of two in  $I$  (see the horizontal axis of Table 3.6). The maximum level of aggregation is reached when all products are aggregated into built-to-stock products.

Order type	Vehicle type		
	<i>CLIO</i>	...	<i>Megane</i>
built-to-order	( <i>CLIO, BTO</i> )	...	( <i>Megane, BTO</i> )
built-to-stock	( <i>CLIO, BTS</i> )	...	( <i>Megane, BTS</i> )

↔      ↓

Vehicle type aggregation      Order type aggregation

TABLE 3.6 – Two aggregation sub-dimensions for product type

We propose the following MILP formulation for the order types aggregation.

### Input data

- $K$  is the set of products ;
- $d_k$  is the total demand quantity of product  $k$ ,  $\forall k \in K$  ;
- $m_{k_1, k_2}$  is equal to 1 if  $k_1$  and  $k_2$  are the same vehicle type (one built-to-order and one built-to-stock), 0 otherwise,  $\forall (k_1, k_2) \in K^2$  ;
- $G$  is the set of clusters.

### Variables

- $x_{k,g}$  is equal to 1 if product  $k$  is in cluster  $g$ , 0 otherwise,  $\forall k \in K, \forall g \in G$  ;
- $y_{k_1, k_2}$  is equal to 1 if products  $k_1$  and  $k_2$  are in the same cluster, 0 otherwise,  $\forall (k_1, k_2) \in K^2$ .

The objective function of the order types aggregation is given in equation (P.0.Order). This aggregation does not induce any data approximations. However, some arcs become unusable due to fiscal constraints applied to aggregated built-to-order products into built-to-stock. Consequently, the more built-to-order products are aggregated with built-to-stock products, the more over-constrained the model. The objective is hence to minimize the demand for built-to-order and built-to-stock products clustered together.

$$\text{Minimize} \quad \sum_{(k_1, k_2) \in K^2} (d_{k_1} + d_{k_2}) \times y_{k_1, k_2} \quad (\text{P.0.Order})$$

s.t.

$$\sum_{g \in G} x_{k,g} = 1 \quad \forall k \in K \quad (\text{P.1})$$

$$x_{k_1,g} + x_{k_2,g} - 1 \leq y_{k_1,k_2} \quad \forall (k_1, k_2) \in K^2, \forall g \in G \quad (\text{P.2})$$

$$y_{k_1,k_2} \leq m_{k_1,k_2} \quad \forall (k_1, k_2) \in K^2 \quad (\text{P.3.Order})$$

$$x_{k,g} \in \{0, 1\} \quad \forall k \in K, \forall g \in G \quad (\text{P.4})$$

$$y_{k_1,k_2} \in \{0, 1\} \quad \forall (k_1, k_2) \in K^2 \quad (\text{P.5})$$

A product type is allocated to a single cluster (P.1). The channeling constraint is (P.2). We aggregate built-to-order products with built-to-stock products having similar vehicle types (P.3.Order).

The vehicle type aggregation includes a truck fill rate and an origin (a plant) data (see Section 3.3). We propose assessing the average truck fill rate of the vehicle types aggregated together as the truck fill rate of the new vehicle type in  $I_A$ . We limit the vehicle types aggregation for vehicles produced in the same plant. Indeed, the origin of a vehicle must be guaranteed to satisfy the demand. In  $I$ , a vehicle type is built in a single plant. With all that in mind, we could aggregate the *CLIO* with the *Megane* if they are produced in the same plant. We would obtain 2 product types ((*CLIO – Megane, BTO*) and (*CLIO – Megane, BTS*)) instead of 4 (see Table 3.6). The maximum level of aggregation contains two vehicle types by plants (one per order type).

The MILP formulation for the vehicle types aggregation is slightly different.

### Input data

- $K$  is the set of products ;
- $o^k$  is the load factor of product  $k$  in a truck,  $\forall k \in K$  ;
- $m_{k_1,k_2}$  is equal to 1 if  $k_1$  and  $k_2$  are the same vehicle type (one built-to-order and one built-to-stock), 0 otherwise,  $\forall (k_1, k_2) \in K^2$  ;
- $G$  is the set of clusters.

Variables are similar to those of the order types clustering.

The objective function for the vehicle types clustering is given in (P.0.Vehicle). The truck fill rate of aggregated vehicle types is approximated. In order to limit the level of approximation, the objective is to minimize the fill rate difference between product types within the same cluster.

$$\text{Minimize} \quad \sum_{(k_1, k_2) \in K^2} |o_{k_1} - o_{k_2}| \times y_{k_1, k_2} \quad (\text{P.0.Vehicle})$$

The constraints are similar to the constraints for the order type clustering, except that constraint (P.3.Order) becomes :

$$y_{k_1, k_2} \leq 1 - m_{k_1, k_2} \quad \forall (k_1, k_2) \in K^2 \quad (\text{P.3.Vehicle})$$

In (P.3.Vehicle), we accept to aggregate different vehicle types having similar order types.

### 3.4.1.2 Spatial aggregation

Spatial aggregation involves gathering geographical entities (plant, center, or dealer) into a single entity. We gather the following input data associated with geographical entities : the entity type, the transportation costs and duration, and for centers, only the transit and the inventory costs, and the ability to be a usable center for built-to-stock products. For the sake of the geographical feasibility of  $S_A$ , the maximum level of spatial aggregation respects the following rules. First, we do not aggregate a dealer with a center or a plant, as such an aggregation implies altering the model. More specifically, these facilities are organized differently in the flow graph. Second, if an entity is connected to a second entity and a third entity is not connected to the second entity (in the network graph), then the first and third entities cannot be aggregated. Solutions might otherwise contain arcs that do not exist in the given input network and thus can be unfeasible. With that in mind, only dealers can be aggregated in our case study since no pair of centers respect this second rule.

The dealers' aggregation only impacts the transportation costs and duration. To minimize the impact of the aggregation of dealers on the solutions, we replace the transportation costs and duration related to a group of dealers with the average transportation costs and duration for all the dealers in the considered group. To define the maximum level of spatial aggregation, we observe the impact of the dealer aggregation on the solutions while increasing the aggregation level incrementally.

The following MILP formulation is proposed to cluster dealers.

#### Input data

- $D$  is the set of dealers ;
- $N$  is the set of facilities ;
- $A_R$  is the set of arcs representative of road transport ;
- $A_S$  is the set of arcs representative of sea transport ;
- $A$  is the set of arcs ( $A = A_R \cup A_S$ ) ;
- $K$  is the set of products ;
- $tc_{i,j}$  is the transportation cost per unit from entity  $i$  to  $j$ ,  $\forall(i, j) \in A$  ;
- $o^k$  is the load factor of product  $k$  in an average sized truck,  $\forall k \in K$  ;
- $e_{i_1, i_2}$  is equal to 1 if  $\forall j \in N, ((j, i_1) \in A \wedge (j, i_2) \in A) \vee ((j, i_1) \notin A \wedge (j, i_2) \notin A)$ , 0 otherwise,  $\forall(i_1, i_2) \in D^2$  ;
- $G$  is the set of clusters.

#### Variables

- $x_{i,g}$  is equal to 1 if dealer  $i$  is in cluster  $g$ , 0 otherwise,  $\forall i \in D, \forall g \in G$  ;

- $y_{i_1,i_2}$  is equal to 1 if dealers  $i_1$  and  $i_2$  are in the same cluster, 0 otherwise,  $\forall(i_1, i_2) \in D^2$ .

The objective function for the aggregation of dealers is given in (D.0). Transportation costs are directly impacted by the aggregation and appear in the cost function of the original problem. The objective is hence to minimize the approximation of the transportation costs induced by the clusters of dealers.

$$\text{Minimize} \quad \sum_{(i_1, i_2) \in D^2} \sum_{j \in N | (j, i_1) \in A_R} \frac{\sum_{k \in K} o_k}{|K|} |tc_{j, i_1} - tc_{j, i_2}| \times y_{i_1, i_2} + \\ \sum_{(i_1, i_2) \in D^2} \sum_{j \in N | (j, i_1) \in A_S} |tc_{j, i_1} - tc_{j, i_2}| \times y_{i_1, i_2} \quad (\text{D.0})$$

s.t.

$$\sum_{g \in G} x_{i,g} = 1 \quad \forall i \in D \quad (\text{D.1})$$

$$x_{i_1,g} + x_{i_2,g} - 1 \leq y_{i_1, i_2} \quad \forall (i_1, i_2) \in D^2, \forall g \in G \quad (\text{D.2})$$

$$y_{i_1, i_2} \leq e_{i_1, i_2} \quad \forall (i_1, i_2) \in D^2 \quad (\text{D.3})$$

$$x_{i,g} \in \{0, 1\} \quad \forall i \in D, \forall g \in G \quad (\text{D.4})$$

$$y_{i_1, i_2} \in \{0, 1\} \quad \forall (i_1, i_2) \in D^2 \quad (\text{D.5})$$

Dealers are allocated to one cluster (D.1). The channeling constraint is (D.2). We only aggregate dealers connected to the same facilities (D.3).

### 3.4.1.3 Temporal aggregation

Temporal aggregation involves decreasing the period granularity in the model. These aggregations impact the inventory cost, the transportation duration, the product release date from plants, and the availability of sea transportation.

To reasonably approximate these data, we round the transportation duration and availability dates of sea transportation to the nearest period. We multiply the daily inventory cost by the number of days in an aggregated period. The larger the period is, the higher the impact on temporal aspects of the solutions. The delivery lead time can be strongly impacted. Therefore, compliance with the time horizon cannot be guaranteed beyond a temporal aggregation level. To define the maximum level of temporal aggregation, we observe the impact of decreasing the period granularity incrementally on the solutions (the same way as for spatial aggregations).

### 3.4.2 Solutions disaggregation

As explained before, the solution  $S_A$  needs to be disaggregated to be comparable with the solution  $S$ . We propose two disaggregation methods ( $DM$ ) that maintain the characteristics of  $S_A$ .

In BCNDP, two types of information are relevant :

1. The used routes ;
2. The product quantities planned in the different route sections.

Consequently, we choose two systematic disaggregation methods that preserve these two previous decisions taken in  $S_A$  :

- $DM\_Route$  : select the used routes in  $S_A$  and force the original problem to only use these routes.
- $DM\_Quantity$  : set the flow quantities on the arcs to get a solution as close as possible to  $S_A$ , while giving the optimization more flexibility, slightly releasing the quantity constraints by  $\alpha\%$ . More specifically, we force the product quantity for each arc to be contained within  $\alpha\%$  of the flow value indicated in  $S_A$  or between 0 plus  $\alpha\%$  in case of aggregated arcs in the network of  $S_A$ .

In the next sections, we present in details how these two strategies are used to disaggregate solutions obtained using spatial, product type, and temporal aggregations, respectively.

#### 3.4.2.1 Disaggregating spatial aggregation

Following spatial aggregation, if a section from entity  $i$  to a cluster of dealers is used in  $S_A$ , all the routes from  $i$  to all dealers in the corresponding cluster are usable in  $DM\_Route$ . Take the example in Figure 3.4. On the left, the solution with aggregated input data ( $S_A$ ) has a path from  $U$  to all dealers aggregated in  $d'$  passing through center  $C$ .  $S_A$  tells how many products are transported from  $U$  to the set of dealers in  $d'$ , but does not tell how the flow is partitioned between the dealers  $d_1$  and  $d_2$ . To disaggregate  $S_A$  (and have the product distribution to  $d_1$  and  $d_2$ ), we solve the original problem BCNDP with additional constraints,  $cstr(S_A)$ , given on the right-hand side of Figure 3.4. In the case of  $DM\_Route$ , the additional constraints force only the green arcs to be active in BCNDP.

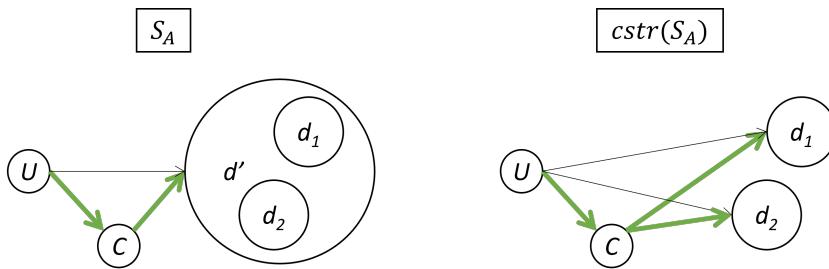


FIGURE 3.4 – Constraint added in the  $BCNDP + cstr(S_A)$  in  $DM\_Route$  after spatial aggregation

If  $DM\_Quantity$  is used to disaggregate, then the value of the flow on the corresponding arcs is added as constraints. It needs to be between 0 and the value in  $S_A$  plus  $\alpha\%$  (see Figure 3.5 with an  $\alpha\%$  of 10%).

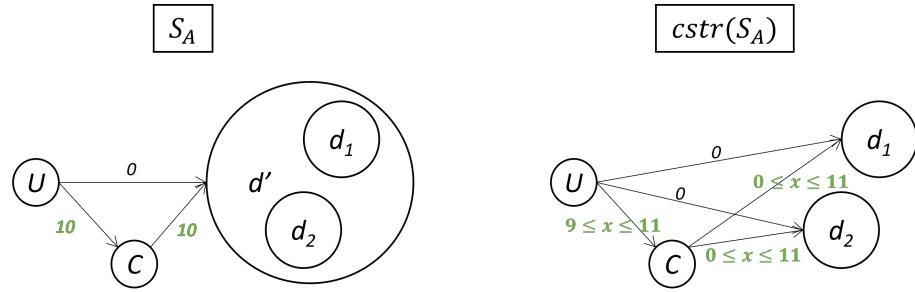


FIGURE 3.5 – Constraint added in the  $BCNDP + cstr(S_A)$  in  $DM\_Quantity$  after spatial aggregation

### 3.4.2.2 Disaggregating product type aggregation

We recall that the product type aggregation has two options : order types aggregation or vehicle type aggregation. The order types aggregation results in additional constraints on the flow. Hence, the solution ( $S_A$ ) obtained with such aggregations is always feasible. Therefore, we do not need to apply any disaggregation methods to these solutions.

Regarding the vehicle type aggregation,  $DM\_Route$  is simple to implement since the aggregation of vehicle types does not impact the geographical aspects of the solution  $S_A$ .

Adjustments are however required in  $DM\_Quantity$ . For example, let us assume that vehicle types *CLIO* and *Megane* are aggregated into  $(CLIO, Megane)$ . One  $(CLIO, Megane)$  uses an arc at a certain period  $t$  in  $S_A$ . Since we do not know if this product is a *CLIO* or a *Megane*, the number of *CLIO* and the number of *Megane* on this arc at period  $t$  should be between 0 and 1. As mentioned before, to give some flexibility to the disaggregation model, we relax these limits by  $\alpha\%$  in  $DM\_Quantity$  (see Figure 3.6 with an  $\alpha\%$  of 10%).

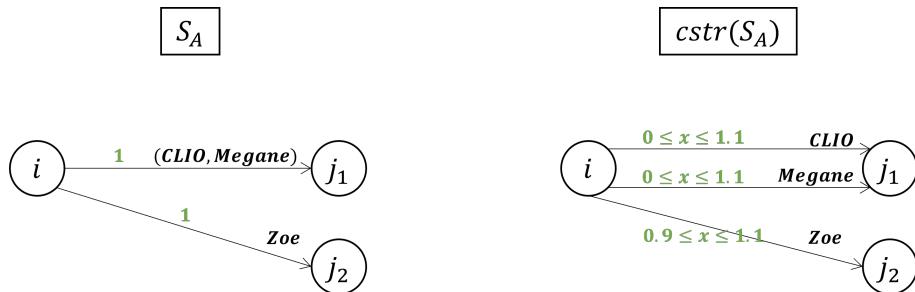


FIGURE 3.6 – Constraint added in the  $BCNDP + cstr(S_A)$  in  $DM\_Quantity$  after vehicle type aggregation

In addition, since product types are injected into the network at specific periods, two aggregated vehicle types may have their plant release date swapped. Figure 3.7 gives such an example leading to an unfeasible solution. The *CLIO* and *Megane* are aggregated. One *CLIO* is produced at period 0 and one *Megane* at period 1. For the

sake of simplicity, all transportation durations are null. With the flow planning of  $S_A$ , dealer  $d_2$  can only receive the aggregated product at period 0, while in  $I$  the *Megane* is supposed to leave the plant at period 1. To avoid this problem in  $DM\_Quantity$ , we temporally relax the constraints concerning the use of  $S_A$  by summing up temporal information. More specifically, if two vehicle types are aggregated, their flow is possible between the earliest release date and the latest delivery date of these product types in  $S_A$ .

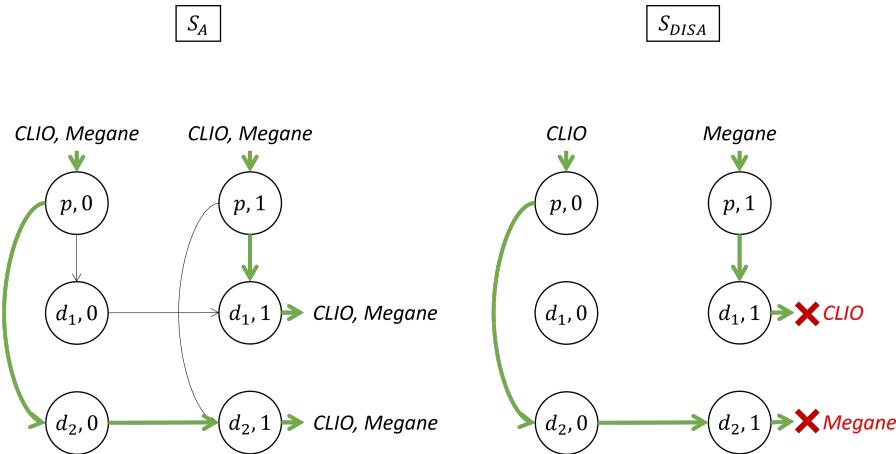


FIGURE 3.7 – Example of a temporally unfeasible disaggregation for  $DM\_Quantity$

### 3.4.2.3 Disaggregating temporal aggregation

$DM\_Route$  is straightforward to implement after temporal aggregations since temporal aggregation does not deteriorate geographical information.

However, temporal adjustments are necessary to apply  $DM\_Quantity$ , since the temporal characteristics of product flows are obviously impacted. Let us assume the case of temporal aggregation of 2 days period given in Figure 3.8. If one *CLIO* leaves the aggregated node  $(i, t'_1)$  to an entity  $j$  in  $S_A$ , deciding that this *CLIO* can leave in  $DM\_Quantity$  at  $t_1$  or  $t_1 + 1$  is not sufficient to ensure a feasible solution  $S_{DISA}$ . In fact, since the transportation time  $\tau'_{i,j}$  is also an approximation, we cannot ensure that the aggregated node  $(j, t'_1 + \tau'_{i,j})$  in  $S_A$  corresponds to the nodes  $(j, t_1 + \tau_{i,j})$  and  $(j, t_1 + 1 + \tau_{i,j})$ . We should therefore take into account this approximation in  $DM\_Quantity$ . Moreover, this approximation applies to every flow in  $S_A$ . Consequently, the approximation propagates and increases with the number of visited centers in a path. All this considered, we choose to let go of all temporal information and only keep spatial and product types information of  $S_A$ . In the case of our example, the sum of *CLIO* for all periods on this arc in  $S_A$  is 1 *CLIO*. Therefore, in  $DM\_Quantity$ , the number of *CLIO* going from  $i$  to  $j$  at all periods is bounded to  $1 \pm \alpha$  (see Figure 3.8 with  $\alpha = 10\%$ ).

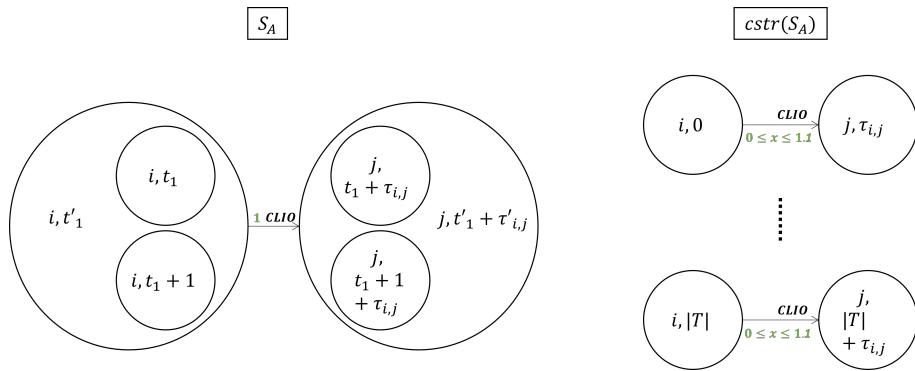


FIGURE 3.8 – Constraint added in the  $BCNDP + cstr(S_A)$  in  $DM\_Quantity$  after temporal aggregation

### 3.4.3 Results evaluation

The impact of the aggregations is measured along three indicators : (1) the solving difficulty, (2) the solution cost, (3) the solution physical characteristics (see Figure 3.9).

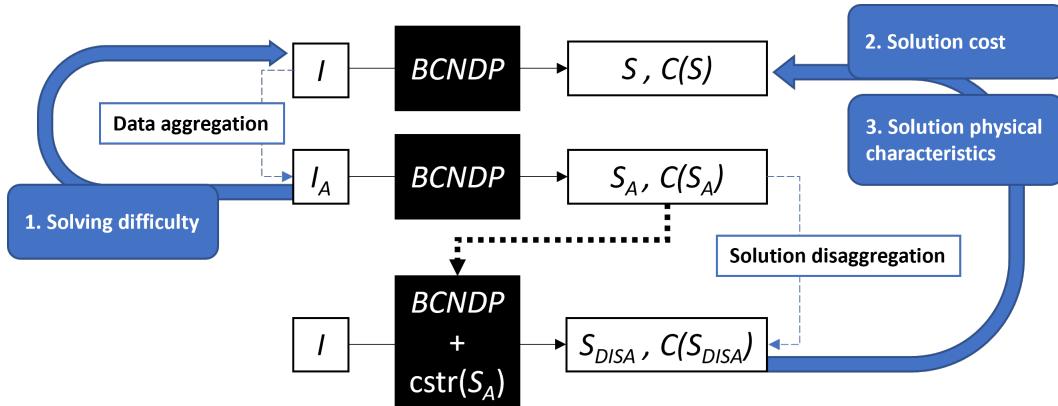


FIGURE 3.9 – Evaluation of the aggregation-disaggregation process

First, we want to quantify how much the model solving is eased by input aggregation. The solving difficulty of the model is measurable with the comparison of the model's size between  $I$  and  $I_A$  and of the tree search performance.

Second, the simplification of the model should not deteriorate the quality of the solutions. Therefore, comparing the solution costs  $C(S)$  and  $C(S_{DISA})$  is interesting.

Lastly, to determine if  $S_{DISA}$  is a good physical representation of  $S$ , we compare flow characteristics between  $S$  and  $S_{DISA}$ .

## 3.5 Numerical experiments

In this section, we apply our methodology to BCNDP and describe the quantitative analysis of the results.

### 3.5.1 Scope description and experimental conditions

The following experiments are computed with CPLEX 12.9 as a MILP solver using its Java API and run on an Intel Core i7-8850H CPU, 2.60GHz, and 64GB of RAM. All the data sets are industrial real-case scenarios from the automotive industry. For all instances  $I$  and  $I_A$ , we run the BCNDP with a time limit ( $TL$ ) of one hour CPU. And we use an  $\alpha\% = 10\%$  in  $DM\_Quantity$ .

All centers in Europe and boarding the Mediterranean sea are candidate centers. The demand data set comes from the demand in Italy from January to March 2019. There are 27 different vehicle types and thus 52 product types (one built-to-order and one built-to-stock order types for 25 vehicle type, and 2 vehicle types are ordered exclusively in built-to-stock). There are 13 plants, 57 centers, and 91 dealers. The lead time can be of approximately 50 to 75 periods. We design 12 instances out of this data set : 9 instances of 10 days of demand and 3 instances of 1 month of demand, respectively called  $TD1$  to  $TD9$  and  $M1$  to  $M3$ .

The aggregation selection strategy consists of the analysis of three factors :

1. the solving difficulty ;
2. the solution cost ;
3. the solution's physical characteristics.

The difficulty of the model resolution is appreciated by the quantity of integer decision variables of the BCNDP. We also examine the gap between the solutions and the corresponding lower bound (denoted  $Opt\_proof\_Gap$ ), more specifically :

- ❖  $\frac{C(S) - LB(S)}{C(S)}$  (in blue in the figures)
- ❖  $\frac{C(S_{DISA}) - LB(S_{DISA})}{C(S_{DISA})}$  (other colors than blue in the figures)

This latter indicator is only widely interpreted since the compared problems are different (because they use different input aggregation dimensions and levels). It is nevertheless interesting to observe the tendency of this gap when the number of decision variables decreases.

The quality of  $S_A$  is determined by comparing the costs  $C(S_{DISA})$  and  $C(S)$ . At the optimum,  $C(S) \leq C(S_{DISA})$  since  $S_{DISA}$  is obtained with the same model as  $S$  but with additional constraints. Yet, because solving the model to optimum is too long, we set a computation time limit,  $TL$ , to solve the problem, and consequently,  $C(S)$  and  $C(S_{DISA})$  are not the optimal costs. More specifically, we look at the following rates (denoted  $Cost\_quality\_Gap$ ) :

- ❖  $\frac{C(S) - LB(S)}{C(S)}$  (in blue in the figures)
- ❖  $\frac{C(S_{DISA}) - LB(S)}{C(S_{DISA})}$  (other colors than blue in the figures)

As for the representative nature of the solutions, we compare the characteristics of  $S_{DISA}$  with the characteristics of  $S$ . We focus on the following characteristics :

- The average truck fill rate ;
- The rate of direct flows ;
- The overall lead time ;
- The rate of used centers ;
- The rate of used routes.

Since we cannot tell which exact vehicle leaves or arrives at which period in a solution, we cannot calculate the average lead time for all vehicles. The overall lead time is defined as the duration between the earliest release date from a plant and the latest arrival date at a dealer.

We present our results in box-and-whisker plots like in the example Figure 3.10.

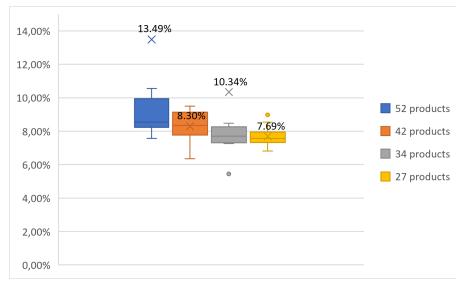


FIGURE 3.10 – Example for a box-and-whisker plot

These plots contain one indicator (on the vertical axis) and consider a single aggregation dimension. For example, Figure 3.10 presents the *Cost\_Quality\_Gap* obtained with the order type dimension. The level of aggregation goes increasingly from left to right (on the horizontal axis). On the very left (in blue), the values represent the solutions  $S$ . On the right, the values represent the solutions  $S_{DISA}$ . On the very right, we see the values of the solutions  $S_{DISA}$  obtained with the maximum aggregation level.

The x represents the mean of the values, and we added the mean value above its corresponding x. The top of the box represents the third quartile, the bottom of the box the first quartile, and the line within the box is the median. The whiskers represent the minimum and maximum values. Some exceptional values can be outside the whiskers and therefore are illustrated by small dots. The mean always includes all the values (extreme values included), which can sometimes lead to mean values outside of the whiskers (as for the aggregation levels of 52 and 34 products in Figure 3.10). For better visualization, we reduce the vertical axis of the figures to the whiskers (or mean if outside the whiskers). As a result, extreme values may not appear.

### 3.5.2 Product type aggregation

#### 3.5.2.1 Order type aggregation

There are 52 product types (vehicle and order types considered). If all built-to-order products are aggregated with their equivalent vehicle type into built-to-stock products, there are 27 products (one for each vehicle type). One can refer to Section 3.4.1.1 for a better understanding. Since there are only 2 order types, using the order type to quantify the aggregation levels only works in the case of a complete aggregation (all products are built-to-stock). To propose intermediate aggregation levels, we aggregate built-to-order products with built-to-stock products vehicle type per vehicle type, which is why the aggregation level is quantified per product type and not order type in this section. We consider three aggregation levels : the 52 product types aggregation into 42, 34, and 27 product types.

Figure 3.11 shows the number of integer variables over all instances according to the aggregation levels. Figure 3.12 shows the *Opt\_proof\_Gap* according to the aggregation level.

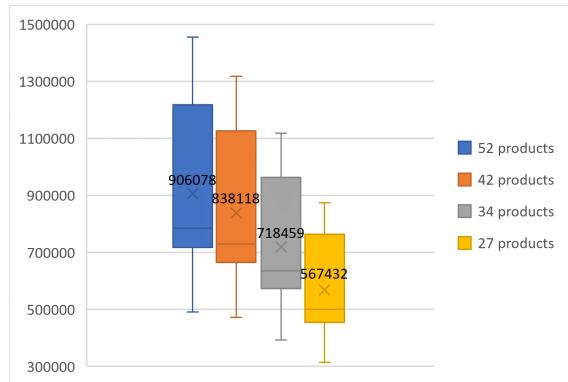


FIGURE 3.11 – Integer variables

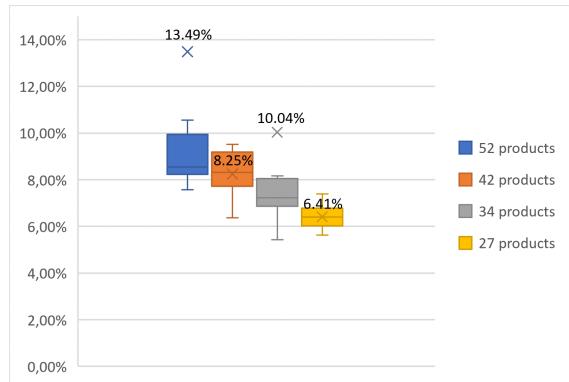


FIGURE 3.12 – *Opt\_proof\_Gap*

In Figure 3.11, the number of variables diminishes with each aggregation level. The mean value decreases by 37% between the baseline input  $I$  and the input  $I_A$  of the maximum level of aggregation. Figure 3.12 shows that the *Opt\_proof\_Gap* tends to decrease with the number of integer variables reduction.

The *Cost\_quality\_Gap* for each aggregation level is given in Figure 3.13.

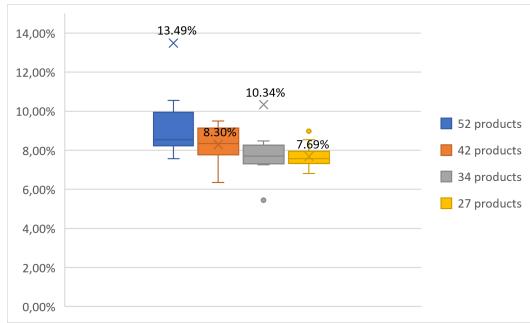


FIGURE 3.13 – Cost\_quality\_Gap

In Figure 3.13,  $C(S_A)$  is on average better than  $C(S)$ . For example, the average cost improves by 5.19% between  $C(S)$  and the first aggregation level (two thirds of the solutions are improved). It is however difficult to determine a correlation between  $C(S_{DISA})$  and the aggregation level because the cost improvement is not monotonic, and the stability of  $C(S_{DISA})$  varies with the aggregation level. Nevertheless, we observe that the maximum level of aggregation yields the best results with an average cost of 7.69% (11 of the 12 instances are improved). The complexity reduction induced by input aggregation presumably allows the BCNDP to reach better solutions within the computation time.

The following figures gather the physical characteristics of the solutions according to the aggregation level.

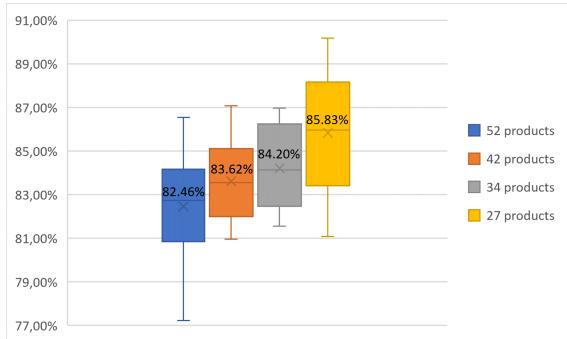


FIGURE 3.14 – Truck fill rate

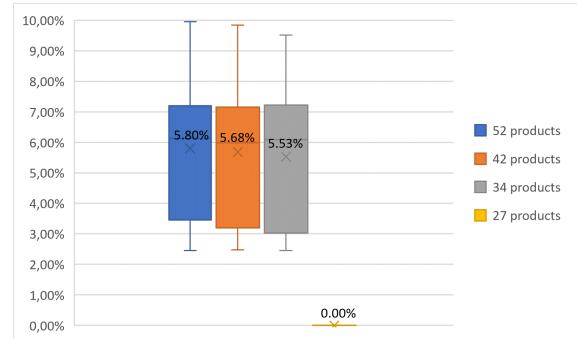


FIGURE 3.15 – Direct flow rate

In Figure 3.14, the truck fill rate increases at each increase in the aggregation level. Indeed, since fewer direct flows are possible when higher levels of aggregation are applied, the flow density is increased, and so is the truck fill rate. The variation of the truck fill rate suddenly increases with the maximum level of aggregation. The brutal impossibility for direct flows might yield better densifications in trucks in some cases and create low-quantity indirect flows in other cases.

Figure 3.15 shows that the direct flow rate remains stable for intermediary aggregation levels. The maximum level of aggregation, however, induces a drop to 0% of the direct flow rate. Indeed, this level of aggregation implies considering all originally built-to-order products as built-to-stock products, which means that no direct flow is possible.

### 3.5.2.2 Vehicle type aggregation

We identify 27 vehicle types and 14 origins (plants) in the demand data. The maximum level of aggregation for vehicle types contains hence 14 vehicle types. We propose two intermediate levels between 27 and 14 types, namely 19 and 23 vehicle types.

Let us look at the influence of this aggregation dimension on the BCNDP difficulty.

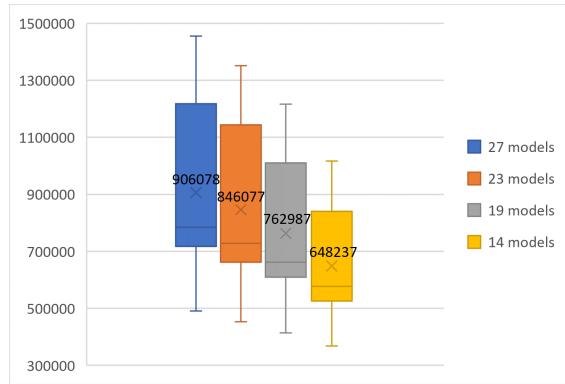


FIGURE 3.16 – Integer variables

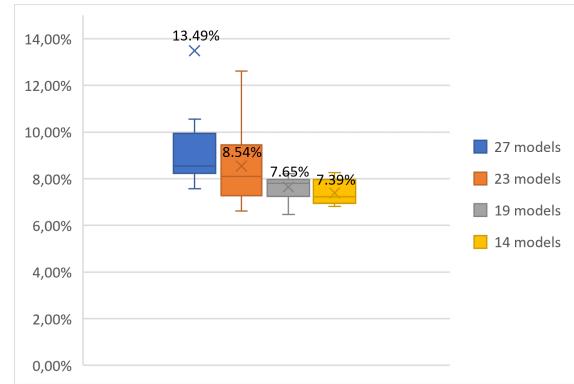


FIGURE 3.17 – *Opt\_proof\_Gap*

Figure 3.16 shows that increasing the aggregation level reduces the number of integer variables of the BCNDP for each aggregation level (28% on average for the maximum level of aggregation compared to the baseline input  $I$ ). Besides, the model size becomes more stable when the aggregation level increases. Moreover, the *Opt\_proof\_Gap* reduces with the aggregation level (see Figure 3.17) to reach an average gap of 7.39% with the maximum aggregation level. In addition, this gap stabilizes when the level of aggregation increases.

The *Cost\_quality\_Gap* at each aggregation level is given in Figures 3.18 and 3.19.

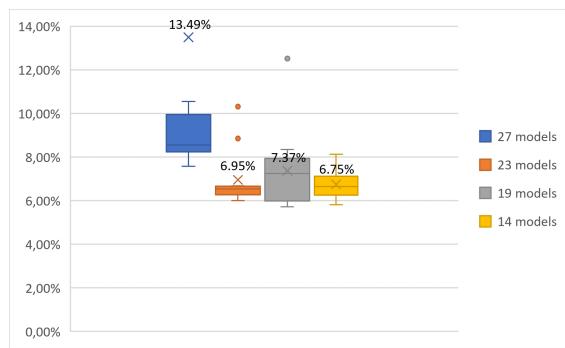


FIGURE 3.18 – *Cost\_quality\_Gap* obtained with *DM\_Route*

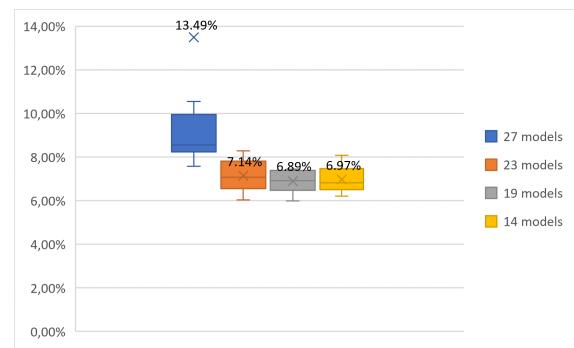


FIGURE 3.19 – *Cost\_quality\_Gap* obtained with *DM\_Quantity*

In Figures 3.18 and 3.19, the cost ceases to decrease and stabilizes after the first level of aggregation. This first level of aggregation reduces the cost of the solutions on average by 6.54% with *DM\_Route* and by 6.35% with *DM\_Quantity*. 11 of the 12

solutions are improved with both disaggregation methods.

The following figures gather the solutions' physical characteristics according to the aggregation level.

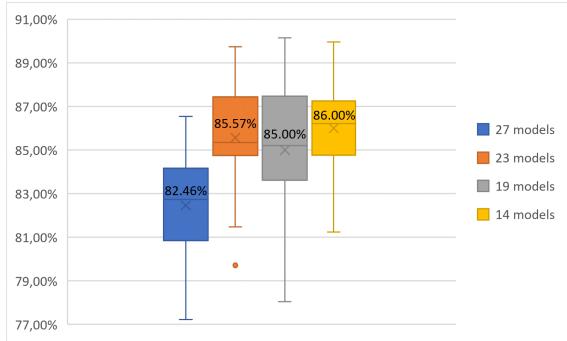


FIGURE 3.20 – Truck fill rate obtained with *DM\_Route*

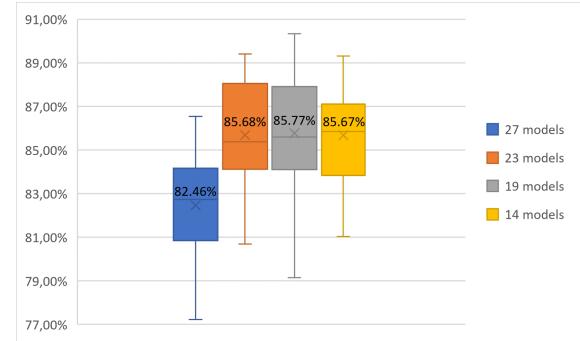


FIGURE 3.21 – Truck fill rate obtained with *DM\_Quantity*

In Figures 3.20 and 3.21, the truck fill rate increases with the aggregation of vehicle types, and it remains relatively stable after the first aggregation level.

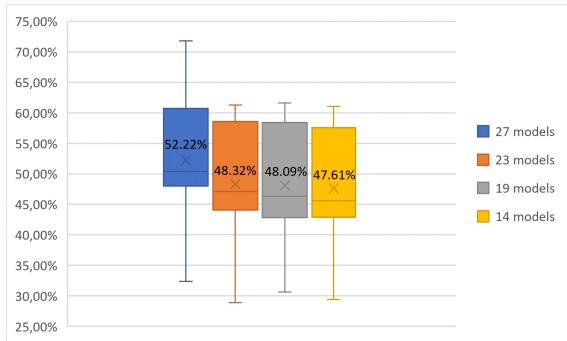


FIGURE 3.22 – Used routes rate obtained with *DM\_Route*

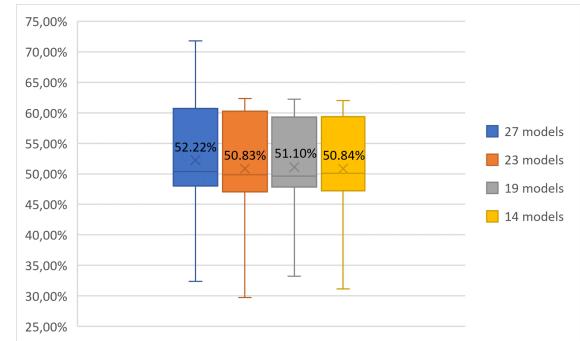


FIGURE 3.23 – Used routes rate obtained with *DM\_Quantity*

Figures 3.22 and 3.23 show that the rate of used routes diminishes slightly with the first level of aggregation and remains stable with the following aggregation levels. Accordingly, better solutions may contain fewer used routes. This may also be the consequence of the disaggregation methods design since they both overconstrain the use of the routes in the BCNDP. The used routes rate decreasing trend is consistent with the truck fill rate improvement. Indeed, the fewer centers we use, the denser the network and the more opportunities to fill trucks and vice versa.

### 3.5.3 Spatial aggregation

We have 91 dealers in the data set. We decide to aggregate incrementally 10%, 20%, and 30% of the dealers. Higher aggregation level attempts yield low-quality solutions. In addition, aggregating 30% of the dealers already induces a significant reduction of the number of decision variables. In brief,  $I$  contains 91 dealers, and the

aggregated instances  $I_A$  contain 81, 72, and 63 dealers.

Let us look at the impact on the resolution difficulty of the BCNDP induced by spatial aggregation.

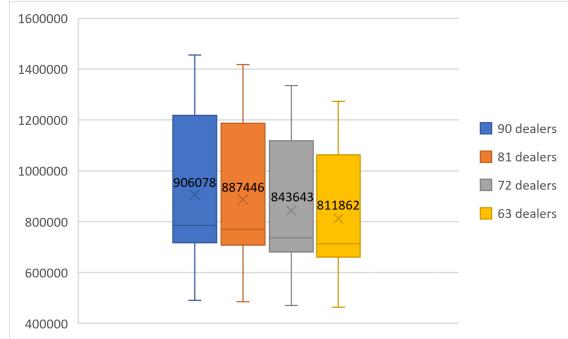


FIGURE 3.24 – Integer variables

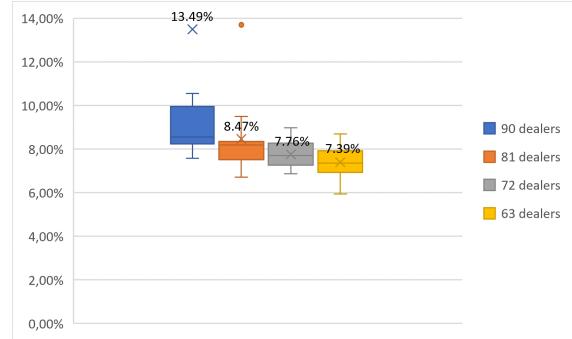


FIGURE 3.25 – *Opt\_proof\_Gap*

Figure 3.24 shows that dealers' aggregation reduces the number of integer variables of the BCNDP (9.71% on average for the maximum aggregation level). Spatial aggregation is however the aggregation dimension that reduces the least the number of integer variables. Moreover, the *Opt\_proof\_Gap* reduces with the aggregation level (see Figure 3.25) to reach an average gap of 7.39% with the maximum aggregation level. This gap stabilizes with the first aggregation levels.

The *Cost\_quality\_Gap* with both disaggregation methods and for each aggregation level is given in Figures 3.26 and 3.27.

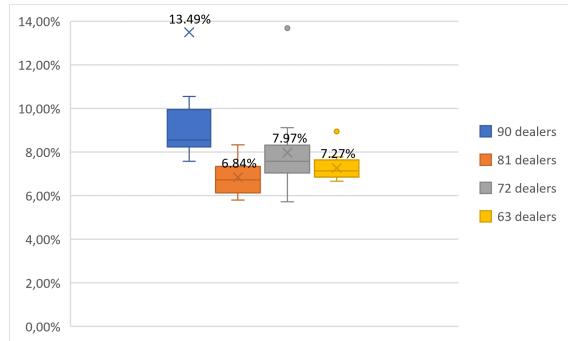


FIGURE 3.26 – *Cost\_quality\_Gap* obtained with *DM\_Route*

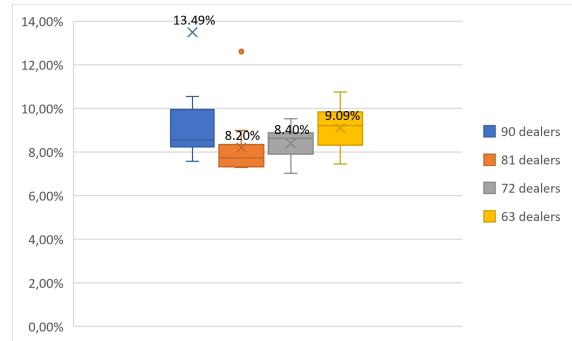


FIGURE 3.27 – *Cost\_quality\_Gap* obtained with *DM\_Quantity*

Generally, the costs of the solutions obtained with *DM\_Route* are better than the ones obtained with *DM\_Quantity*. Thus, spatial aggregation is more profitable if the problem is tactical (find the routes to use). With both disaggregation methods, the first level of aggregation gives the best solutions.  $C(S_{DISA})$  are on average 7.12% better than  $C(S)$  with *DM\_Route* (all 12 solutions improved) and 5.68% with *DM\_Quantity* (11 of the 12 solutions improved). Moreover, the cost variability differs with the aggregation level and the disaggregation method. One reason for the choice of the maximum aggregation level is that it already reduces the cost quality of 7 of

the 12 solutions.

The following figures gather the physical characteristics of the solutions according to the aggregation level.

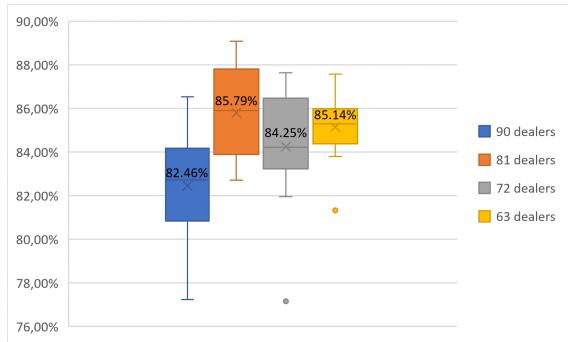


FIGURE 3.28 – Truck fill rate obtained with *DM\_Route*

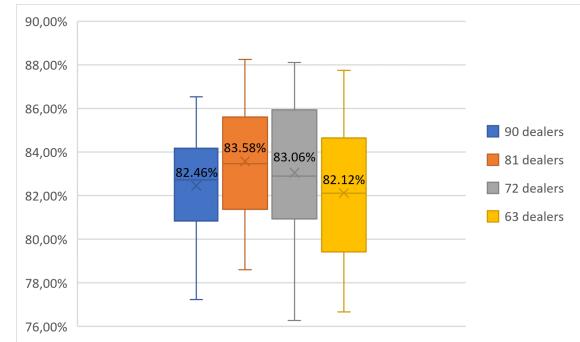


FIGURE 3.29 – Truck fill rate obtained with *DM\_Quantity*

In Figures 3.28 and 3.29, the truck fill rate increases with the first level of aggregation and then fluctuates when the aggregation level increases, and this for both disaggregation methods. As for the cost, the truck fill rate variability differs with the aggregation level and the disaggregation method. Let us note that the truck fill rate is higher with *DM\_Route* (method showing the best cost results).

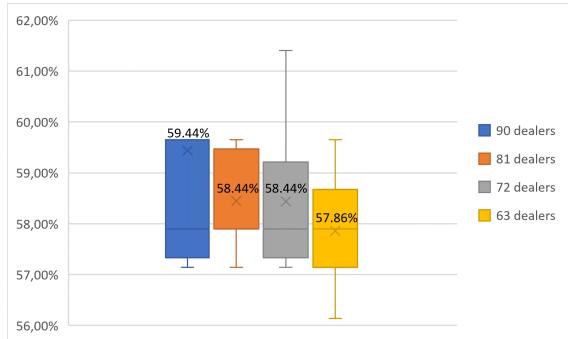


FIGURE 3.30 – Used centers rate obtained with *DM\_Route*

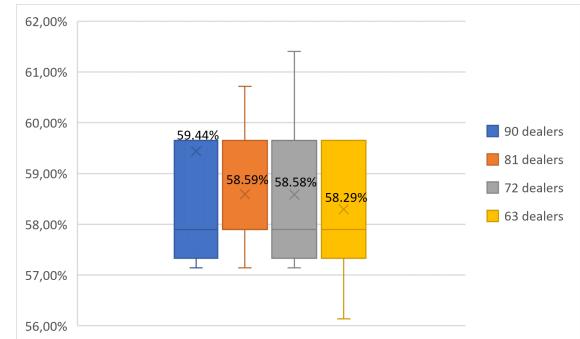


FIGURE 3.31 – Used centers rate obtained with *DM\_Quantity*

According to Figures 3.30 and 3.31, the used centers rate reduces on average by 0.58 center with *DM\_Route* and by 0.52 center with *DM\_Quantity* with the two first spatial aggregation levels (81 and 72 dealers) and by 0.92 center with *DM\_Route* and by 0.67 center with *DM\_Quantity* with the maximum spatial aggregation level (63 dealers). Thus, spatial aggregation slightly reduces the number of used centers, although this impact is almost negligible.

### 3.5.4 Temporal aggregation

We increase the period day by day from 2 days periods up to 7 days periods.

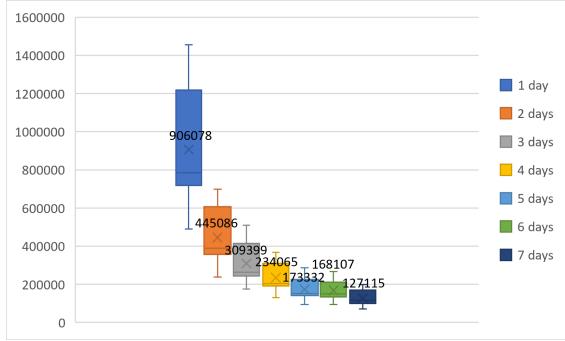


FIGURE 3.32 – Integer variables

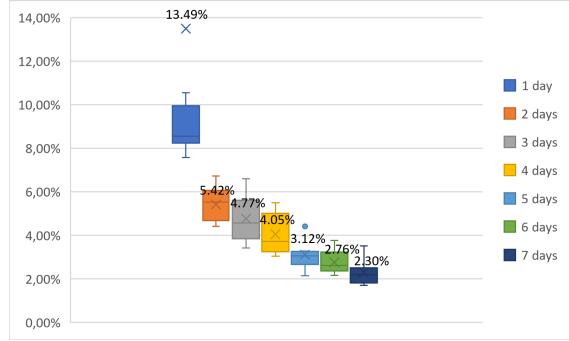
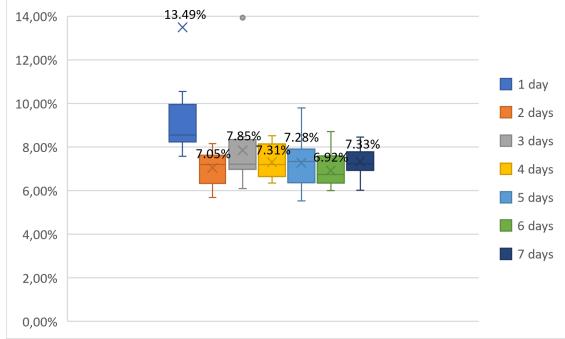
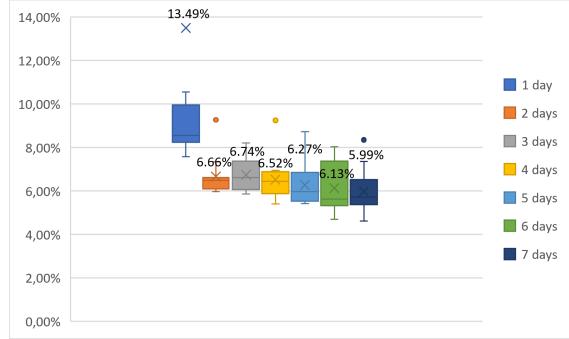

 FIGURE 3.33 – *Opt\_proof\_Gap*

Figure 3.32 shows that increasing the aggregation level yields a reduction of the number of integer variables of the BCNDP logarithmically (85.85% on average for the maximum level of aggregation). The temporal aggregation dimension induces the most significant reduction in integer variables. The number of integer variables stabilizes with the increase in aggregation level. Moreover, the *Opt\_proof\_Gap* reduces almost linearly with the aggregation level (see Figure 3.33) to reach an average gap of 2.30% with the maximum level of aggregation. The temporal aggregation dimension leads to the sharpest gap reduction.

The *Cost\_Quality\_Gap* obtained with both disaggregation methods and for each aggregation level is represented in Figures 3.34 and 3.35.


 FIGURE 3.34 – *Cost\_quality\_Gap* obtained with *DM\_Route*

 FIGURE 3.35 – *Cost\_quality\_Gap* obtained with *DM\_Quantity*

All solutions are improved regardless of the aggregation level, except for instance *TD7* with an aggregation of 3 days. Generally,  $C(S_{DISA})$  obtained with *DM\_Quantity* are better than the ones obtained with *DM\_Route*. Thus, temporal aggregation leads to quality solutions even when additional constraints are added in  $cstr(S_A)$ . With *DM\_Quantity*, the best  $C(S_{DISA})$  are, on average, 7.98% better than  $C(S)$ . These solutions are obtained with the maximum aggregation level (7 days). We justify the maximum level of aggregation of 7 days period by the stagnation of the improvement of  $C(S_{DISA})$  after the first aggregation level.

The following figures gather the solutions' physical characteristics according to the aggregation level.

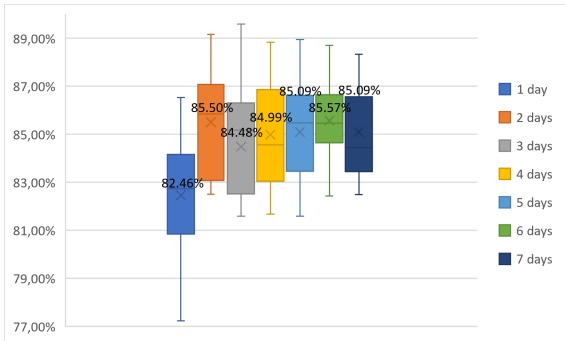


FIGURE 3.36 – Truck fill rate obtained with *DM\_Route*

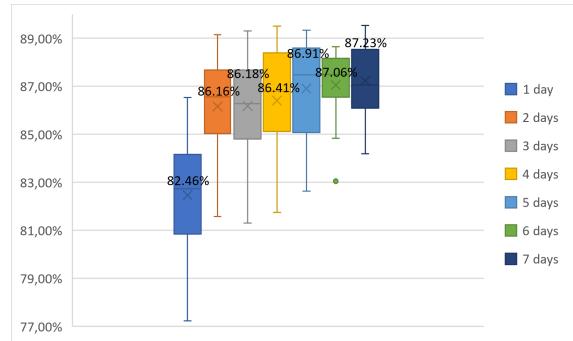


FIGURE 3.37 – Truck fill rate obtained with *DM\_Quantity*

In Figures 3.36 and 3.37, the truck fill rate increases with the first level of aggregation and then fluctuates when the aggregation level increases, and this with both disaggregation methods. It seems nevertheless to keep increasing slightly with *DM\_Quantity* (the method with the best cost-wise results) when the level of aggregation increases. The variability of the truck fill rate is slightly lower with *DM\_Quantity*. As a result, it appears that quality solutions are obtained by optimizing the truck fill rate and reducing road transportation costs. Let us note that temporal aggregation does not limit economies of density within trucks. Economies of density occur when the product density in geographical areas of a network allows for better use of resources and thus cost reduction (Shashin, 2008). Temporal aggregation does not hinder the economies of density since it does not deteriorate the geographical information of the network. On the contrary, by inducing accumulations of products into trucks within the same aggregated periods, temporal aggregation induces economies of density. Besides, temporally aggregated trucks remain after disaggregation since the BCNDP does not contain constraints on the delivery lead time.

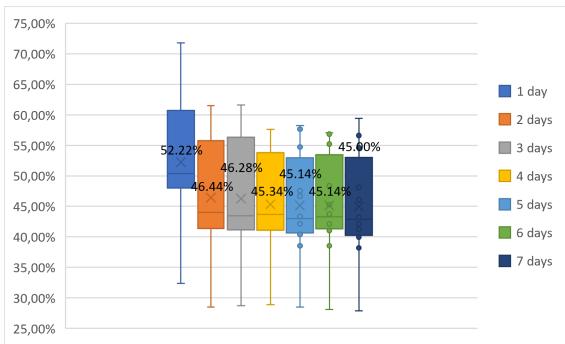


FIGURE 3.38 – Used routes rate obtained with *DM\_Route*

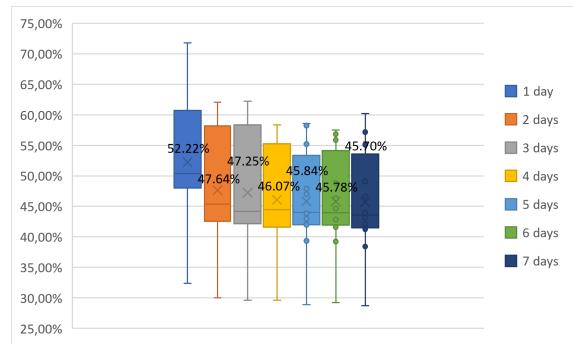


FIGURE 3.39 – Used routes rate obtained with *DM\_Quantity*

According to Figures 3.38 and 3.39, the used routes rate diminishes on average by 5.18% of routes with the first aggregation levels (2 days) and by 6.18% of routes with the maximum level of aggregation (7 days). A possible explanation is that temporal aggregation induces more flow densification. This effect agrees with the truck fill rate improvement as in the case of vehicle type aggregation.

### 3.5.5 Synthesis and managerial perspectives

We synthesize the influence of input aggregations on the behavior of the model. Table 3.7 gathers the evolution of our indicators when the aggregation level increases for each aggregation dimension. The indicators requiring a disaggregation phase are obtained with the method *DM\_Quantity*. Similar evolutions are observed with the use of *DM\_Route*.

- Almost equal symbols ( $\approx$ ) mean that the indicator remains stable when the aggregation level increases.
- Bold arrows represent a monotonous increase ( $\nearrow$ ) or decrease ( $\searrow$ ) in the indicator when the aggregation level increases.
- Thin arrows represent a tendency to increase ( $\nearrow$ ) or decrease ( $\searrow$ ) (not monotonous) for the indicator when the aggregation increases.

Aggregation dimension	Integer variables	Cost	Truck fill rate	Direct flow rate	Overall lead time	Center use	Route use
Order type	$\searrow$	$\searrow$	$\nearrow$	$\searrow$	$\approx$	$\approx$	$\approx$
Vehicle type	$\searrow$	$\searrow$	$\nearrow$	$\approx$	$\approx$	$\approx$	$\searrow$
Spatial	$\searrow$	$\searrow$	$\nearrow$	$\approx$	$\approx$	$\searrow$	$\approx$
Temporal	$\searrow$	$\searrow$	$\nearrow$	$\approx$	$\approx$	$\approx$	$\searrow$

TABLE 3.7 – Synthesis of the impact of aggregation on the behavior of the model

Table 3.7 shows that the problem's resolution difficulty decreases with the aggregation level regardless of the aggregation dimension. Indeed, the number of integer variables diminishes with the aggregation level. This decline is not surprising, as the aggregation levels are designed to reduce the number of decision variables of the model.

The costs of the solutions obtained under a limited computation time tend to reduce when input aggregation is applied. The simplification of the model allows for reaching better solutions. This global solution improvement shows the advantage of considering input aggregation for a SCND problem. Yet,  $C(S_{DISA})$  does not decrease monotonously when the aggregation level increases. Determining the aggregation level that most benefits the problem resolution is therefore essential.

Let us look at the physical characteristics of the solutions. All  $S_{DISA}$  possess a higher truck fill rate than  $S$ , regardless of the aggregation dimension or level. Knowing that the road transportation cost is incurred per trucks, the improvement of the truck fill rate in  $S_{DISA}$  leads naturally to better  $C(S_{DISA})$ . The direct flow rate remains stable, except for the product order type aggregation (see Section 3.5.2.1 for more details). The used centers rate also remains stable. We only observe a slight reduction tendency in the case of spatial aggregation, although we show that this reduction is negligible. The used routes rate is also stable. Results show a slight decrease in

the case of vehicle type and temporal aggregation dimensions. These previous results suggest that economies of density can be achieved without increasing the flow density through centers but simply by improving the truck fill rate. Lastly, we do not observe a dramatic impact of aggregation on the overall lead time. The truck fill rate improvement does not imply additional waiting time for trucks to fill up.

Regarding the case study, we recommend the following practices for input aggregation (in the following preferred order of application) :

1. Use a temporal granularity of two days periods.
2. Use a vehicle type aggregation of one-third of the vehicle types.
3. Use a spatial aggregation of no more than 10% of the car dealerships.
4. Use an order type aggregation of one-third of the vehicle types.

**1. Temporal granularity** Aggregating input on two days duration period allows for significant improvement of  $C(S_{DISA})$  (7.26% on average with all solutions improved) compared to  $C(S)$ . Besides, it does not impact the network structure of the solutions. Further aggregation levels are possible since they seem to maintain the physical characteristics of the solutions. However, they do not necessarily improve the cost of the solutions.

**2. Vehicle type aggregation** One can apply a vehicle type aggregation of one-third of the vehicle types (cost improvement of 6.86% with 11 of the 12 solutions improved).

**3. Spatial aggregation** It is possible to apply a spatial aggregation of 10% of the car dealerships (cost improvement of 5.68% with all solutions improved using *DM\_Route* and 10 of the 12 solutions improved with *DM\_Quantity*). However, spatial aggregation should absolutely not exceed an aggregation level of 10% of the car dealerships. Higher aggregation levels degrade the cost of the solutions. In addition, they reduce the used centers' rate compared to  $S$ . In fact, car dealerships are already aggregated into dealer zones in the input baseline  $I$ , which makes further spatial aggregation redundant.

**4. Order type aggregation** An order type aggregation of one-third of the product types allows a reduction of  $C(S_{DISA})$  of 5.63% (with two thirds of the solutions improved). However, the impacts of higher aggregation levels are relatively unpredictable. An aggregation of two thirds of the product types generates solutions with variable quality, and notably one exceptionally costly solution with the instance *M1*. Applying the maximum level of aggregation makes the direct flow rate fall to zero. Considering the volatility of the results, we do not strongly advise applying any level of order types aggregation.

## 3.6 Conclusion

This paper proposes a systematic methodology to address the issue of input data aggregation. Even if the application of input aggregation is only proposed for a specific

industrial problem, the genericness of the methodology should allow applying it to many problems involving data on products, space, and time.

For our case study, the aggregation-disaggregation methodology allows providing solutions to the BCNDP within a controlled computation time. We systematically analyze the three dimensions of aggregation (product type, spatial, and temporal) and their different levels. The solutions obtained with input aggregation are often of better quality than those obtained with the original input in the same computing time. Moreover, the characteristics of these solutions (used routes and centers) remain stable, *i.e.* the aggregation-disaggregation method leads to relatively similar solutions to the original model.

Even if the results obtained are interesting from an industrial point of view, some limitations emerge. First, the numerical study focuses on a specific country at a given time. It would be interesting to do the same study on a different geographical area and/or at a different time. However, the complexity of collecting data and setting up the instances prevented this from being done. Furthermore, we chose to disaggregate the solutions obtained after the aggregation using the initial mathematical model with added constraints. Other reconstruction techniques should be studied. Finally, the aggregation dimensions are applied separately. Aggregating two or all three dimensions simultaneously might yield even better results.

Since the industrial problem is too difficult to solve, obtaining an optimal solution in a reasonable time is not possible. From a theoretical point of view, it would be interesting to consider a simpler problem, allowing us to obtain an optimal solution and propose a systematic analysis of aggregations for this problem. Thus, the optimal solutions from the aggregation-disaggregation methodology could be compared with the original model's optimal solutions and not the best solution obtained after a limited computation time.

In the proposed methodology, the disaggregation phase reconstructs feasible solutions to the initial problem and thus allows comparing their cost values and characteristics to the original solutions. This phase is not necessarily relevant from an industrial point of view because the solution obtained after aggregation should be sufficient to make the desired managerial decisions. Thanks to the design of the disaggregation methods, the centers that will be used and the routes on which to negotiate transportation with Third Party Logistics (3PL) are maintained from the aggregated solutions. However, there might be a difference between the cost of the solution with the aggregated input and the cost of its disaggregated counterpart. In fact, the input aggregation phase introduces data approximations that can influence the cost estimation of the solutions. This bias induced by data approximation on the overall cost of the solutions offers an angle for further research to guarantee that the cost of the solution after aggregation is in line with the actual cost after disaggregation.



# Chapitre 4

## Cost adjustment in a supply chain decision support system using aggregated input

### Abstract

Supply chain network design problems are known to be difficult problems to solve, especially when industrial-sized instances are involved. Input aggregation is a common practice to reduce the size of such models and ease their resolution. However, input aggregation can induce data alterations and consequently induce a bias on the solution's cost, which can affect the acceptance of the model by decision-makers.

We realize a quantitative study of a vehicle distribution problem in the automotive industry, to which are applied different input aggregation dimensions (product type, spatial, and temporal) and levels (input data granularity). The bias induced by input aggregation on the solution's cost is analyzed, and we propose a cost adjustment method to reduce it. Cost adjustment values are trained with a multi-scenario linear programming model and then systematically applied to the cost of the solution. Analyses show the performance of this cost adjustment method in reducing bias.

### Keywords

Supply Chain Network Design, Decision Support System, Input aggregation, Cost adjustment, Multi-scenario linear programming

## 4.1 Introduction

Model-driven Decision Support System (DSS) are powerful tools for large companies to conceive supply chain networks. A classical model for a supply chain design at a strategic and tactical decision level is the Supply Chain Network Design (SCND) problem. SCND models are difficult to solve since they involve complex constraints and large-sized scopes. Simplifying a model is a common strategy to ensure its solvability (Reich et al., 2019). To reduce the size of a SCND problem, one can apply different aggregations on the model's input. For instance, the daily product flow between a supplier and a manufacturer can be aggregated into a monthly flow to decide the size of the transportation fleet.

The disadvantage of data aggregation is that it can alter the model's precision and induce a bias in the solutions and their cost. For instance, the aggregations mentioned above may lead to a loss of information about the daily flow variations, leading to over or underestimation of the fleet size. A solution to overcome such bias is to disaggregate the solutions obtained with aggregated inputs and thus obtain a more realistic cost estimation of the proposed solutions. Unfortunately, disaggregation methods can be difficult to solve and, in an industrial context, too time-consuming. Nevertheless, if the costs of the solutions obtained with aggregated input are far from their disaggregated cost, the probability that decision-makers will refuse the model is greater. The non-acceptance of a model can cause the failure of the DSS industrialization. Therefore, we need to give the decision-makers a relevant estimation of the cost of the proposed aggregated solutions by determining the bias on the cost and proposing a fast method to reduce it.

Such DSS based on mathematical programming are complex to design since the DSS developers, with specific domain knowledge in development and mathematical formulation, have a different understanding of the problem than the decision-makers using the DSS, the latter having field application knowledge (Power & Sharda, 2007). However, the quality of the design of a model determines its acceptance by decision-makers. More specifically, the comprehension and confidence in the advised decisions (Power & Sharda, 2007) and the expected performance of the technology (Davis, 1989) play a crucial role in DSS acceptance. Acceptance is essential to make the development of this model worthwhile. Unfortunately, non-acceptance cases of mathematical programming-based DSS seem to be frequent (Reich et al., 2019). In the literature, contributions dealing with the use and acceptance of model-driven DSS are rare (Power & Sharda, 2007; Aloysius et al., 2006). Regarding DSS to solve SCND problems, one can refer to the application given by Reich et al. (2019). They also argue that uncertainty and volatility can lead to the belief that a DSS is incorrect. Since input aggregation adds uncertainty in the cost estimation of the solutions, a bias analysis followed by the cost adjustment methodology can reassure decision-makers and improve the chance of the model's acceptance.

In this article, we realize a quantitative study of the impact of input data aggregation on a SCND model for the vehicle distribution of an automotive constructor with batch transportation cost formulation. Input aggregations are applied due to the

considerable computation time involved in solving the problem. Three aggregation dimensions are considered : product type (vehicle differentiation), spatial (geographical locations), and temporal (planning periods). Moreover, several aggregation levels are applied for each of these aggregation dimensions. For example, periods originally of one-day duration are aggregated incrementally to one-week periods.

First, we quantify the bias induced by input aggregation on the cost of the solutions. The impact of input aggregation on the cost estimation of a model is a well-known problem in the literature. Geoffrion (1977) focuses on product aggregation for logistics planning models and proposes guidelines for product aggregation to apply to this model thanks to a method to predetermine the error caused by aggregation. Francis et al. (2009) give a review on the impact of geographical aggregations on location models. They conclude that despite the known advantage of choosing the right aggregation level, no study addresses this problem analytically. Besides, few studies analyze the aggregation error, and even fewer use real data.

Second, since large companies' supply chain network involves high cost, it is fundamental to estimate the cost of the designed solutions as precisely as possible. For our case study, the attempted disaggregation method is too long to compute. The decision-maker wishes to exploit aggregated solutions without applying a time-costly disaggregation phase. We hence propose a faster methodology to mitigate the bias in cost estimation. To this end, we aim to quantify the bias and incorporate adjustment values into the cost calculation to counter the effect of the bias on the cost. We propose a multi-scenario Linear Programming (LP) model to calculate the adjustment values and a strategy to validate them. To the best of our knowledge, no prior work studies the bias induced by input aggregation on the cost of solutions whose objective is to correct this bias a posteriori.

This article is organized as follows. Section 4.2 describes the vehicle distribution problem, the Mixed-Integer Linear Programming (MILP) formulation, and the strategy to obtain aggregated solutions and their disaggregated costs. Then, we depict the proposed LP model to adjust the cost of the solutions in Section 4.3. Section 4.4 gives the evaluation protocol of the adjustment method. Finally, Section 4.5 contains an analysis of the bias induced by input aggregation on the cost estimation of the solutions and the performance of the proposed cost adjustment method.

## 4.2 Description of the network design problem

We consider a tactical SCND problem for the vehicle distribution of an automotive constructor : the Batch Cost Network Design Problem (BCNDP) (see **Chapter 2**). The objective of the BCNDP is to find routes to use and vehicle flows to satisfy the demands of car dealerships (denoted dealers), minimizing transportation, handling, and storage costs.

First, we describe the BCNDP model and highlight the original inputs ( $I$ ) and outputs (see Figure 4.1). Since the BCNDP model is too difficult to solve with

industrial-sized instances, the automotive constructor applies input aggregations. Second, we aggregate the input  $I$  into aggregated input ( $I_A$ ). The output of the model with aggregated input  $I_A$  is the solution  $S_A$  with a cost  $C(S_A)$ . Third, we use a new model ( $BCNDP + cstr(S_A)$ ) to calculate the disaggregated cost  $C(S_{DISA})$  of the solutions obtained after input aggregation ( $S_A$ ). This model uses the original input  $I$  and constrains the BCNDP model to keep the characteristics of the solution  $S_A$ . A feasible solution to the original problem with an accurate cost is thus obtained.

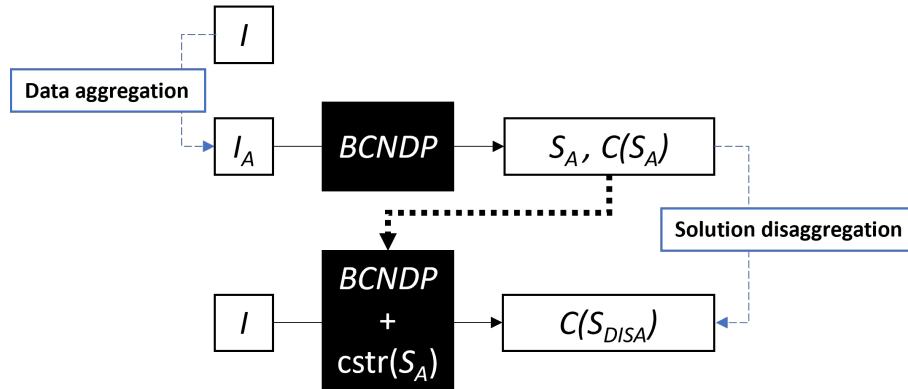


FIGURE 4.1 – Obtaining  $S_A$  and  $C(S_{DISA})$

#### 4.2.1 The batch cost network design problem

Figure 4.2 illustrates a simplified representation of the studied distribution network. The network is composed of 13 plants, about 60 centers, and about 90 dealers. They are connected by route sections that represent road transportation or sea transportation. The products to transport from plants to dealers are vehicles. Products possess a vehicle type (CLIO, Megane...) and order type (built-to-order or built-to-stock). The demanded products must reach their dealers before the end of a time horizon. Direct flows are possible if the concerned arcs exist. All exchanges between plants and centers are possible. However, the availability of transportation costs, the frequency of sea transportation, and fiscal constraints on built-to-stock products limit the network. The objective is to optimize the design and planning of the product flow from plants to dealers.

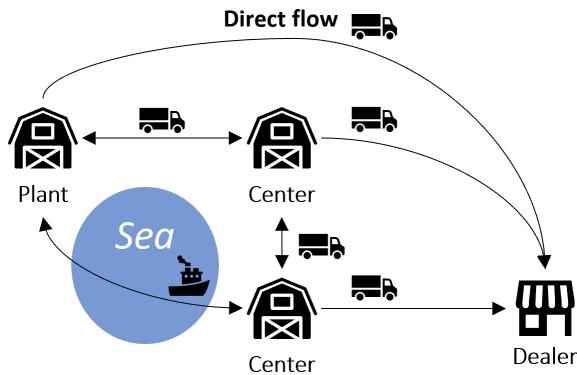


FIGURE 4.2 – Graph example of the BCNDP

A solution's cost is the sum of the three following costs :

- Transportation cost : depends on the number of trucks transporting products by road and the number of products by sea.
- Handling cost : depends on the number of vehicles to go through a center.
- Inventory cost : depends on the number of vehicles stored in centers per period.

The resulting network is modeled as a time-space flow graph. A node is defined by a geographical entity (plant, center, or dealer) and a period. An arc represents a possible flow of a product type between two nodes (see **Chapter 2**).

The problem resolution is too difficult considering industrial instances. Therefore, input aggregation is applied to obtain solutions faster despite the loss of precision that it might imply.

#### 4.2.2 Aggregated solutions

In order to obtain solutions in a reasonable time, aggregations on the input data are proposed. These aggregations differ in their dimensions (product type, spatial, temporal) and levels (amplitude) (see **Chapter 3**).

We apply the following dimensions and levels of aggregations to the BCNDP input. Each of these aggregations is applied to the original input instances ( $I$ ) to obtain aggregated instances ( $I_A$ ) :

- Product type aggregation is an aggregation of vehicle types (CLIO, Megane...) with similar order type, resulting in a loss of precision on the truck fill rate. Only vehicle types that are produced at the same plant can be aggregated. We propose 3 aggregation levels, namely apply 33%, 66%, and 100% (one vehicle type per plant) of the possible vehicle type aggregations ;
- Spatial aggregation is a geographical aggregation of dealers, resulting in a loss of precision on the transportation cost and duration. Only dealers connected to the same centers and plants can be aggregated. We propose 3 aggregation levels, namely aggregate 10%, 20% and 30% of dealers ;

- Temporal aggregation is an aggregation of the time periods in the model, resulting in a loss of precision of the transportation time, inventory cost, product release date, and sea transportation frequency. We propose 6 aggregation levels, namely periods of 2 to 7 days.

Solving the BCNDP with the aggregated input results in an aggregated solution, denoted  $S_A$ , with a cost of  $C(S_A)$ . This cost might be biased due to the loss of precision incurred by input aggregation. The following section gives an idea of how the aggregation can influence the cost of the solutions.

### 4.2.3 Influence of input data aggregation on costs

In the SCND problem presented in Section 4.2.1, there are three cost types : transportation cost, inventory holding cost, and product handling cost at centers. Each data aggregation dimension may induce direct and/or indirect approximations of the costs mentioned above.

Spatial aggregation directly introduces approximations of transportation costs for arcs reaching dealers. However, aggregations also induce indirect alterations in the shape of the solutions and consequently impact the cost. For example, let us assume dealers  $d_1$  and  $d_2$  are aggregated into dealer  $d'$ . If two *CLIO* are transported from center  $i$  to aggregated dealer  $d'$  in the aggregated solution  $S_A$ , a single truck can transport these two *CLIO* from  $i$  to  $d'$ , which costs one truck. However, if within these two *CLIO*, one must go to dealer  $d_1$  and one must go to dealer  $d_2$ , one truck transports one *CLIO* to  $d_1$  and a second truck transports one *CLIO* to  $d_2$  in the disaggregated solution, which costs two trucks. In this case, the transportation cost of the aggregated solution is an underestimation of the transportation cost of the corresponding disaggregated solution.

Temporal aggregation directly induces approximations of the inventory cost per period since several periods are aggregated into one bigger period (e.g., daily periods aggregated in one week). For instance, in an aggregated solution  $S_A$ , a group of vehicles may stay in the inventory during one period (assume one week). In reality, it may only stay for five days, resulting in an overestimated inventory cost. Besides, it induces alterations in the transportation duration and ship frequency, which can also bias the inventory duration in the solution and, thus, indirectly bias the inventory cost. For instance, a group of vehicles may stay in a departure port for one period (assume one week) to wait for a ship departure. In reality, the ship departure frequency may only be four days, resulting in an overestimated inventory cost.

Product type aggregation induces approximation in the truck fill rate of the products, which indirectly leads to a bias in the transportation cost. It also induces a loss of temporal information for the product release date and, therefore, can indirectly impact the inventory cost.

One way to estimate a more accurate cost of  $S_A$  is to disaggregate the solution and recalculate the incurred cost. The latter is called the disaggregated cost  $C(S_{DISA})$

and can be used to estimate the error induced by input aggregation.

#### 4.2.4 Disaggregated cost calculation

The disaggregation consists in running BCNDP with an additional set of constraints ( $cstr(S_A)$ ) using the original input  $I$  (see the introduction of Section 4.2). The  $cstr(S_A)$  are simply constraints expressed as functions of the product quantities to ship through the network, found by the aggregated solutions  $S_A$ . The idea here is to constrain the BCNDP to propose solutions that respect these products' quantities (see **Chapter 3**). Some of the constraints are relaxed if we cannot guarantee that there exists a feasible solution. The result is a disaggregated solution with a cost of  $C(S_{DISA})$ . The difference between  $C(S_A)$  and  $C(S_{DISA})$  is an indicator of the error introduced by the aggregation.

One drawback of this approach is its difficulty in implementation. The  $BCNDP + cstr(S_A)$  model is not easy to solve for industrial-sized instances and is consequently time-consuming and impractical. However, without this disaggregation phase, we are left with a cost of solution that might include a bias, magnitude of which is unknown. Therefore, we propose a methodology to adjust the aggregated cost and thus obtain a better estimation of the real cost of the aggregated solutions for the decision-makers.

### 4.3 Cost adjustment method

We describe a cost adjustment method that is faster to implement in practice than the disaggregation method. This adjustment method consists of adding adjustment values within the cost  $C(S_A)$ . The idea is to estimate the adjustment values to compensate for the bias induced by input aggregation on the cost. In this section, we present three cost adjustment methods.

#### 4.3.1 Principles of the cost adjustment methods

To determine the adjustment values, we propose a multi-scenario LP model : the Cost Adjustment Problem (CAP). The input of CAP are the aggregated solutions  $S_A$  and their target cost  $C(S_{DISA})$ . The output is adjustment values  $E$ . The goal of the CAP is to find the best adjustment values  $E$  to apply on the cost of the aggregated solutions  $C(S_A)$  so that these costs are as close as possible to the corresponding disaggregated cost  $C(S_{DISA})$ .

Let us specify that the adjustment values are applied to each cost type (transportation, handling, and inventory) of the aggregated solution, namely  $TC(S_A)$ ,  $PC(S_A)$ , and  $SC(S_A)$ . Adjustment values applied on a cost type should not compensate for the bias of a different cost type. For example, the adjustment value applied to the transportation cost should not aim at reducing the bias on the inventory cost. Let us denote  $TC(S_{DISA})$ ,  $PC(S_{DISA})$ , and  $SC(S_{DISA})$ , the transportation, handling, and inventory cost of the disaggregated solutions. Therefore, we denote  $TE$ , the adjustment values applied to cost  $TC(S_A)$  to make it closer to  $TC(S_{DISA})$ . Similarly, we denote

$PE$  the adjustment values applied to cost  $PC(S_A)$  to make it closer to  $PC(S_{DISA})$ , and  $SE$  the adjustment values applied to cost  $SC(S_A)$  to make it closer to  $SC(S_{DISA})$ .

We propose three adjustment values calculation methods, namely  $AM\_CostType$ ,  $AM\_Center$ , and  $AM\_Section$ , that involve three refinement formulation levels of the adjustment values applied to the different cost types : transportation, handling, and inventory. The more refined the formulation of adjustment values  $E$ , the more various values they can take. For instance, the least refine formulation has only one adjustment value per cost type. These refinement levels are described in the following subsections.

#### 4.3.2 The model of the cost adjustment problem

All the inputs are common to the three CAP methods. We keep the following information from the BCNDP :

- $P$  is the set of plants
- $W$  is the set of distribution centers
- $T$  is the set of periods
- $A$  is the set of arcs
- $K$  is the set of products
- $tc_{i,j}$  is the transportation cost per unit from entity  $i$  to  $j$ ,  $\forall(i, j) \in A$
- $pc_i$  is the handling cost per product unit through plant or center  $i$ ,  $\forall i \in P \cup W$
- $sc_i$  is the inventory cost per product unit and per period unit at plant or center  $i$ ,  $\forall i \in P \cup W$
- $p_i^{k,t}$  is the quantity of product  $k$  produced at entity  $i$  at period  $t$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $z_{i,j}^t$  is the charged unit quantity from node  $(i, t)$  to entity  $j$ ,  $\forall(i, j) \in A$ ,  $\forall t \in T$
- $l_i^{k,t}$  is the quantity of product  $k$  leaving node  $(i, t)$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$
- $s_i^{k,t}$  is the inventory quantity of product  $k$  at plant or center  $i$  between period  $t$  and  $t + 1$ ,  $\forall i \in P \cup W$ ,  $\forall k \in K$ ,  $\forall t \in T$

We need the following additional input data to construct the CAP models :

- $\mathcal{I}$  is the set of instances
- $TC(S_{DISA}^q)$  is the transportation cost of the disaggregated solution of instance  $q$ ,  $\forall q \in \mathcal{I}$
- $PC(S_{DISA}^q)$  is the handling cost of the disaggregated solution of instance  $q$ ,  $\forall q \in \mathcal{I}$
- $SC(S_{DISA}^q)$  is the inventory cost of the disaggregated solution of instance  $q$ ,  $\forall q \in \mathcal{I}$

We gather the following common variables for the three CAP methods.

- $\mathbf{TC}^E(S_A^q)$  is the adjusted transportation cost of the aggregated solution of instance  $q$ ,  $\forall q \in I$
- $\mathbf{PC}^E(S_A^q)$  is the adjusted handling cost of the aggregated solution of instance  $q$ ,  $\forall q \in I$
- $\mathbf{SC}^E(S_A^q)$  is the adjusted inventory cost of the aggregated solution of instance  $q$ ,  $\forall q \in I$
- $\Delta\mathbf{TC}^q$  is the absolute difference between  $\mathbf{TC}^E(S_A^q)$  and  $TC(S_{DISA}^q)$ ,  $\forall q \in I$
- $\Delta\mathbf{PC}^q$  is the absolute difference between  $\mathbf{PC}^E(S_A^q)$  and  $PC(S_{DISA}^q)$ ,  $\forall q \in I$
- $\Delta\mathbf{SC}^q$  is the absolute difference between  $\mathbf{SC}^E(S_A^q)$  and  $SC(S_{DISA}^q)$ ,  $\forall q \in I$

The CAP models are as follows :

$$\text{Minimize} \quad \sum_{q \in I} \Delta\mathbf{TC}^q + \Delta\mathbf{PC}^q + \Delta\mathbf{SC}^q \quad (0)$$

s.t.

$$|TC(S_{DISA}^q) - \mathbf{TC}^E(S_A^q)| \leq \Delta\mathbf{TC}^q \quad \forall q \in I \quad (1)$$

$$|PC(S_{DISA}^q) - \mathbf{PC}^E(S_A^q)| \leq \Delta\mathbf{PC}^q \quad \forall q \in I \quad (2)$$

$$|SC(S_{DISA}^q) - \mathbf{SC}^E(S_A^q)| \leq \Delta\mathbf{SC}^q \quad \forall q \in I \quad (3)$$

$$Cstr(\mathbf{TC}^E(S_A^q)) \quad \forall q \in I \quad (4)$$

$$Cstr(\mathbf{PC}^E(S_A^q)) \quad \forall q \in I \quad (5)$$

$$Cstr(\mathbf{SC}^E(S_A^q)) \quad \forall q \in I \quad (6)$$

$$\mathbf{TC}^E(S_A^q), \mathbf{PC}^E(S_A^q), \mathbf{SC}^E(S_A^q) \in \mathbf{R}^+ \quad \forall q \in I \quad (7)$$

$$\Delta\mathbf{TC}^q, \Delta\mathbf{PC}^q, \Delta\mathbf{SC}^q \in \mathbf{R}^+ \quad \forall q \in I \quad (8)$$

The objective is to minimize for each type of cost the sum for all instances of the difference between the adjusted cost and the target cost (0). We consider the absolute difference between the adjusted cost and the target cost for the transportation cost (1), the handling cost (2), and the inventory cost (3). These last three constraints can be easily linearized. The linearized version is applied in the numerical experiments. Constraints (4) to (6) differ according to the CAP method. Adjusted costs are positive (7), so are absolute differences (8).

### 4.3.3 Method AM\_CostType

Method *AM\_CostType* uses a single adjustment value for each cost type. Thus, a unique transportation adjustment value is added to the transportation cost of each arc. A unique handling adjustment value is added to the handling cost of each center. Lastly, a unique inventory adjustment value is added to the inventory cost of each center.

We introduce the following adjustment variables :

- $t\epsilon$  is the adjustment variable of the transportation cost
- $p\epsilon$  is the adjustment variable of the handling cost
- $s\epsilon$  is the adjustment variable of the inventory cost

Constraints (4), (5), and (6) become :

$$TC^E(S_A^q) = \sum_{t \in T} \sum_{(i,j) \in A} (tc_{i,j} + t\epsilon) z_{i,j}^{t,q} \quad \forall q \in I \quad (4.\text{CostType})$$

$$PC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (pc_i + p\epsilon) \sum_{k \in K} a_i^{k,t,q} \quad \forall q \in I \quad (5.\text{CostType})$$

$$SC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (sc_i + s\epsilon) \sum_{k \in K} s_i^{k,t,q} \quad \forall q \in I \quad (6.\text{CostType})$$

Besides, we add the last following constraint to ensure that the adjustment values are in  $\mathbf{R}$  :

$$t\epsilon, p\epsilon, s\epsilon \in \mathbf{R} \quad (9.\text{CostType})$$

#### 4.3.4 Method AM\_Center

Method *AM\_Center* uses one adjustment value per flow through one geographical entity for all cost types. Different transportation adjustment values are applied for each starting geographical entity, and different handling and inventory adjustment values are applied for each center. This method involves thinner adjustment values than *AM\_CostType*.

We introduce the following more refined adjustment variables :

- $t\epsilon_i$  is the adjustment variable of the transportation cost starting from entity  $i$ ,  $\forall i \in P \cup W$
- $p\epsilon_i$  is the adjustment variable of the handling cost of entity  $i$ ,  $\forall i \in P \cup W$
- $s\epsilon_i$  is the adjustment variable of the inventory cost of entity  $i$ ,  $\forall i \in P \cup W$

Thus, constraints (4), (5), and (6) become :

$$TC^E(S_A^q) = \sum_{t \in T} \sum_{(i,j) \in A} (tc_{i,j} + t\epsilon_i) z_{i,j}^{t,q} \quad \forall q \in I \quad (4.\text{Center})$$

$$PC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (pc_i + p\epsilon_i) \sum_{k \in K} a_i^{k,t,q} \quad \forall q \in I \quad (5.\text{Center})$$

$$SC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (sc_i + s\epsilon_i) \sum_{k \in K} s_i^{k,t,q} \quad \forall q \in I \quad (6.\text{Center})$$

We add the last following constraint :

$$t\epsilon_i, p\epsilon_i, s\epsilon_i \in \mathbf{R} \quad \forall i \in P \cup W \quad (9.\text{Center})$$

### 4.3.5 Method AM\_Section

In this last method, the adjustment values remain the same for the handling and inventory costs. However, the transportation adjustment values differ for each route section. Consequently, only the adjusted transportation cost differs between *AM\_Center* and *AM\_Section*.

We describe it as follows :

- $t\varepsilon_{i,j}$  is the adjustment variable of the transportation cost from entity  $i$  to entity  $j$ ,  $\forall(i, j) \in A$

This time, constraints (4), (5), and (6) become :

$$TC^E(S_A^q) = \sum_{t \in T} \sum_{(i,j) \in A} (tc_{i,j} + t\varepsilon_{i,j}) z_{i,j}^{t,q} \quad \forall q \in I \quad (4.\text{Section})$$

$$PC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (pc_i + p\varepsilon_i) \sum_{k \in K} a_i^{k,t,q} \quad \forall q \in I \quad (5.\text{Section})$$

$$SC^E(S_A^q) = \sum_{t \in T} \sum_{i \in P \cup W} (sc_i + s\varepsilon_i) \sum_{k \in K} s_i^{k,t,q} \quad \forall q \in I \quad (6.\text{Section})$$

We add the last following constraint :

$$\begin{aligned} t\varepsilon_{i,j} &\in \mathbf{R} \quad \forall(i, j) \in A \quad (9.\text{Section}) \\ p\varepsilon_i, s\varepsilon_i &\in \mathbf{R} \quad \forall i \in P \cup W \end{aligned}$$

Let us note that constraints (5.Center) and (5.Section) and constraints (6.Center) and (6.Section) are similar.

## 4.4 Method implementation

In the previous section, we describe the methods to obtain adjustment values. In terms of usage, these adjustment values will be calculated with historical instances and applied to the cost of solutions to implement. In this section, we propose an implementation protocol of the CAP method to characterize the performance of the adjustment value in reducing the cost error of instances that are not in the “historical” set of instances. This protocol is applied with the three adjustment methods *AM\_CostType*, *AM\_Center*, and *AM\_Section*. We can determine the best CAP method and its relevance by gathering the resulting cost errors.

### 4.4.1 Training the adjustment values

To calculate the adjustment values, we select a training set of instances  $\mathcal{I}^t$ . This set contains aggregated solutions  $S_A^q | q \in \mathcal{I}^t$ . We want to adjust the original cost of the aggregated solutions  $C(S_A)$  so that this adjusted cost  $C^E(S_A^q)$  is as close as possible to these solutions’ disaggregated cost  $C(S_{DISA})$  (see Figure 4.3).

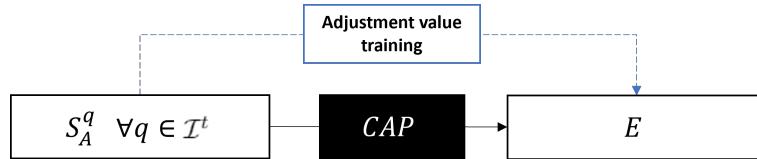


FIGURE 4.3 – Obtaining adjustment values

#### 4.4.2 Validation of the adjustment values

To evaluate the adjustment values, we select a validation set of instances  $\mathcal{I}^v$  different from the training set  $\mathcal{I}^t$  ( $\mathcal{I}^t \cap \mathcal{I}^v = \emptyset$ ) (see Figure 4.4). The adjustment values are applied to  $S_A$  with a cost simulation ( $CAP + cstr(E)$ ). This simulation uses a CAP and sets the adjustment variables to the adjustment values  $E$  found in the training phase. Concretely, it means that the adjustment values that are decision variables of the CAP become input data ( $cstr(E)$ ). From there, we obtain adjusted costs  $C^E(S_A)$  that we compare with target disaggregated costs  $C(S_{DISA})$ . If the new adjusted costs  $C^E(S_A)$  are closer to  $C(S_{DISA})$  than the original costs  $C(S_A)$ , the estimation of the cost is improved.

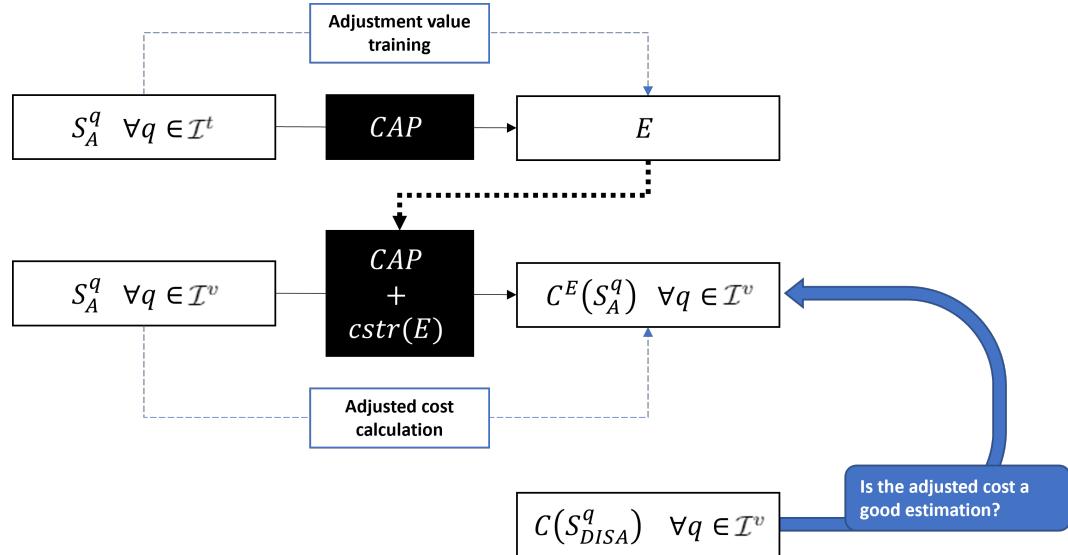


FIGURE 4.4 – Training and validation methodology

### 4.5 Numerical experiments

In this section, we present four types of experiments :

- The first tests aim to analyze how well our CAP methods perform by comparing new costs adjusted with the adjustment values  $C^E(S_A)$  to the initial aggregated solution costs  $C(S_A)$ . To this end, we compare the error obtained in each case referring to the target cost  $C(S_{DISA})$ . The comparisons are conducted on the total cost and per aggregation type (see Section 4.5.1)
- Second tests aim to refine the same analysis per cost type : transportation,

handling, and inventory. Here, only the best-performing CAP method identified in the previous analysis is employed (see Section 4.5.2)

- Third, we compare the performance of the proposed CAP method to another potential estimation tool, namely a simple linear regression. (see Section 4.5.3)
- Lastly, we present a sensitivity analysis of the impact of the choice of the training and validation instances on the CAP performance (see Section 4.5.4).

All experiments are performed on a computer with an Intel Core i7-8850H CPU, 2.60GHz, and 64GB of RAM. CPLEX 12.9 is used as a MILP solver with its Java API.

The data sets are industrial real-case scenarios from the automotive industry. Aggregated solutions  $S_A$  and their disaggregated costs  $C(S_{DISA})$  are taken from **Chapter 2**, which has 12 sets of instance ( $TD1, TD2, TD3, TD4, TD5, TD6, TD7, TD8, TD9, M1, M2$  and  $M3$ ). We divide them into a training set and a validation set as follows :

- ❖  $\mathcal{I}^t = \{TD1, TD2, TD3, TD4, TD5, TD6, M1, M2\}$
- ❖  $\mathcal{I}^v = \{TD7, TD8, TD9, M3\}$

Because of the significant computation time of the BCNDP and the difficulty gathering data, the number of instances is limited. Indeed, we apply for each of these instances in total 12 different aggregations, all dimensions and levels considered. Despite the aggregations reducing the size of the BCNDP, we need to limit its computation time to one hour CPU. The disaggregation method is also difficult to solve and therefore limited to one hour of CPU. Thus, each instance needs 24 hours of computation time to obtain the input of the CAP, the aggregated solutions  $S_A$ , and their disaggregated cost  $C(S_{DISA})$ .

#### 4.5.1 Performance of cost adjustment methods

To evaluate the performance of the CAP methods, we use the error introduced by the aggregation on the cost of the solution  $C(S_A)$  and the error resulting from each CAP method on the cost  $C^E(S_A)$ . Recall that  $C(S_{DISA})$  is the target cost. Hence, these indicators give us the percent deviation of each cost term from the target cost.

- ❖  $Error\_init = \frac{|C(S_A) - C(S_{DISA})|}{C(S_{DISA})}$ , error introduced by the aggregation on the solution cost  $C(S_A)$ ;
- ❖  $Error\_adjust = \frac{|C^E(S_A) - C(S_{DISA})|}{C(S_{DISA})}$ , error obtained after an adjustment method.

Our first experiments show that the adjustment values resulting from *AM\_Center* and *AM\_Section* often take enormous positive or negative values. We fear that the methods tend to “overfit” the instances in the input for a negligible gain on the cost error reduction. This issue remains even when forcing the LP to pick the solution with the smallest adjustment values when several solutions with similar absolute errors exist.

To overcome this matter, we introduce bounds on the adjustment values as follows :

- We bound the adjustment values to  $\pm\beta$ ;
- To avoid having solutions with extreme adjustment values and force more adjustment values to be null, we also try to bound the sum of the adjustment values to  $\pm\beta N$  in *AM\_Center* and to  $\pm\beta N^2$  in *AM\_Section* (with  $N$  being the number of geographical entities). We observe that this constraint indeed allows obtaining solutions with lower adjustment values leading to error reductions of sensibly the same quality than without bounds ;
- Finally, we prevent the error on the cost from deteriorating for each instance in  $\mathcal{I}^t$ . We want the error to be at least as good as without the CAP method for each instance. To do so, we add the following constraint to the model :

$$|TC(S_{DISA}^q) - \mathbf{TC}^E(\mathbf{S}_A^q)| \leq |TC(S_{DISA}^q) - TC(S_A^q)| \forall q \in \mathcal{I}^t \quad (10)$$

$$|PC(S_{DISA}^q) - \mathbf{PC}^E(\mathbf{S}_A^q)| \leq |PC(S_{DISA}^q) - PC(S_A^q)| \forall q \in \mathcal{I}^t \quad (11)$$

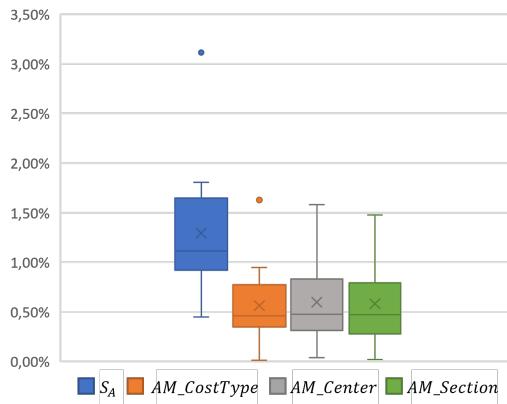
$$|SC(S_{DISA}^q) - \mathbf{SC}^E(\mathbf{S}_A^q)| \leq |SC(S_{DISA}^q) - SC(S_A^q)| \forall q \in \mathcal{I}^t \quad (12)$$

In Section 4.5, which contains the numerical analysis, we only show the best versions of *AM\_Center* and *AM\_Section*. In fact, since the solutions' quality varies according to the applied bounds, we could not simply select one version. Let us specify that the tested bounds  $\beta$  in methods *AM\_Center* and *AM\_Section* are namely 5, 10 and 20.

In this section, the results presented are obtained with the validation instance set  $\mathcal{I}^v$ . The color code in the figures is as follows : blue for  $S_A$ , orange for *AM\_CostType*, grey for *AM\_Center*, and green for *AM\_Section*.

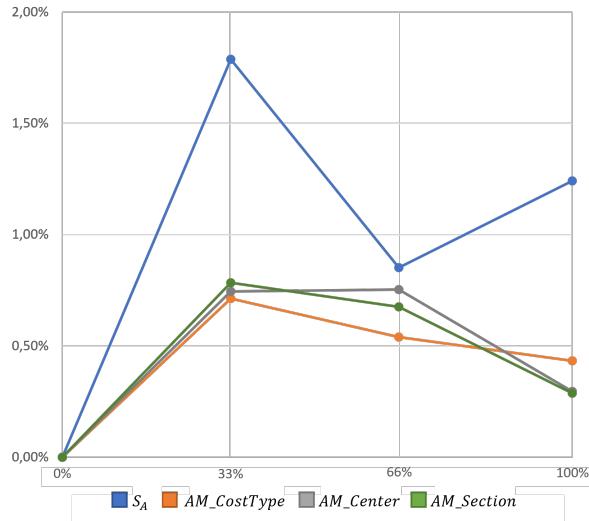
#### 4.5.1.1 Product type aggregation

Figure 4.5 shows *Error\_init* and *Error\_adjust* for the 3 CAP methods, all instances and aggregation levels considered. It is a box plot diagram, where x is the mean value of the  $\mathcal{I}^v$  instances cost errors, all aggregation levels included (in total 12 values, 4 instances with 3 aggregation levels). The bottom and top of the box are the first and third quartiles, and the line within the box is the median. Finally, the bottom and top whiskers are minimum and maximum values. Some extreme values can be outside the whiskers. In this case, they are represented by small circles.


 FIGURE 4.5 – Cost error on  $I^v$  instances with product type aggregation

First, the mean *Error\_init* is 1.29%, and the worst error is 3.11%. Second, on average, *AM\_CostType* shows the best results. The mean *Error\_adjust* reduces by more than half compared to *Error\_init*. Besides, this method shows the smallest “box”, meaning the error are more condensed around the mean error. Thus, this method allows for achieving smaller variability. Furthermore, the best versions within both methods *AM\_Center* and *AM\_Section* is the one using a bound for adjustment values of  $\pm 5$ . More specifically, the smaller the adjustment values are bounded, the smaller the error.

Figure 4.6 shows the detail of these mean errors per aggregation level. From left to right, the aggregation level increases as follows : all the product types, 1/3 of the possible vehicle types aggregated, 2/3 of the possible vehicle types aggregated, and 1 product type per plant.


 FIGURE 4.6 – Mean cost error on  $I^v$  instances according to the product type aggregation level

For the product type aggregation, we do not observe any correlation between the aggregation level and the error in the cost estimation induced by input aggregation.

We cannot see on this diagram a method outperforming the others.

#### 4.5.1.2 Spatial aggregation

Figure 4.7 shows *Error\_init* and *Error\_adjust* with the 3 CAP methods, all instances and aggregation levels considered (in total 12 values, 4 instances with 3 aggregation levels).

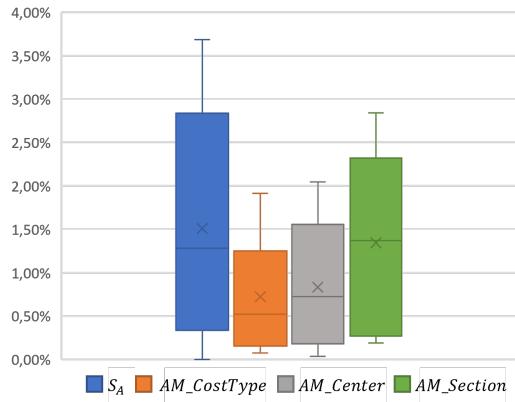


FIGURE 4.7 – Cost error on  $\mathcal{I}^v$  instances with spatial aggregation

First, the mean *Error\_init* is 1.51%, and the maximum *Error\_init* is 3.69%. Second, *AM\_CostType* shows the best *Error\_adjust* reducing the mean error by half compared to *Error\_init*. It is also the method introducing the least variability (smallest box and lowest top whisker). *AM\_CostType* and *AM\_Center* best estimations are obtained without bounds on the adjustment values.

Figure 4.8 shows the mean *Error\_init* and *Error\_adjust* per aggregation level. From left to right, the aggregation levels are as follows : all the dealers differentiated, 10% of the dealers aggregated, 20% of the dealers aggregated, and 30% of the dealers aggregated.

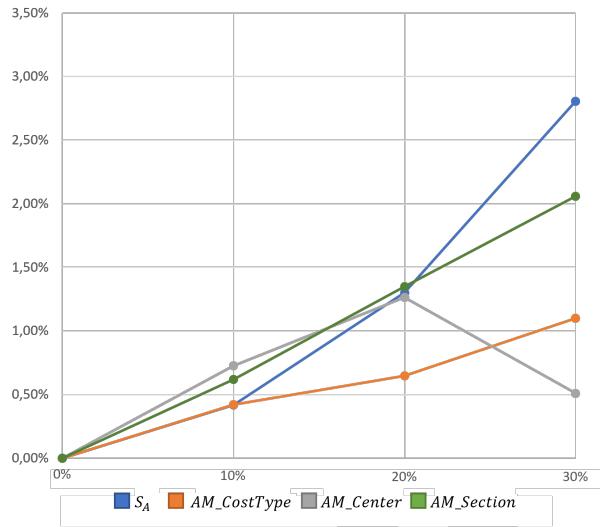


FIGURE 4.8 – Mean cost error on  $\mathcal{I}^v$  instances according to the spatial aggregation level with spatial aggregation

*Error\_init* and *Error\_adjust* deteriorate when the aggregation level increases. Indeed, the higher the aggregation level, the more alterations are applied to the inputs. CAP method  $AM\_CostType$  stands out with all aggregation levels, except for the highest where  $AM\_Center$  performs exceptionally well. Figure 4.8 is a specific example with variable results since  $AM\_Center$  shows very good results for the highest aggregated level, results which we could not predict or interpret.

#### 4.5.1.3 Temporal aggregation

Figure 4.9 shows *Error\_init* and *Error\_adjust* for the 3 CAP methods, all instances and aggregation levels included (in total 24 values, 4 instances with 6 aggregation levels).

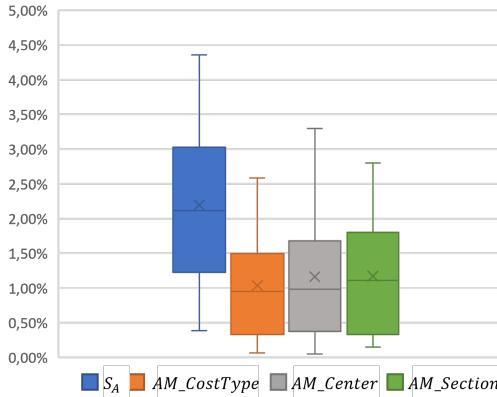


FIGURE 4.9 – Cost error on  $\mathcal{I}^v$  instances with temporal aggregation

First, the mean *Error\_init* is 2.20%, and the maximum *Error\_init* is 4.36%, even though temporal aggregation induces the most significant input alterations. Second, CAP method  $AM\_CostType$  shows the best *Error\_adjust*. It decreases the

mean error by half compared to  $Error\_init$ . This method introduces also the least variability. The best bound version in  $AM\_Center$  and  $AM\_Section$  are the one bounding the adjustment values to  $\pm 10$ .

Figure 4.10 shows the mean  $Error\_init$  and  $Error\_adjust$  per aggregation level.

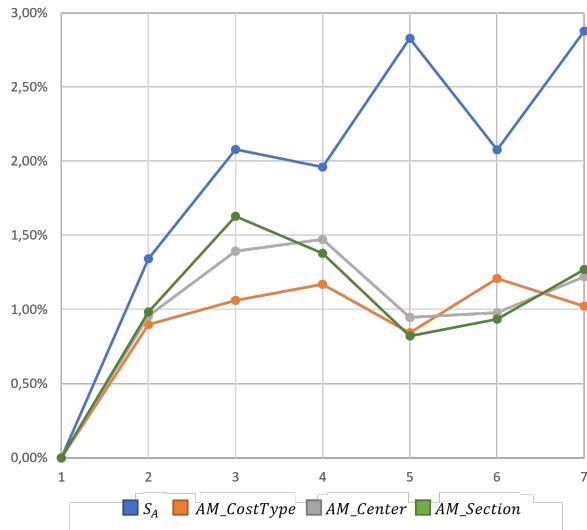


FIGURE 4.10 – Mean cost error on  $\mathcal{I}^v$  instances according to the temporal aggregation level

$Error\_init$  and  $Error\_adjust$  increase with the aggregation level. For most aggregation levels, method  $AM\_CostType$  shows the best results. The only exceptions occur with aggregation levels of 5 and 6 days periods. In these cases,  $AM\_Center$  and  $AM\_Section$  show better performances.

#### 4.5.1.4 Conclusion on the adjustment method

$AM\_CostType$  gives the best results with the least variability. It decreases the mean error by about half for all aggregation dimensions compared to  $Error\_init$ .

In our industrial context, decision-makers participate in the DSS creation. The DSS methodology is mostly transparent, depending on the modeling skills of the decision-makers.  $AM\_CostType$  method contains the adjustment value  $E$  with the simplest formulation (one adjustment value per cost type). It is the most gentle CAP method since the adjustment values tend to take relatively small values. It can be reassuring for decision-makers because the adjustment does not distort the aggregated cost supposedly already close to the real cost. It is also the easiest to implement on the field since decision-makers tend to accept simple formulations better, as they are more likely to understand them.

In conclusion, for performance, simplicity, and managerial purposes, the method  $AM\_CostType$  is selected to realize the following more specific analysis.

### 4.5.2 Analysis per cost type

Input aggregation does not uniformly impact the different cost types since the introduced data alterations do not similarly influence the transportation flows and the use of the distribution centers. Furthermore, each cost type may not impact the total cost with the same intensity. Therefore, we provide further analysis by focusing on the individual cost types.

Figure 4.11 shows the distribution of the cost types for all the target disaggregated solutions  $S_{DISA}$ , all sets of instances  $\mathcal{I}^t$  and  $\mathcal{I}^v$  considered. We observe that the transportation cost represents the most significant part of the total cost, on average 86.66%. Moreover, the handling cost represents 12.59% of the total cost. Lastly, the inventory is almost negligible since it represents 0.75% of the total cost. Besides, this distribution does not vary (widest variation of less than 1%).

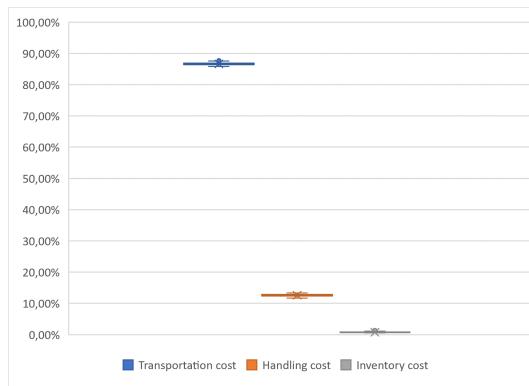


FIGURE 4.11 – Cost types distribution

We conclude that the transportation cost most impacts the total cost. In the upcoming sections, we present the comparative analysis of *Error\_init* and *Error\_adjust* with the CAP method *AM\_CostType* for the different cost types in the order of their importance in the total cost distribution.

#### 4.5.2.1 Error on transportation cost

Let us take a closer look at the transportation cost *Error\_init* and *Error\_adjust* for each aggregation dimension : product type, spatial, and temporal. For the sake of simplicity, we denote :

- ❖  $TError_{init} = \frac{|TC(S_A) - TC(S_{DISA})|}{TC(S_{DISA})}$ , error induced by the aggregation on the solution transportation cost  $TC(S_A)$ ;
- ❖  $TError_{adjust} = \frac{|TC^E(S_A) - TC(S_{DISA})|}{TC(S_{DISA})}$ , error obtained with *AM\_CostType*.

#### Product type aggregation

Figure 4.12 shows *TError\_init* (in blue) and *TError\_adjust* (in orange) according to the product type aggregation level.

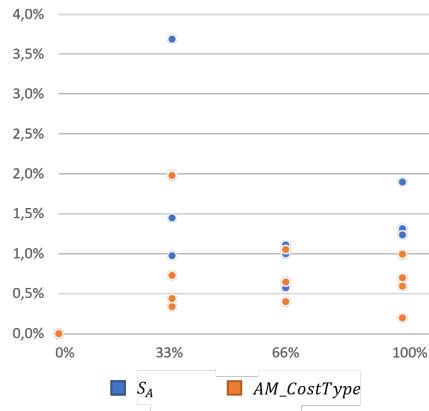


FIGURE 4.12 –  $TError\_init$  and  $TError\_adjust$  according to the product type aggregation level

Product type aggregation does not show a specific increase in the mean or the variability of  $TError\_init$  and  $TError\_adjust$  when the aggregation level increases. On the contrary, they decrease slightly. Approximations introduced by product aggregation do not significantly impact  $TError\_init$  after the first aggregation level. Nevertheless, the CAP method  $AM\_CostType$  reduces the mean error by half on average for each aggregation level.

Let us look at the adjustment values to improve our understanding of the bias introduced by input aggregations. Figure 4.13 shows the adjustment values corresponding to the transportation cost  $t\epsilon$  obtained with  $AM\_CostType$  when product type aggregation is applied.

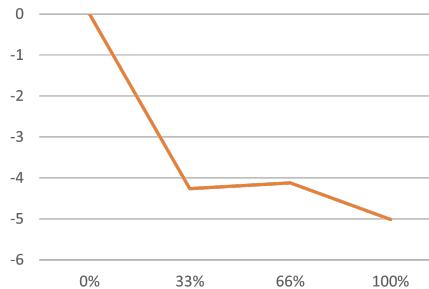


FIGURE 4.13 –  $t\epsilon$  according to the product type aggregation level

First,  $t\epsilon$  is always negative. This result is in line with the fact that  $TC(S_A)$  is systematically overestimated compared to the target cost  $TC(S_{DISA})$ . Second,  $t\epsilon$  variability is relatively low when the aggregation level increases. Lastly, the highest aggregation level most impacts the cost estimation.

A possible interpretation for the cost overestimation lies in the aggregation choice and the demand structure. For instance, let us assume that a truck can contain 8 *CLIO* or 9 *ZOE* or 7 *Megane* and that there is a demand for *CLIO*. If *CLIO* are aggregated with *Megane*, the number of trucks can be overestimated in  $S_A$  (or equal) and therefore  $TC(S_A) \geq TC(S_{DISA})$ . If *CLIO* are aggregated with *ZOE*,

the number of trucks can be underestimated in  $S_A$  (or equal) and therefore also  $TC(S_A) \leq TC(S_{DISA})$ . The more configurations like the *CLIO* (small vehicle) and *Mégane* (big vehicle) aggregation with a high demand of *CLIO* (small vehicle) occur, the more the cost is overestimated. In the first aggregation level (with the most significant adjustment), 5 out of 8 clusters fall into this configuration. We estimate the number of overestimated trucks to 306 against 171 for underestimated trucks.

Let us recall, there is one value for  $t\epsilon$  per aggregation level. To test the variability of the results when  $t\epsilon$  changes, we want to know what happens when a single  $t\epsilon$  value is chosen for all aggregation levels. Figure 4.14 shows the mean  $TError\_adjust$  on all aggregation levels when the mean  $t\epsilon$  is applied (in yellow), when the minimum amplitude  $t\epsilon$  is applied (in dark grey), and when the maximum amplitude  $t\epsilon$  is applied (in purple).

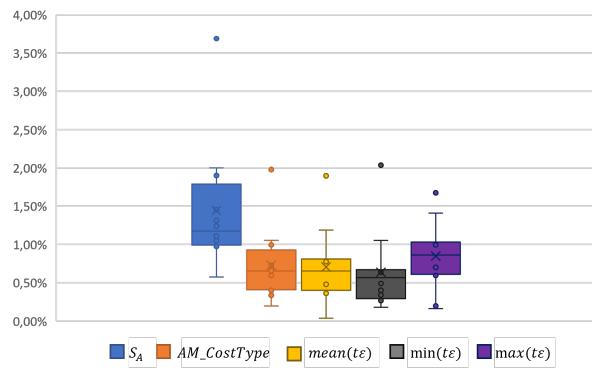


FIGURE 4.14 – error according to the  $t\epsilon$  value with product type aggregation

Since  $t\epsilon$  values are so close for the different aggregation levels, we observe similar quality results when applying a unique  $t\epsilon$  on all aggregation levels. As a result, the variability of *AM\_CostType* is also low when  $t\epsilon$  slightly varies, and we could apply a unique  $t\epsilon$  for all aggregation levels.

### Spatial aggregation

Figure 4.15 shows  $TError\_init$  (in blue) and  $TError\_adjust$  (in orange) according to the spatial aggregation level.

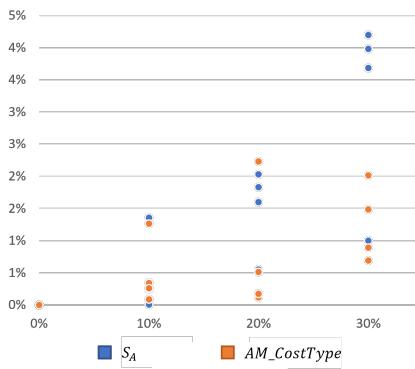


FIGURE 4.15 –  $TError\_init$  and  $TError\_adjust$  according to the spatial aggregation level

Regarding spatial aggregation,  $TError\_init$  values and variability increase monotonously with the aggregation level. On the other hand,  $TError\_adjust$  improves when the aggregation level increases. The greater the error induced by aggregation, the more efficient the  $AM\_CostType$  method seems. Besides, the variability of  $TError\_adjust$  is always smaller than for  $TError\_init$ .

Figure 4.16 shows the adjustment values  $t\epsilon$  corresponding to the transportation cost when spatial aggregation is applied.

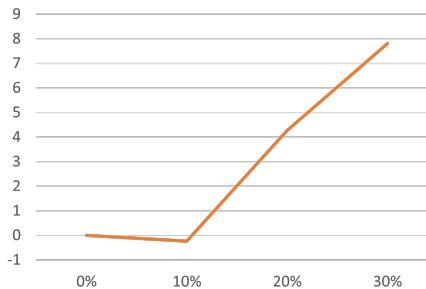


FIGURE 4.16 –  $t\epsilon$  according to the spatial aggregation level

Increasing the spatial aggregation level leads to increasing  $t\epsilon$ . It seems, therefore, that spatial aggregation causes the underestimation of the transportation cost. Indeed, the more spatially aggregated the input is, the more underestimated the cost, and thus the higher the adjustment value.

The underestimation of the transportation cost is caused by the devaluation of the number of trucks on the arcs delivering car dealerships. For instance, let us assume dealers  $d_1$  and  $d_2$  are aggregated into dealer  $d'$  and that 2 vehicles are transported in 1 truck to  $d'$ . If, in reality, within these 2 vehicles, one is asked by  $d_1$  and the other by  $d_2$ , 2 trucks are necessary to realize the transportation.  $C(S_A)$  is thus underestimated.

Since  $t\epsilon$  values increases with the aggregation level, it might not be possible to use a unique  $t\epsilon$  value for all aggregation levels. Figure 4.17 shows the mean  $TError\_adjust$  on all aggregation levels when the mean  $t\epsilon$  is applied (in yellow), when the minimum

amplitude  $t\epsilon$  is applied (in dark grey), and when the maximum amplitude  $t\epsilon$  is applied (in purple).

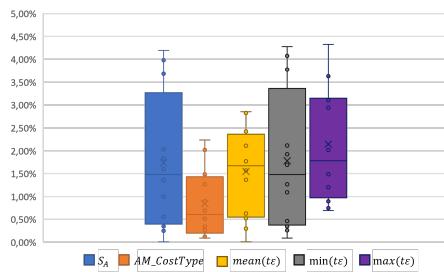


FIGURE 4.17 – error according to the  $t\epsilon$  value with spatial aggregation

Only the mean adjustment value (on all aggregation levels) shows acceptable results, yet not as good as differentiating the  $t\epsilon$  per aggregation level (see Figure 4.17). Minimum or maximum  $t\epsilon$  values deteriorate  $TError\_init$ .

### Temporal aggregation

Figure 4.18 shows  $TError\_init$  (in blue) and  $TError\_adjust$  (in orange) according to the temporal aggregation level (periods from 1 to 7 days duration).

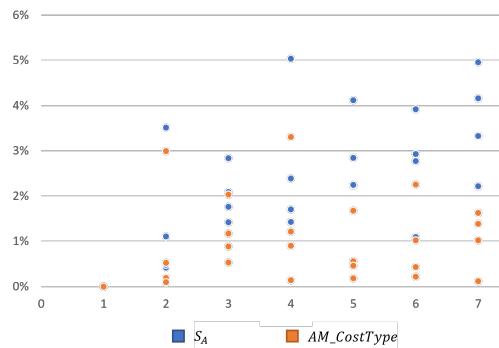


FIGURE 4.18 –  $TError\_init$  and  $TError\_adjust$  according to the temporal aggregation level

Temporal aggregation also induces an increase in  $TError\_init$  when the aggregation level increases.  $TError\_init$  variability fluctuates with the input aggregation level without showing a clear tendency.  $TError\_adjust$  improves when the aggregation level increases.

Figure 4.19 shows the adjustment values  $t\epsilon$  corresponding to the transportation cost when temporal aggregation is applied.

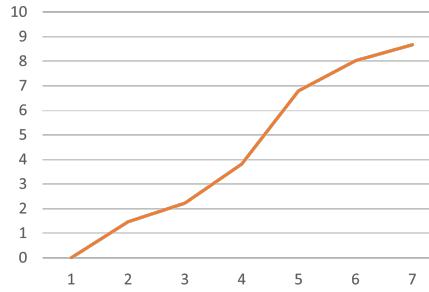


FIGURE 4.19 –  $t\epsilon$  according to the temporal aggregation level

We can observe that the adjustment value are positive and increase with the aggregation level, in accordance with the underestimation of the transportation cost induced by temporal aggregations.

Indeed, temporal aggregation allows for product densification within trucks. These densifications are only achievable because the period granularity is large. Consequently, less trucks are due in  $S_A$  than  $S_{DISA}$ .

As spatial aggregation adjustment values  $t\epsilon$ , the  $t\epsilon$  value increases with the aggregation level. The mean  $TError\_adjust$  value for all aggregation dimensions and levels when applying a unique  $t\epsilon$  are shown in Figure 4.20.

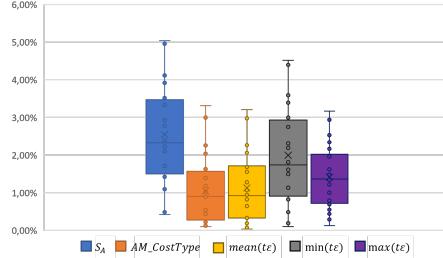


FIGURE 4.20 – error according to the  $t\epsilon$  value with temporal aggregation

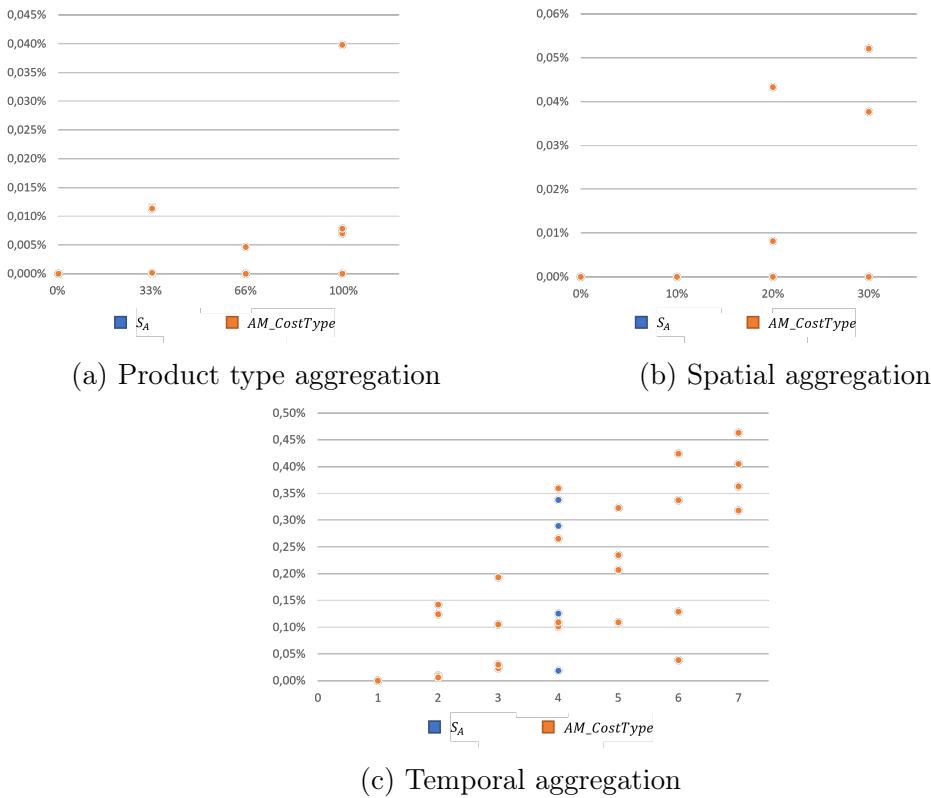
Mean and maximum amplitude  $t\epsilon$  reveal acceptable  $TError\_adjust$ , close to the when  $t\epsilon$  are differentiated by aggregation level.

#### 4.5.2.2 Error on the handling cost

As mentioned above, the handling cost represents, on average, 12.59% of the total cost. For the sake of simplicity, we denote :

- ❖  $PError\_init = \frac{|PC(S_A) - PC(S_{DISA})|}{PC(S_{DISA})}$ , error induced by the aggregation on the solution handling cost  $PC(S_A)$ ;
- ❖  $PError\_adjust = \frac{|PC^E(S_A) - PC(S_{DISA})|}{PC(S_{DISA})}$ , error obtained with  $AM\_CostType$ .

Let us look at the impact of input aggregation on  $PError\_init$  and  $PError\_adjust$  (Figure 4.21).


 FIGURE 4.21 –  $PError\_init$  and  $PError\_adjust$  according to the aggregation level

$PError\_init$  is minor and reaches a maximum of 0.76% for a temporal aggregation of 5 days periods with instance  $TD3$ . The error of 0.76% of 12.59% (less than 0.1%) of the total cost is negligible. Besides,  $PError\_adjust$  does not improve compared to  $PError\_init$ . Let us precise that the blue dots often do not appear in the previous figures since they are hidden behind the orange dot, meaning that the adjustment is so small that we obtain the same error between  $PError\_init$  and  $PError\_adjust$ . Therefore, we recommend leaving the handling cost type as it is.

#### 4.5.2.3 Error on the inventory cost

The inventory cost represents 0.75% of the total cost. The maximum initial error is 244% for a temporal aggregation of 6 days periods (obtained with  $TD3$ ). Consequently, the inventory cost is not very informative for decision-makers. However, this bias does not impact the global cost since the inventory cost only represents 0.75% of the total cost. Thus, this error is 244% of 0.75% of the total cost, leading to a global error of 1.83%.

Nevertheless, let us explain why the inventory cost error could explode this much. The inventory cost calculation depends strongly on the temporal aspects of the solutions. Moreover, the disaggregation method does not always maintain the temporal information from  $S_A$ , depending on the aggregation dimension. Therefore,  $S_A$  and  $S_{DISA}$  may differ temporally. This effect also impacts the adjustment method  $AM\_CostType$ , which becomes obsolete when too much temporal information is lost

during the disaggregation process.

Temporal aggregation is the most impacted aggregation dimension since no temporal information is kept between  $S_A$  and  $S_{DISA}$ . Therefore, we observe an explosion in the inventory cost error. The second most impacted aggregation dimension is the product type aggregation, whose disaggregation induces a partial loss of temporal information. On the other hand, temporal information is not altered during the disaggregation of spatially aggregated solutions. Therefore, the cost error is relatively small in this case (maximum error of 5.33% obtained for  $M2$  with an aggregation of 30% of the dealers).

#### 4.5.3 Performance comparison with a linear regression

Given the same data set, one can also propose cost adjustments using a simple linear regression. Therefore, in this section, we propose a comparison of  $AM\_CostType$  with a simple linear regression to explore the interest of the former method further.

For the sake of simplicity, we denote :

- ❖  $TC^{reg}(S_A)$  the adjusted transportation cost obtained with the simple linear regression method ;
- ❖  $TError\_reg = \frac{|TC^{reg}(S_A) - TC(S_{DISA})|}{TC(S_{DISA})}$  the error of the cost obtained with the simple linear regression  $TC^{reg}(S_A)$ .

For the simple linear regression, the set of instances  $\mathcal{I}^t$  is used to find an affine curve ( $y = mx + b$ ) representing the new adjusted cost. The linear regression uses the Least Square method formulation :

- ❖  $m = \frac{\sum_{q \in \mathcal{I}^t} (C(S_A^q) - \bar{x})(C(S_{DISA}^q) - \bar{y})}{\sum_{q \in \mathcal{I}^t} (C(S_A^q) - \bar{x})^2}$  where  $\bar{x} = Mean(C(S_A^q) | q \in \mathcal{I}^t)$  and  $\bar{y} = Mean(C(S_{DISA}^q) | q \in \mathcal{I}^t)$
- ❖  $b = \bar{y} - m\bar{x}$

Tables 4.1, 4.2 and 4.3 contain  $TError\_adjust$  and  $TError\_reg$  For the sake of simplicity and since the error on the training set  $\mathcal{I}^t$  is relatively tiny for both methods, only validation instances  $\mathcal{I}^v$  are included in the tables.

Aggregation level	Instance	$S_A$	$AM\_CostType$	Linear Regression
33%	<i>TD7</i>	1.45%	0.33%	0.74%
	<i>TD8</i>	0.98%	0.73%	0.67%
	<i>TD9</i>	2.00%	0.44%	0.40%
	<i>M3</i>	3.69%	1.98%	0.62%
	<b>Mean</b>	<b>2.03%</b>	<b>0.87%</b>	<b>0.61%</b>
66%	<i>TD7</i>	1.05%	0.66%	0.32%
	<i>TD8</i>	1.00%	0.65%	0.65%
	<i>TD9</i>	1.11%	0.40%	0.41%
	<i>M3</i>	0.57%	1.05%	3.57%
	<b>Mean</b>	<b>0.93%</b>	<b>0.69%</b>	<b>1.24%</b>
100%	<i>TD7</i>	1.90%	0.20%	1.15%
	<i>TD8</i>	1.31%	0.70%	0.34%
	<i>TD9</i>	1.24%	0.59%	0.32%
	<i>M3</i>	0.99%	0.99%	3.19%
	<b>Mean</b>	<b>1.36%</b>	<b>0.62%</b>	<b>1.25%</b>
<b>Mean</b>		<b>1.44%</b>	<b>0.73%</b>	<b>1.03%</b>

TABLE 4.1 – Errors resulting from input aggregation, the adjustment method, and the linear regression for product type aggregation

Aggregation level	Instance	$S_A$	$AM\_CostType$	Linear Regression
10%	<i>TD7</i>	0.25%	0.34%	0.00%
	<i>TD8</i>	0.01%	0.09%	0.07%
	<i>TD9</i>	0.35%	0.26%	0.29%
	<i>M3</i>	1.35%	1.27%	0.32%
	<b>Mean</b>	<b>0.49%</b>	<b>0.49%</b>	<b>0.17%</b>
20%	<i>TD7</i>	1.60%	0.12%	1.35%
	<i>TD8</i>	1.83%	0.18%	1.91%
	<i>TD9</i>	2.03%	0.51%	2.06%
	<i>M3</i>	0.55%	2.23%	0.44%
	<b>Mean</b>	<b>1.50%</b>	<b>0.76%</b>	<b>1.44%</b>
30%	<i>TD7</i>	3.98%	0.89%	3.72%
	<i>TD8</i>	3.68%	0.69%	3.74%
	<i>TD9</i>	4.20%	1.48%	4.22%
	<i>M3</i>	1.00%	2.02%	1.98%
	<b>Mean</b>	<b>3.22%</b>	<b>1.27%</b>	<b>3.42%</b>
<b>Mean</b>		<b>1.62%</b>	<b>0.84%</b>	<b>1.68%</b>

TABLE 4.2 – Errors resulting from input aggregation, the adjustment method, and the linear regression for spatial aggregation

Aggregation level	Instance	<i>SA</i>	<i>AM_CostType</i>	Linear Regression
2 days	<i>TD7</i>	0.42%	0.19%	0.75%
	<i>TD8</i>	1.11%	0.53%	0.19%
	<i>TD9</i>	3.51%	2.99%	2.58%
	<i>M3</i>	0.48%	0.10%	0.18%
	<b>Mean</b>	<b>1.38%</b>	<b>0.95%</b>	<b>0.93%</b>
3 days	<i>TD7</i>	2.09%	1.18%	0.93%
	<i>TD8</i>	1.42%	0.53%	0.48%
	<i>TD9</i>	2.84%	2.03%	1.88%
	<i>M3</i>	1.76%	0.89%	1.46%
	<b>Mean</b>	<b>2.03%</b>	<b>1.16%</b>	<b>1.19%</b>
4 days	<i>TD7</i>	1.43%	0.91%	0.25%
	<i>TD8</i>	2.39%	3.31%	1.46%
	<i>TD9</i>	5.04%	0.14%	4.10%
	<i>M3</i>	1.71%	1.21%	1.40%
	<b>Mean</b>	<b>2.64%</b>	<b>1.39%</b>	<b>1.80%</b>
5 days	<i>TD7</i>	2.23%	0.56%	1.07%
	<i>TD8</i>	2.25%	0.46%	1.31%
	<i>TD9</i>	4.12%	1.68%	3.16%
	<i>M3</i>	2.84%	0.19%	2.54%
	<b>Mean</b>	<b>2.86%</b>	<b>0.72%</b>	<b>2.02%</b>
6 days	<i>TD7</i>	1.09%	2.25%	0.08%
	<i>TD8</i>	2.77%	0.43%	1.83%
	<i>TD9</i>	3.92%	1.02%	2.96%
	<i>M3</i>	2.93%	0.22%	2.62%
	<b>Mean</b>	<b>2.68%</b>	<b>0.98%</b>	<b>1.88%</b>
7 days	<i>TD7</i>	2.22%	1.39%	1.04%
	<i>TD8</i>	3.33%	0.12%	2.39%
	<i>TD9</i>	4.16%	1.02%	3.20%
	<i>M3</i>	4.96%	1.63%	4.66%
	<b>Mean</b>	<b>3.67%</b>	<b>1.04%</b>	<b>2.82%</b>
<b>Mean</b>		<b>2.54%</b>	<b>1.04%</b>	<b>1.77%</b>

TABLE 4.3 – Errors resulting from input aggregation, the adjustment method, and the linear regression for temporal aggregation

The simple linear regression shows similar to better performances for the first aggregation level, with all aggregation dimensions considered (33% of the product type aggregations, 10% of the dealers, and 2 days periods). It even reduces the variability of the error.

However, the results are the opposite with all the higher aggregation levels. We observe significant improvements in the mean *TError\_adjust* compared to *TError\_reg*. *TError\_reg* is even worse than *TError\_init*, with 30% of the dealers aggregated and with 66% of the product type aggregations.

On average, considering all aggregation levels, *TError\_adjust* is always better than *TError\_reg*, despite the excellent performance of the linear regression with the first aggregation level. *TError\_adjust* improves by 0.30%, 0.84%, and 0.73% for product type, spatial, and temporal aggregation, compared to *TError\_reg*.

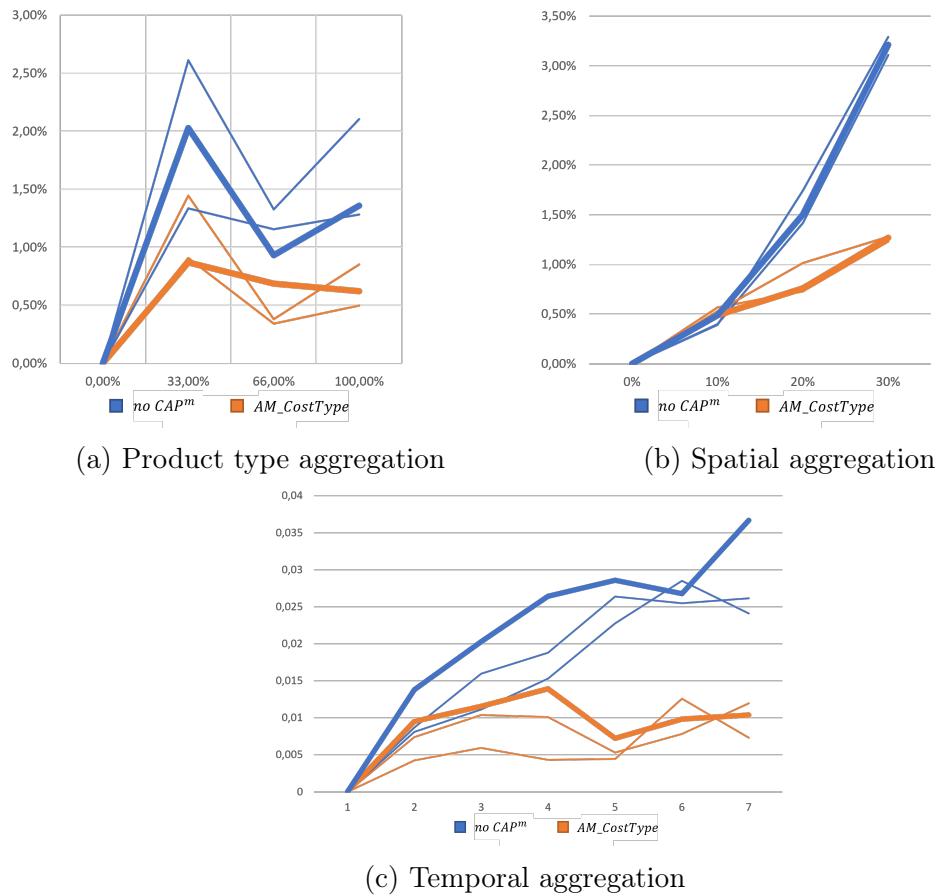
#### 4.5.4 Sensitivity analysis of the training and validation sets distribution

Finally, we want to question the influence of the choice of the training and validation instance sets ( $\mathcal{I}^t$  and  $\mathcal{I}^v$ , respectively) on the performance of *AM\_CostType*. Table 4.4 gathers the different training and validation set configurations of instances. Configuration 1 is the original configuration used above. It is a natural configuration since instances containing the demand from January and February are in  $\mathcal{I}^t$ , and those containing the demand from March are in  $\mathcal{I}^v$ . Thus, it simulates the training of instances on historical data and the application of the adjustment values to new instances in the future. Configurations 2 and 3 are new configurations attempted in this section.

Configuration	$\mathcal{I}^t$	$\mathcal{I}^v$
1	[TD1, TD2, TD3, M1, TD4, TD5, TD6, M2]	[TD7, TD8, TD9, M3]
2	[TD1, TD2, TD3, M1, TD7, TD8, TD9, M3]	[TD4, TD5, TD6, M2]
3	[TD4, TD5, TD6, M2, TD7, TD8, TD9, M3]	[TD1, TD2, TD3, M1]

TABLE 4.4 –  $\mathcal{I}^t$  and  $\mathcal{I}^v$  configurations

Figure 4.22 shows the mean *TError\_init* in blue and *TError\_adjust* in orange with product type, spatial, and temporal aggregations for instances  $\mathcal{I}^v$ . Configuration 1 is represented thicker than configurations 2 and 3.


 FIGURE 4.22 –  $TError\_init$  and  $TError\_adjust$  with all  $\mathcal{I}^t \mathcal{I}^v$  configurations

Configurations 2 and 3 lead to similar tendencies to the original configuration 1. The error is generally reduced to the same extent as with configuration 1.

Specifically, when product type aggregation is applied,  $TError\_adjust$  is smaller than  $TError\_init$ , regardless of the configuration. For equivalent aggregation levels, the worst improvement is obtained with configuration 1 (improvement of 46% of  $TError\_init$ , on average). In this configuration, the validation set contains the biggest instances (the demanded quantities are much more significant in march). In comparison, configurations 2 and 3 improve  $TError\_init$  by 59% and 55%. Therefore, the improvements are better when instances in  $\mathcal{I}^t$  contains more significant demands.

Considering spatial aggregation, for equivalent aggregation levels, the improvement of  $TError\_init$  remains relatively stable regardless of the configuration. In all cases, it is not improved for the first aggregation level.  $TError\_init$  is improved between 42% and 49% for the second aggregation level and by 60% for the third aggregation level, all configurations considered.

When temporal aggregation is applied,  $TError\_init$  is improved, regardless of the configuration. The average improvements are 55%, 66%, and 41% for configurations 1, 2, and 3, respectively. However, the improvement's variability is much higher than the other aggregation dimensions for the different aggregation levels.

In conclusion, *AM\_CostType* shows consistent improvement of the error regardless of the training and validation instances configuration. In some cases, *AM\_CostType* performs better when the instances with greater demands are in the  $\mathcal{I}^t$ . Therefore, increasing the number of instances in the training set could be a good area for improvement.

## 4.6 Conclusion

Input aggregation is an intuitive method to reduce the size of a *SCNDP* model. It is also beneficial to reduce the amount of data to be collected. In the era of big data and sustainability, the trade-off between collecting and storing large amounts of data sets or reduced but useful data becomes an interesting question (Brint et al., 2021).

Unfortunately, input data aggregation can introduce a bias in the cost of the model's solutions. We analyze this bias and propose an efficient method to adjust the cost of the aggregated solutions to counterbalance this error for a real industrial *SCNDP* model of the automotive industry. This method appears better than a simple linear regression. Despite an original error relatively low (maximum mean error of 2.30%), the selected cost adjustment method reduces the mean cost error by half on average, with all aggregation dimensions (product type, spatial, and temporal) and levels considered. Lastly, the cost estimation improvement increases with the aggregation level. These savings may appear very small in percentage. However, in terms of expenses, reducing a cost error in logistics by 1 or 2 percent could sum up to several million dollars. In 2019, the global logistics market was valued at USD 141.8 billion for the automotive industry<sup>1</sup>. In this very competitive environment, cutting logistics costs, which do not add value to the final product, is an essential stake.

Lastly, the method involves an adjustment values calculation phase trained with a set of instances (training set). Then, the adjustment values are applied to a new validation set of instances. The numerical experiments show that the method performance is independent of the training and validation set distribution.

In our industrial context, decision-makers are involved in the design process of the *DSS*. The *DSS* developer must be able to explain the ideas behind the solution creation within the *DSS* so that the decision-maker trusts and accepts the *DSS*. Considering the best cost adjustment method (a component of our *DSS*), the method possesses the simplest formulation. This component is, therefore, easier to implement and apprehend for users. Additionally, the fact that the method applies relatively small but efficient adjustment values can reassure users. In fact, obtaining small adjustment values implies that the initial cost error is relatively small and that the adjustment does not significantly distort the aggregated cost. In conclusion, for performance, simplicity, and acceptance purposes, the method *AM\_CostType* is the most appropriate for the industrial case.

---

1. Grand View Research 2023 <https://www.grandviewresearch.com/industry-analysis/automotive-logistics-market>

In practice, two usage questions arise. First, the disaggregated target costs could be calculated with our proposed method or a different one. For example, real-life past costs could be used. However, one should be careful that the real applied network design is sufficiently similar to the network obtained in the aggregated solution  $S_A$ . Second, an appropriate strategy for updating the adjustment must be implemented. The training set must contain enough instances, and these could also represent the demand seasonality of the considered period.

Further analysis could expand the size of the training set in the multi-scenario  $LP$  model to obtain more effective adjustment values. In our case, we only have a few instances (12 solutions and target costs). Unfortunately, generating more data takes input-gathering time and involves a significant computation time for each added instance and aggregation dimension or level. Lastly, our problem's real-world nature predetermines data availability limits.





# Conclusion générale

La conception de réseau logistique pour l'industrie automobile s'appuie sur les outils d'aide à la décision qui permettent d'exploiter au mieux des réseaux de transports contractualisés. Les problèmes de conception se modélisent sous la forme du problème de Conception de réseaux logistiques (CRL) servant à prendre des décisions tactiques à stratégiques. Pour faciliter la résolution de tels modèles de taille industrielle, il est possible de travailler le niveau de détail des données d'entrée pour que celui-ci soit en concordance avec le caractère global des décisions concernées.

Cette étude contribue à proposer un outil de conception du réseau de distribution de véhicules pour l'industrie automobile et répond au besoin d'une méthode pour préconiser un bon niveau d'agrégation des données d'entrée pour cet outil. Au cours des analyses, nous montrons que l'étude d'un bon niveau de détail des données d'entrées est fondamentale pour résoudre de tels problèmes. Un accent est tout particulièrement porté sur l'acceptation de l'outil final proposé par les utilisateurs qui conçoivent le réseau.

## Synthèse des contributions

Dans ce manuscrit, nous nous intéressons à un problème de CRL pour la distribution de véhicules du constructeur automobile Renault dont nous proposons une modélisation. Notre objectif est de définir une méthodologie qui permet de préconiser une agrégation de données d'entrée pour les problèmes de CRL. Nous proposons une façon de définir différentes dimensions et niveaux d'agrégations possibles pour le problème étudié. Notre méthodologie se base sur une analyse quantitative de l'impact d'agrégations de données d'entrée sur un modèle de CRL. L'analyse prend en compte l'impact des agrégations sur la qualité des solutions (le coût de la fonction objectif) et la forme des flux (taux de flux directs...) par rapport aux solutions obtenues sans agrégation. Enfin, une étude de l'erreur sur l'estimation du coût (comparé au coût des mêmes solutions désagrégées) ainsi qu'une méthode d'ajustement du coût permettent de quantifier et réduire les biais induits par les agrégations.

En conclusion, les agrégations préconisées permettent pour le problème considéré :

- d'obtenir de meilleures solutions dans un temps de calcul limité ;
- de maintenir les caractéristiques physiques des solutions ;
- de contenir une erreur sur l'estimation du coût satisfaisante et interprétable ;
- et enfin de réduire cette erreur avec une méthode rapide d'ajustement du coût.

La simplification de la résolution de problème dans notre étude a pour but de permettre d'atteindre des solutions de bonne qualité dans un temps de calcul acceptable pour les utilisateurs. Enfin, nous avons pu écarter un facteur pouvant impacter la confiance envers les agrégations proposées, à savoir l'incertitude sur la précision des coûts des solutions obtenues. En effet, une méthode rapide de réajustement du coût permet de réduire de moitié en moyenne l'écart entre le coût des solutions agrégées et celles que l'on obtiendrait après désagrégation.

## Perspectives

Notre objectif est de proposer une méthodologie afin de déterminer le bon niveau d'agrégation des données d'entrées pour les problèmes de CRL. Nous proposons une étude quantitative appliquée à un problème spécifique pour montrer l'intérêt de notre méthode. Il serait intéressant d'analyser l'impact d'agrégations sur d'autres modèles de CRL, d'autant plus s'ils comportent des décisions de niveau stratégique comme des coûts d'utilisation de centres.

La définition de nos niveaux d'agrégation se base sur le nombre de variables de décisions dans le modèle. Il existe d'autres moyens de simplifier des modèles pour rendre leur résolution plus facile. Par exemple, certains problèmes contiennent des fonctions de coût ou des contraintes de capacité minimum et/ou maximum très complexes (par exemple des fonctions par pallier). Il serait intéressant d'analyser de tels modèles et de simplifier graduellement ces fonctions pour en observer l'impact sur la précision des résultats et le temps de calcul. Notre problème contenait des coûts de transports particuliers. Ainsi, nous avons pu entre-ouvrir cette problématique en comparant les résultats de notre modèle avec un même modèle dans lequel cet aspect a été simplifié.

Nous comparons des solutions obtenues avant la fin des recherches arborescente, car le problème étudié ne peut converger vers une solution optimale dans un temps de calcul acceptable. L'analyse d'un modèle plus simple à résoudre, ou dont la taille est plus restreinte, pourrait permettre de comparer les solutions agrégées à la solution optimale obtenue sans agrégation.

Comme évoqué plus tôt, notre étude utilise la simplification de modèles en tant que moyen pour réduire le temps de leur résolution et d'améliorer leur acceptabilité. Il serait intéressant de s'intéresser à d'autres avantages que peut amener l'agrégation de données, comme par exemple des économies de ressources. En effet, l'agrégation de données d'entrée d'un modèle peut être catégorisée en tant qu'« innovation frugale » (Bhatti et al., 2013). L'agrégation d'information permet de simplifier un modèle pour être en concordance avec le besoin de ses utilisateurs, au lieu de tendre vers une solution accessoirement plus complexe et coûteuse en ressources. Dans ce sens, d'autres indicateurs pourraient être observés, comme, par exemple :

- l'énergie consommée pour le calcul de solutions ;
- le temps de récupération et préparation des données d'entrées ;
- le temps de développement de l'outil ;

## CONCLUSION GÉNÉRALE

- les compétences nécessaires pour le maintien de l'outil. En entreprise, il faut considérer avoir du personnel connaissant l'outil ou pouvant se l'approprier relativement rapidement. Sinon, le risque est de perdre l'outil, si un problème survient. Une météuristiche peut nécessiter plus de compétences et de temps pour s'en imprégner que l'agrégation de données d'entrée.
- L'innovation frugale a d'abord reçu beaucoup d'attention comme moyen d'améliorer la compétitivité des entreprises. Plus récemment, ses principes sont considérés comme un vecteur permettant d'accomplir des économies de ressources et de tendre vers des organisations durables et robustes dans un contexte de crise environnementale. Identifier l'innovation pertinente à mettre en place pour les besoins des utilisateurs reste cependant un exercice complexe.



# Bibliographie

- E. Alarcon-Gerbier & U. Buscher. Modular and mobile facility location problems : A systematic review. *Computers & Industrial Engineering*, page 108734, 2022.
- M. Albareda-Sambola, E. Fernández, Y. Hinojosa, & J. Puerto. The multi-period incremental service facility location problem. *Computers & Operations Research*, 36 (5) :1356–1375, 2009.
- J. A. Aloysius, F. D. Davis, D. D. Wilson, A. R. Taylor, & J. E. Kottemann. User acceptance of multi-criteria decision support systems : The impact of preference elicitation techniques. *European Journal of Operational Research*, 169(1) :273–285, 2006.
- S. Alumur & B. Y. Kara. Network hub location problems : The state of the art. *European Journal of Operational Research*, 190 :1–21, 2008.
- S. A. Alumur, S. Nickel, F. Saldanha-da Gama, & V. Verter. Multi-period reverse logistics network design. *European Journal of Operational Research*, 220(1) :67–78, 2012.
- S. A. Alumur, S. Nickel, F. S. da Gama, & Y. Seçerdin. Multi-period hub network design problems with modular capacities. *Operations Research Letters*, 33(2) :134–142, 2015.
- S. A. Alumur, J. F. Campbell, I. Contreras, B. Y. Kara, V. Marianov, & M. E. O’Kelly. Perspectives on modeling hub location problems. *European Journal of Operational Research*, 291(1) :1–17, 2021.
- D. Ambrosino & M. G. Scutellà. Distribution network design : New problems and related models. *European Journal of Operational Research*, 165(3) :610–624, 2005.
- M. Amiri-Aref, W. Klibi, & M. Z. Babai. The multi-sourcing location inventory problem with stochastic demand. *European Journal of Operational Research*, 266 (1) :72–87, 2018.
- D. Andersson & L. O. Eriksson. Effects of temporal aggregation in integrated strategic/tactical and strategic forest planning. *Forest Policy and Economics*, 9(8) :965–981, 2007.
- S. Ansari, M. Baştıre, X. Li, Y. Ouyang, & K. Smilowitz. Advancements in continuous approximation models for logistics and transportation systems : 1996–2016. *Transportation Research Part B : Methodological*, 107 :229–252, 2018.

- A. Antunes & D. Peeters. A dynamic optimization model for school network planning. *Socio-Economic Planning Sciences*, 34(2) :101–120, 2000.
- A. Antunes & D. Peeters. On solving complex multi-period location models using simulated annealing. *European Journal of Operational Research*, 130(1) :190–201, 2001.
- A. B. Arabani & R. Z. Farahani. Facility location dynamics : An overview of classifications and applications. *Computers & Industrial Engineering*, 62(1) :408–420, 2012.
- P. Avella, M. Boccia, S. Salerno, & I. Vasilyev. An aggregation heuristic for large scale p-median problem. *Computers & Operations Research*, 39(7) :1625–1632, 2012.
- M. N. Azaiez. Aggregation in decision problems : Concepts and applications. *Journal of King Saud University-Engineering Sciences*, 21(2) :101–109, 2009.
- A. Bajaj & S. R. Nidumolu. A feedback model to understand information system usage. *Information & management*, 33(4) :213–224, 1998.
- A. Balakrishnan & S. C. Graves. A composite algorithm for a concave-cost network flow problem. *Networks*, 19(2) :175–202, 1989.
- R. H. Ballou. Unresolved issues in supply chain network design. *Information Systems Frontiers*, 3(4) :417–426, 2001.
- M. J. Basallo-Triana, C. J. Vidal-Holguín, & J. J. Bravo-Bastidas. Planning and design of intermodal hub networks : A literature review. *Computers & Operations Research*, 136 :105469, 2021.
- M. Beynon, S. Rasmequan, & S. Russ. A new paradigm for computer-based decision support. *Decision Support Systems*, 33(2) :127–142, 2002.
- Y. Bhatti, S. E. Khilji, & R. Basu. Frugal innovation. In *Globalization, change and learning in South Asia*, pages 123–145. Elsevier, 2013.
- A. Brint, A. Genovese, C. Piccolo, & G. J. Taboada-Perez. Reducing data requirements when selecting key performance indicators for supply chain management : The case of a multinational automotive component manufacturer. *International Journal of Production Economics*, 2021.
- A. M. Campbell. Aggregation for the probabilistic traveling salesman problem. *Computers & Operations Research*, 33(9) :2703–2724, 2006.
- C. Canel, B. M. Khumawala, J. Law, & A. Loh. An algorithm for the capacitated, multi-commodity multi-period facility location problem. *Computers & Operations Research*, 28(5) :411–427, 2001.
- M. Cebecauer & L. Buzna. A versatile adaptive aggregation framework for spatially large discrete location-allocation problems. *Computers & Industrial Engineering*, 111 :364–380, 2017.

- S. Chopra. Designing the distribution network in a supply chain. *Transportation Research Part E*, 39 :123–140, 2003.
- I. Contreras, J.-F. Cordeau, & G. Laporte. The dynamic uncapacitated hub location problem. *Transportation Science*, 45(1) :18–32, 2011.
- I. Correia & T. Melo. Multi-period capacitated facility location under delayed demand satisfaction. *European Journal of Operational Research*, 255(3) :729–746, 2016.
- I. Correia & T. Melo. A multi-period facility location problem with modular capacity adjustments and flexible demand fulfillment. *Computers & Industrial Engineering*, 110 :307–321, 2017.
- I. Correia, T. Melo, & F. S. da Gama. Comparing classical performance measures for a multi-period, two-echelon supply chain network design problem with sizing decisions. *Computers & Industrial Engineering*, 64(1) :366–380, 2013.
- T. G. Crainic, B. Gendron, & M. R. A. Kazemzadeh. A taxonomy of multilayer network design and a survey of transportation and telecommunication applications. *European Journal of Operational Research*, 2022.
- Ş. Esnaf & T. Küçükdeniz. A fuzzy clustering-based hybrid method for a multi-facility location problem. *Journal of Intelligent Manufacturing*, 20(2) :259–265, 2009.
- J. Current, S. Ratwick, & C. ReVelle. Dynamic facility location when the total number of facilities is uncertain : A decision analysis approach. *European Journal of Operational Research*, 110(3) :597–609, 1997.
- F. S. da Gama & M. E. Captivo. A heuristic approach for the discrete dynamic location problem. *Location Science*, 6 :211–223, 1998.
- F. D. Davis. Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS quarterly*, pages 319–340, 1989.
- F. D. Davis, R. P. Bagozzi, & P. R. Warshaw. User acceptance of computer technology : A comparison of two theoretical models. *Management science*, 35(8) :982–1003, 1989.
- P. B. de Oliveira, R. S. de Camargo, G. de Miranda Júnior, & A. X. Martins. A computational study of a decomposition approach for the dynamic two-level uncapacitated facility location problem with single and multiple allocation. *Computers & Industrial Engineering*, 151 :106964, 2021.
- J. Dias, M. E. Captivo, & J. Clímaco. Efficient primal-dual heuristic for a dynamic location problem. *Computers & Operations Research*, 34(6) :1800–1823, 2007.
- Z. Dulcic, D. Pavlic, & I. Silic. Evaluating the intended use of decision support system (dss) by applying technology acceptance model (tam) in business organizations in croatia. *Procedia-Social and Behavioral Sciences*, 58 :1565–1575, 2012.

- I. Elbeltagi, N. McBride, & G. Hardaker. Evaluating the factors affecting dss usage by senior managers in local authorities in egypt. *Journal of Global Information Management (JGIM)*, 13(2) :42–65, 2005.
- B. Fahimnia, H. Davarzani, & A. Eshragh. Planning of complex supply chains : A performance comparison of three meta-heuristic algorithms. *Computers & Operations Research*, 89 :241–252, 2018.
- H. Fan, Z. Yang, X. Zhang, S. Wu, J. Long, & L. Liu. A novel multi-satellite and multi-task scheduling method based on task network graph aggregation. *Expert Systems with Applications*, page 117565, 2022.
- P. Farahani, C. Meier, & J. Wilke. Digital supply chain management agenda for the automotive supplier industry. In *Shaping the digital enterprise*, pages 157–172. Springer, 2017.
- R. Z. Farahani, M. Hekmatfar, A. B. Arabani, & E. Nikbakhsh. Hub location problems : A review of models, classification, solution techniques, and applications. *Computers & Industrial Engineering*, 64 :1096–1109, 2013.
- M. Fattahi, M. Mahootchi, K. Govindan, & S. M. M. Husseini. Dynamic supply chain network design with capacity planning and multi-period pricing. *Transportation Research Part E*, 81 :169–202, 2015.
- I. Fragkos, J.-F. Cordeau, & R. Jans. *The multi-period multi-commodity network design problem*. CIRRELT, Centre interuniversitaire de recherche sur les réseaux d’entreprise, 2017.
- I. Fragkos, J.-F. Cordeau, & R. Jans. Decomposition methods for large-scale network expansion problems. *Transportation Research Part B : Methodological*, 144 :60–80, 2021.
- R. L. Francis & T. J. Lowe. On worst-case aggregation analysis for network location problems. *Annals of Operations Research*, 40(1) :229–246, 1992.
- R. L. Francis, T. J. Lowe, M. B. Rayco, & A. Tamir. Aggregation error for location models : survey and analysis. *Annals of Operations Research*, 167(1) :171–208, 2009.
- E. O. Gavrilouk. Aggregation in hub location problems. *Computers & Operations Research*, 36(12) :3136–3142, 2009.
- A. M. Geoffrion. A priori error bounds for procurement commodity aggregation in logistics planning models. *Naval Research Logistics Quarterly*, 24(2) :201–212, 1977.
- A. Ghaderi & M. S. Jabalameli. Modeling the budget-constrained dynamic uncapacitated facility location–network design problem and solving it via two efficient heuristics : A case study of health care. *Mathematical and Computer Modelling*, 57 (3-4) :382–400, 2013.
- M. S. Gönül, D. Önkal, & M. Lawrence. The effects of structural characteristics of explanations on use of a dss. *Decision support systems*, 42(3) :1481–1493, 2006.

- C. W. J. Granger & P. L. Siklos. Systematic sampling, temporal aggregation, seasonal adjustment, and cointegration theory and evidence. *Journal of Econometrics*, 66 (1-2) :357–369, 1995.
- K. R. Gue. A dynamic distribution model for combat logistics. *Computers & Operations Research*, 30 :267–281, 2003.
- A. Gupta & J. Könemann. Approximation algorithms for network design : A survey. *Surveys in Operations Research and Management Science*, 16(1) :3–20, 2011.
- A. Haghani & S.-C. Oh. Formulation and solution of a multi-commodity, multi-modal network flow model for disaster relief operations. *Transportation Research Part A : Policy and Practice*, 30(3) :231–250, 1996.
- Y. Hinojosa, J. Kalcsics, S. Nickel, J. Puerto, & S. Velten. Dynamic supply chain design with inventory. *Computers & Operations Research*, 35(2) :373–391, 2008.
- W. M. Hirsch & G. B. Dantzig. The fixed charge problem. *Naval research logistics quarterly*, 15(3) :413–424, 1968.
- M. Hoffmann, L. Kotzur, & D. Stolten. The pareto-optimal temporal aggregation of energy system models. *Applied Energy*, 315 :119029, 2022.
- F. Holz, C. Karakosta, & A. Neumann. The challenges of spatial and temporal aggregation : Modelling issues, applications, and policy implications, 2020.
- M. W. Horner & M. E. O’Kelly. A combined cluster and interaction model : the hierarchical assignment problem. *Geographical Analysis*, 37(3) :315–335, 2005.
- R. Ishfaq & C. R. Sox. Hub location-allocation in intermodal logistic networks. *European Journal of Operational Research*, 210(2) :213–230, 2011.
- C. J. C. Jabbour, P. D. C. Fiorini, N. O. Ndubisi, M. M. Queiroz, & Éderson Luiz Piatto. Digitally-enabled sustainable supply chains in the 21st century : A review and a research agenda. *Science of the Total Environment*, 725 :138177, 2020.
- A. Jain & U. S. Palekar. Aggregate production planning for a continuous reconfigurable manufacturing process. *Computers & Operations Research*, 32(5) :1213–1236, 2005.
- H. Jang & T. Lee. Demand point aggregation method for covering problems with gradual coverage. *Computers & Operations Research*, 60 :1–13, 2015.
- S. D. Jena, J.-F. Cordeau, & B. Gendron. Solving a dynamic facility location problem with partial closing and reopening. *Computers & Operations Research*, 67 :143–154, 2016.
- D. J.-F. Jeng & G.-H. Tzeng. Social influence on the use of clinical decision support systems : revisiting the unified theory of acceptance and use of technology by the fuzzy dematel technique. *Computers & Industrial Engineering*, 62(3) :819–828, 2012.
- X. Jiang, R. Bai, J. Ren, J. Li, & G. Kendall. Lagrange dual bound computation for stochastic service network design. *European Journal of Operational Research*, 2022.

- M. A. A. Jr., S. N. Kadipasaoglu, & B. M. Khumawala. An empirical comparison of tabu search, simulated annealing, and genetic algorithms for facilities location problems. *International Journal of Production Economics*, 103(2) :742–754, 2006.
- B. Y. Kara & M. R. Taner. Hub location problems : the location of interacting facilities. In *Foundations of location analysis*, pages 273–288. Springer, 2011.
- U. Kayande, A. De Bruyn, G. L. Lilien, A. Rangaswamy, & G. H. Van Bruggen. How incorporating feedback mechanisms in a dss affects dss evaluations. *Information Systems Research*, 20(4) :527–546, 2009.
- A. Kazemi, P. Le Bodic, A. T. Ernst, & M. Krishnamoorthy. New partial aggregations for multicommodity network flow problems : An application to the fixed-charge network design problem. *Computers & Operations Research*, 136 :105505, 2021.
- M. Kchaou-Boujelben. *Modeling and solving a distribution network design problem with multiple operational constraints. Application to a case-study in the automotive industry*. PhD thesis, Ecole Centrale Paris, 2013.
- M. Kchaou-Boujelben, C. Gicquel, & M. Minoux. A MILP model and heuristic approach for facility location under multiple operational constraints. *Computers & Industrial Engineering*, 98 :446–461, 2016.
- P. B. Keenan & P. Jankowski. Spatial decision support systems : Three decades on. *Decision Support Systems*, 116 :64–76, 2019.
- K. Kijmanawat & H. Ieda. Development and application of cm-gats algorithms in solving large multilevel hierarchical network design problems. *Research in Transportation Economics*, 13 :121–142, 2005.
- W. Klibi, A. Martel, & A. Guitouni. The impact of operations anticipations on the quality of stochastic location-allocation models. *Omega*, 62 :19–33, 2016.
- J. G. Klincewicz. Heuristics for the p-hub location problem. *European Journal of Operational Research*, 53(1) :25–37, 1991.
- A. Klose & A. Drexl. Facility location models for distribution system design. *European Journal of Operational Research*, 162(1) :4–29, 2005.
- E. Koca & E. A. Yıldırım. A hierarchical solution approach for a multicommodity distribution problem under a special cost structure. *Computers & Operations Research*, 39(11) :2612–2624, 2012.
- Y.-C. Lai & M.-C. Shih. A stochastic multi-period investment selection model to optimize strategic railway capacity planning. *Journal of Advanced Transportation*, 47(3) :281–296, 2013.
- H.-P. Lu, H.-J. Yu, & S. S. Lu. The effects of cognitive style and model type on dss acceptance : An empirical study. *European Journal of Operational Research*, 131 (3) :649–663, 2001.

- D. Mackrell, D. Kerr, & L. Von Hellens. A qualitative case study of the adoption and use of an agricultural decision support system in the australian cotton industry : The socio-technical view. *Decision Support Systems*, 47(2) :143–153, 2009.
- T. L. Magnanti & R. T. Wong. Network design and transportation planning : Models and algorithms. *Transportation Science*, 18(1) :1–55, 1984.
- M. Marufuzzaman, R. Gedik, & M. S. Roni. A benders based rolling horizon algorithm for a dynamic facility location problem. *Computers & Industrial Engineering*, 98 : 462–469, 2016.
- M. Masaeli, S. A. Alumur, & J. H. Bookbinder. Shipment scheduling in hub location problems. *Transportation Research Part B : Methodological*, 115 :126–142, 2018.
- R. McCormack & G. Coates. A simulation model to enable the optimization of ambulance fleet allocation and base station location for increased patient survival. *European Journal of Operational Research*, 247(1) :294–309, 2015.
- J. Medina, M. Hewitt, F. Lehuédé, & O. Péton. Integrating long-haul and local transportation planning : The service network design and routing problem. *Euro Journal on Transportation and Logistics*, 8(2) :119–145, 2019.
- S. Medina-Gonzalez, I. Gkioulekas, V. Dua, & L. G. Papageorgiou. A graph theory approach for scenario aggregation for stochastic optimisation. *Computers & Chemical Engineering*, 137 :106810, 2020.
- F. Meisel, T. Kirschstein, & C. Bierwirth. Integrated production and intermodal transportation planning in large scale production–distribution-networks. *Transportation Research Part E : Logistics and Transportation Review*, 60 :62–78, 2013.
- M. J. Meixell & V. B. Gargeya. Global supply chain design : A literature review and critique. *Transportation Research Part E*, 41(6) :531–550, 2005.
- E. Melachrinoudis. A multiobjective model for the dynamic location of landfills. *Location Science*, 3(3) :143–166, 1995.
- M. Melo, S. Nickel, & F. S. da Gama. Facility location and supply chain management – a review. *European Journal of Operational Research*, 196(2) :401–412, 2009.
- M. Melo, S. Nickel, & F. S. da Gama. A tabu search heuristic for redesigning a multi-echelon supply chain network over a planning horizon. *International Journal of Production Economics*, 136(1) :218–230, 2012.
- H. Min & G. Zhou. Supply chain modeling : past, present and future. *Computers & Industrial Engineering*, 43(1-2) :231–249, 2002.
- M. Minoux. Network synthesis and dynamic network optimization. In *North-Holland Mathematics Studies*, volume 132, pages 283–323. Elsevier, 1987.
- M. Minoux. Networks synthesis and optimum network design problems : Models, solution methods and applications. *Networks*, 19(3) :313–360, 1989.

- R. N. Monemi, S. Gelareh, A. Nagih, N. Maculan, & K. Danach. Multi-period hub location problem with serial demands : A case study of humanitarian aids distribution in lebanon. *Transportation Research Part E*, 149 :102201, 2021.
- E. T. Morgan & R. R. Razouk. Interactive state-space analysis of concurrent systems. *IEEE Transactions on Software Engineering*, (10) :1080–1091, 1987.
- N. Mrabti, N. Hamani, Y. Boulaksil, M. A. Gargouri, & L. Delahoche. A multi-objective optimization model for the problems of sustainable collaborative hub location and cost sharing. *Transportation Research Part E : Logistics and Transportation Review*, 164 :102821, 2022.
- J. M. Mulvey & H. Vladimirou. Solving multistage stochastic networks : An application of scenario aggregation. *Networks*, 21(6) :619–643, 1991.
- T. Nishi, S. Akiyama, T. Higashi, & K. Kumagai. Cell-based local search heuristics for guide path design of automated guided vehicle systems with dynamic multicommodity flow. *IEEE Transactions on Automation Science and Engineering*, 17(2) :966–980, 2019.
- L. K. Nozick & M. A. Turnquist. Integrating inventory impacts into a fixed-charge model for location distribution centers. *Transportation Research Part E*, 34(3) :173–186, 1998.
- C. Ortiz-Astorquiza, I. Contreras, & G. Laporte. Multi-level facility location problems. *European Journal of Operational Research*, 267(3) :791–805, 2018.
- S. H. Owen & M. S. Daskin. Strategic facility location : A review. *European Journal of Operational Research*, 111 :423–447, 1998.
- R. H. Pearce & M. Forbes. Disaggregated benders decomposition and branch-and-cut for solving the budget-constrained dynamic uncapacitated facility location and network design problem. *European Journal of Operational Research*, 270(1) :78–88, 2018.
- D. J. Power & R. Sharda. Model-driven decision support systems : Concepts and research directions. *Decision Support Systems*, 43(3) :1044–1061, 2007.
- L. Qi & Z.-J. M. Shen. Worst-case analysis of demand point aggregation for the euclidean p-median problem. *European Journal of Operational Research*, 202(2) :434–443, 2010.
- J. Reich, A. Kinra, & H. Kotzab. Strategic decision-making in global supply chain network design—how a decision support system combining milp and ahp on a pareto front can alleviate decision-making. *IFAC-PapersOnLine*, 52(13) :2285–2290, 2019.
- K. Renaud & J. Van Biljon. Predicting technology acceptance and adoption by the elderly : a qualitative study. In *Proceedings of the 2008 annual research conference of the South African Institute of Computer Scientists and Information Technologists on IT research in developing countries : riding the wave of technology*, pages 210–219, 2008.

- D. F. Rogers, R. D. Plante, R. T. Wong, & J. R. Evans. Aggregation and disaggregation techniques and methodology in optimization. *Operations Research*, 39(4) :553–582, 1991.
- G. Rushton. Applications of location models. *Annals of Operations Research*, 18(1) : 25–42, 1989.
- F. Saldanha-da Gama. Facility location in logistics and transportation : An enduring relationship. *Transportation Research Part E : Logistics and Transportation Review*, 166 :102903, 2022.
- C. Sauvey, T. Melo, & I. Correia. Heuristics for a multi-period facility location problem with delayed demand satisfaction. *Computers & Industrial Engineering*, 139 :106171, 2020.
- Y. O. Scherr, M. Hewitt, B. A. N. Saavedra, & D. C. Mattfeld. Dynamic discretization discovery for the service network design problem with mixed autonomous fleets. *Transportation Research Part B : Methodological*, 141 :164–195, 2020.
- G. Shashin. *Hub location models in public transport planning*. PhD thesis, Technical University of Kaiserslautern, Germany, 2008.
- J. B. Sheu & A. Y. Lin. Hierarchical facility network planning model for global logistics network configurations. *Applied Mathematical Modelling*, 36(7) :3053–3066, 2012.
- R. Shibli, M. Lawley, & J. Debuse. Factors influencing decision support system acceptance. *Decision Support Systems*, 54(2) :953–961, 2013.
- A. Silva, D. Aloise, L. C. Coelho, & C. Rocha. Heuristics for the dynamic facility location problem with modular capacities. *European Journal of Operational Research*, 290(2) :435–452, 2021.
- R. Suárez-Vega, D. R. Santos-Peña, P. Dorta-González, & M. Rodríguez-Díaz. A multi-criteria GIS based procedure to solve a network competitive location problem. *Applied Geography*, 31(1) :282–291, 2011.
- X. Tang, F. Lehuédé, & O. Péton. Location of distribution centers in a multi-period collaborative distribution network. *Electronic Notes in Discrete Mathematics*, 52 : 293–300, 2016.
- S. Taylor & P. Todd. Decomposition and crossover effects in the theory of planned behavior : A study of consumer adoption intentions. *International Journal of Research in Marketing*, 12(2) :137–155, 1995.
- N. Teypaz, S. Schrenk, & V.-D. Cung. A decomposition scheme for large-scale service network design with asset management. *Transportation Research Part E : Logistics and Transportation Review*, 46(1) :156–170, 2010.
- P. N. Thanh, N. Bostel, & O. Péton. A DC programming heuristic applied to the logistics network design problem. *International Journal of Production Economics*, 135(1) :94–105, 2012.

- J. Váncza, T. Kis, & A. Kovács. Aggregation-the key to integrating production planning and scheduling. *CIRP Annals*, 53(1) :377–380, 2004.
- F. M. Vanek. Analysis of the potential for spatial redistribution of freight using mathematical programming. *European Journal of Operational Research*, 131(1) :62–77, 2001.
- V. Venkatesh & F. D. Davis. A theoretical extension of the technology acceptance model : Four longitudinal field studies. *Management Science*, 46(2) :186–204, 2000.
- V. Venkatesh, M. G. Morris, G. B. Davis, & F. D. Davis. User acceptance of information technology : Toward a unified view. *MIS quarterly*, pages 425–478, 2003.
- X. Wang & S. W. Wallace. Stochastic scheduled service network design in the presence of a spot market for excess capacity. *EURO Journal on Transportation and Logistics*, 5(4) :393–413, 2016.
- X. Wang, T. G. Crainic, & S. W. Wallace. Stochastic network design for planning scheduled transportation services : The value of deterministic solutions. *INFORMS Journal on Computing*, 31(1) :153–170, 2019.
- Z. Wang & M. Qi. Service network design considering multiple types of services. *Transportation Research Part E : Logistics and Transportation Review*, 126 :1–14, 2019.
- T. Wu, H. Shen, & C. Zhu. A multi-period location model with transportation economies-of-scale and perishable inventory. *International Journal of Production Economics*, 169 :343–349, 2015.
- X. Xiang, T. Fang, C. Liu, & Z. Pei. Robust service network design problem under uncertain demand. *Computers & Industrial Engineering*, 172 :108615, 2022.
- A. Ziliaskopoulos & W. Wardell. An intermodal optimum path algorithm for multimodal networks with dynamic arc travel times and switching delays. *European Journal of Operational Research*, 125(3) :486–502, 2000.
- P. Zipkin. Transportation problems with aggregated destinations when demands are uncertain. *Naval Research Logistics Quarterly*, 29(2) :257–270, 1982.

# **Étude de l'agrégation de données sur la conception d'un réseau logistique : cas de la distribution d'un constructeur automobile**

**Suzanne Le Bihan**

## **Résumé**

La conception d'un réseau logistique consiste à déterminer l'ouverture au sein d'un réseau de centres et de routes, qui permettront de transporter des produits vers des clients le tout en minimisant des coûts. Au niveau tactique, la conception est régulièrement enrichie par la planification du transport de produits, ainsi que le dimensionnement de flux et de stocks. Pour concevoir ce réseau, il est possible de le modéliser sous la forme d'un problème d'optimisation mathématique. La modélisation du problème doit inclure un niveau de détail suffisant afin de proposer des solutions pertinentes d'un point de vue industriel. Cependant, la difficulté de résolution de ces modèles et la taille des instances industrielles, poussent les concepteurs à le simplifier.

Dans ce contexte, nous proposons un modèle de conception de réseaux logistiques pour la distribution tactique de véhicules d'un constructeur automobile et analysons certaines particularités de ce problème. Ce modèle permet de réaliser une étude quantitative d'un problème industriel avec des données réelles.

Ensuite, nous proposons une méthodologie pour analyser l'impact de l'agrégation des données d'entrées sur les résultats d'un modèle et nous l'appliquons à notre cas d'étude. Le choix judicieux du niveau d'agrégation d'un modèle pour le design de réseaux permet de réaliser des économies de ressources de calculs, d'effort de développement de méthode de résolutions plus performantes et de récupération de données. Cependant, trouver un équilibre entre la réduction de la taille du modèle et la précision des résultats n'est pas trivial. Nous étudions l'impact de différents niveaux et dimensions d'agrégations sur le comportement du modèle en terme de performance et forme des solutions.

Enfin, les utilisateurs de modèles ont tendance à mieux comprendre et donc accepter une modélisation dont le niveau de détail correspond aux décisions concernées. Dans ce sens, un indicateur important est la précision de l'estimation du coût des solutions. Nous étudions donc l'impact des agrégations de données d'entrées sur la qualité d'estimation du coût des solutions. Nous proposons une méthode de réajustement de l'estimation du coût des solutions dans l'optique de favoriser l'acceptation de l'outil d'aide à la décision.

## **Mots-clés**

Logistique, conception de réseaux, industrie automobile, agrégation de données

# **Analysis of data aggregation for the design of a supply chain network : the case of the distribution of an automotive manufacturer**

**Suzanne Le Bihan**

## **Abstract**

Designing a supply chain network involves determining the opening of centers and routes within a network, which allows transporting products to customers while minimizing costs. At a tactical level, the design is supplemented by the transportation planning of the products, as well as the dimensioning of stock capacities. Modeling the mathematical optimization problem can help design such a network. The model must include a sufficient level of detail in order to propose industrially relevant solutions. However, the difficulty of solving these models and the industrial-sized instances encourage the designers to simplify the model.

In this context, we propose a model formulation of a supply chain network design problem for an automotive manufacturer's tactical distribution of vehicles and analyze some particularities of this problem. The model allows us to perform a quantitative study of an industrial problem with real data.

Then, we propose a methodology to analyze the impact of input data aggregation on the model's results and apply it to our case study. A sensible choice of the input aggregation level allows for saving computational resources. Besides, it can reduce the effort of developing more efficient resolution methods and recovering data. However, finding a balance between the size reduction of the model and the results' accuracy is not trivial. We study the impact of different levels and dimensions of aggregation on the model's behavior in terms of performance and solution characteristics.

Finally, model users tend to understand better and thus more readily accept a model whose level of detail corresponds to the decision level concerned. In fact, an important metric to gain users' trust is the accuracy of the cost estimate of the solutions. Therefore, we study the impact of input data aggregations on the quality of solution cost estimation. We propose a method to readjust the cost estimate of the solutions obtained with input aggregation in order to promote the acceptance of the decision support tool.

## **Keywords**

Supply chain, network design, automotive industry, data aggregation