

خوارزمية ضبط حزمة جديدة بالاعتماد على أمثلة أسراب الجسيمات متعددة الأهداف الهجينة

م. ماهر النديوي⁽¹⁾

د. م. محمد مازن محاييري⁽²⁾

د. م. رائوف حمدان⁽³⁾

المخلص

تطورت عملية بناء البنى ثلاثية الأبعاد خلال العقدین الأخيرین، وسواء كانت على النطاقات الصغيرة أو المتوسطة أو الكبيرة، فإن عملية ضبط الحزمة (Bundle Adjustment) تلعب دوراً مهماً في هذه العملية، خاصة في البنية من الحركة (SfM) ، والتموضع ووضع الخرائط المتوافقة (SLAM). على الرغم من أن ضبط الحزمة تعمل على تحسين معاملات الكاميرا والنقاط ثلاثية الأبعاد كخطوة نهائية مهمة جداً، فإنها تعاني من متطلبات الذاكرة والكفاءة في إعادة البناء ضمن النطاقات الواسعة جداً. يستخدم التحسين متعدد الأهداف (MOO) في مجالات شتى لحل مختلف مشاكل الحياة الواقعية الهندسية. تعد خوارزمية MOPSO من أهم الخوارزميات التطورية المستخدمة في الأمثلة متعددة الأهداف، تعتمد خوارزمية MOPSO بشكل أساسي على قياس مسافة الحشد (crowding distance) للمفاضلة بين الحلول حيث أنها تساعد في قياس توزيع الحلول على كامل فضاء البحث مما يساعد في زيادة قدرة الخوارزمية على الاستكشاف (exploration) ، لكنها لا تسمح للخوارزمية بالاستكشاف بشكل كافي كونها لا تأخذ اتجاه الاستكشاف بعين الاعتبار. وكذلك فإن MOPSO تبدأ بحثها بشكل عشوائي دون أخذ أي معرفة مسبقة عن فضاء البحث وهو ما يعد غير عملي في بعض التطبيقات التي نستطيع فيها تخمين قيم ابتدائية للحلول مثل ضبط الحزمة. في هذا البحث، تم تقديم خوارزمية جديدة لضبط الحزمة تعتمد على خوارزمية MOPSO هجينة، حيث أنها تستثمر التقنيات المستخدمة في خوارزميات التحسين التقليدية مثل RADAM وتقنيات تخمين الخطأ الأصغر (LSE) الأخرى لتحسين حركة حلول MOPSO، وأظهرت النتائج أن الخوارزمية المقترحة يمكن أن تساعد في تحسين الدقة بالإضافة للكفاءة في كل من الذاكرة والوقت لعملية ضبط الحزمة.

الكلمات المفتاحية: الأمثلة متعددة الأهداف، خوارزمية أمثلة سرب الجسيمات هجينة، ضبط الحزمة.

(1) مهندس في قسم هندسة الحواسيب والأتمتة في كلية الهندسة الميكانيكية والكهربائية، جامعة دمشق.

(2) استاذ مساعد في قسم هندسة الحواسيب والأتمتة في كلية الهندسة الميكانيكية والكهربائية، جامعة دمشق.

(3) مدرس في قسم هندسة الحواسيب والأتمتة في كلية الهندسة الميكانيكية والكهربائية، جامعة دمشق.

A Novel Bundle Adjustment Algorithm Based on Hybrid Multi-Objective Particles Swarm Optimization

Eng.Maher Alndiwee⁽¹⁾

Dr.Eng. Mohmad Mazen Almhairi⁽²⁾

Dr.Eng.Raouf Hamdan⁽³⁾

Abstract

3D reconstruction has been developing during the last two decades, from moderate to medium and to large scale. It's well known that bundle adjustment plays an important role in 3D reconstruction, mainly in Structure from Motion (SfM) and Simultaneously Localization and Mapping(SLAM). While bundle adjustment optimizes camera parameters and 3D points as a non-negligible final step, it suffers from memory and efficiency requirements in very large-scale reconstruction. Multi-objective optimization (MOO) is widely used for solving various engineering real-life problems. MOPSO is regarded as one of the states of the art for meta-heuristic MOO. MOPSO has adopted the concept of crowding distance as a measure that can leverage the characteristics of the distribution of solutions in the search space and provide a high level of exploration. However, this method is not sufficient to effectively explore the search space because it ignores the direction of the exploration. In addition, MOPSO starts the search from a fully randomly initialized swarm without taking any prior knowledge about the searching space into account which is considered impractical in applications where we can estimate initial values for solutions like bundle adjustment. In this paper, we introduced a novel bundle adjustment algorithm based on hybrid MOPSO that takes advantage of the traditional optimization algorithms like ADAM and other LSE solvers to improve the mobility of MOPSO solutions, the results showed that our algorithm can help to improve the accuracy and the efficiency in both memory and time of BA.

Key words: Hybrid, Guess Aided, Multi-Objective Particles Swarm Optimization ,(HGAMOPSO), Bundle Adjustment.

⁽¹⁾Engineer Mechanical & Electrical Faculty Damascus University

⁽²⁾Associate Professor Mechanical & Electrical Faculty Damascus University

⁽³⁾Lecturer Mechanical & Electrical Faculty Damascus University

مراكز الكاميرات التي يتم ضبطها بالنسبة لكل من النقاط المميزة ومواضع الكاميرات كما يوضح الشكل (1). [4]

يمكن صياغة مسألة ضبط الحزمة رياضياً على أنها عملية تصغير لخطأ إعادة الإسقاط المعطى بالمعادلة التالية:

$$\min(e) = \min \sum_{i=1}^n \sum_{j=1}^m (u'_{ij} - \pi(C_j, X_i))^2 \quad (1)$$

حيث:

X_i : هي الاحداثيات في الفضاء ثلاثي الأبعاد للنقطة i .
 C_j : هو موضع الكاميرا j .
 π : هي عملية إسقاط النقاط إلى مستوي الكاميرا.
 u'_{ij} : قيمة البيكسل المقابل للنقطة i ضمن صورة الكاميرا j .

للتبسيط سنرمز لخطأ الإسقاط ب r


$$r = (u'_{ij} - \pi(C_j, X_i)) \quad (2)$$

بالتعويض في (1) فإن عملية ضبط الحزمة سنكتب كما يلي:

$$\min r^T r \quad (3)$$

وبتطبيق منشور تايلور من الدرجة الأولى نحصل على:

$$r(x + \delta x) = r(x) + g^T \delta x + \frac{1}{2} \delta x^T H \delta x \quad (4)$$



الشكل (1) توضيح مفهوم ضبط الحزمة [3]

حيث g هي المشتق الأول ل r او ما يسمى بالترج و H هو المشتق الثاني (hessian). بأخذ المشتق للمعادلة (4) وجعله يساوي الصفر نحصل على:

$$H \delta x = -g \quad (5)$$

وبالتعويض من خلال مصفوفة اليعقوبي J حيث: $H = J^T J + S, g = J^T r$ ويمكن اهمال S عندما تكون صغيرة بما يكفي فنحصل على معادلة غوص

1. المقدمة:

تلعب عملية ضبط الحزمة دوراً هاماً في علم الهندسة متعددة المشاهد (multi-view geometry) وبناء النماذج ثلاثية الأبعاد خاصة في البنية من الحركة (SfM)، والتموضع ووضع الخرائط المتوافقة (SLAM)، والتي بدورها تستخدم في طيف واسع من التطبيقات الهندسية في شتى المجالات العملية. [1] حيث يتم استدعاء ضبط الحزمة عادةً كمرحلة صقل نهائية لتقليل خطأ التخمين لموضع الكاميرا والنقاط ثلاثية الأبعاد، وتعد أيضاً وسيلة لإزالة الانحراف في عمليات إعادة بناء البنى التراكمية. [2]

تم اقتراح عدد من الطرائق لضبط الحزمة خلال العقدين الماضيين، وما زالت الأبحاث تسعى لتحسين طريقة ضبط. [3]

سوف نستعرض ضمن هذا المقال مفهوم ضبط الحزمة والأسس الرياضية للمسألة في المقطع الثاني، وسنستعرض مجموعة من الأعمال السابقة في المقطع الثالث، وأما في المقطع الرابع فسننتقل لتفاصيل الخوارزمية الهجينة المقترحة وكيفية استخدامها في ضبط الحزمة، وسنبين ضمن المقطع الخامس نتائج أداء الخوارزمية المقترحة مقارنة مع ضبط الحزمة المعتمد على تقنيات الأمثلة التكرارية.

فيما يلي جدول بأهم الاختصارات والمصطلحات المستخدمة في البحث ومقابلاتها باللغة العربية:

المصطلح	المعنى
BA	ضبط الحزمة
PSO	خوارزمية أمثلة سرب الجسيمات
MOO	الأمثلة متعددة الأهداف
SfM	استنتاج البنية من الحركة
SLAM	التموضع ووضع الخرائط المتوافقة
pareto front	جبهة باريتو (الحلول الأمثل)

2. ضبط الحزمة (Bundle adjustment):

يشير ضبط الحزمة كمصطلح إلى حزمة اشعة الضوء القادمة من النقاط المميزة في الصورة باتجاه

سبيل المثال ليكن لدينا n صورة و m نقطة ثلاثية الأبعاد سيكون التعقيد من أجل خوارزمية (Levenberg-Marquardt) بنسختها التقليدية المستخدمة لضبط الحزمة من رتبة $O((m+n)^3)$ عملية حسابية من أجل كل دورة أمثلة، واستخدام ذاكرة من رتبة $O((m+n)m.n)$ وبالتالي فإن كلفتها الحسابية مرتفعة جداً.

أوجدت العديد من الطرائق التي تسعى إلى تقليص هذه الكلفة ومنها طريقة مكمّل شور (Schur complement) التي تساعد في تقليل العمليات الحسابية لرتبة $O(m^3+m.n)$ لكل دورة أمثلة و استخدام ذاكرة من رتبة $O(m.n)$ ، ويمكن التقليل أكثر بالاعتماد على البنى الثانوية المتفرقة (secondary sparse structure) كما في [8] . وبالرغم من إمكانية تقليل التعقيد إلا أن الطرائق التكرارية تعاني غالباً من الوقوع في القيم الصغرى محلياً وخاصة عندما تكون التخمينات الأولية بعيدة عن الحل الأمثل وهو ما ينعكس سلباً على دقة عملية ضبط الحزمة باستخدامها. [9]

قام الباحثون في [10] باستخدام طريقة التدرج المترافق (conjugate gradients) من أجل حل مسألة تخمين المربعات الصغرى بدون استخدام تقنية التقليل المعتمدة على مكمّل شور (Schur complement). وكذلك قاموا باستخدام تقنية تحليل (QR- decomposition) لتحليل مصفوفة البعقوبي وذلك من دون تهميش النقاط العلامة (landmarks) . في حين قام Agarwal وآخرون بتقديم طريقة التدرج المترافق المعتمدة على مكمّل شور [6]. وكذلك قام العديد من الباحثين بالاعتماد على مكمّل شور وتطويراته من أجل رفع الكفاءة والدقة لعملية ضبط الحزمة [7]. ومؤخراً قدم الباحثون في [11] طريقة تعتمد على تحليل نظام الكاميرا المقلص (reduced camera system) وتضمنه ضمن طريقة (Levenberg-Marquardt). في حين أن

نيوتن التي تجعل المسألة عبارة عن مسألة تخمين المربعات الصغرى (LSE):

$$J^T J \delta x = -J^T r \quad (6)$$

ولكن تعاني طريقة غاوص نيوتن من عدم القدرة على الوصول لحل عندما تكون المصفوفة $J^T J$ شاذة (singular) ولتجنب ذلك يمكن استخدام صيغة ليفينبيرغ (Levenberg-Marquardt) كما يلي:

$$(J^T J + \lambda I) \delta x = -J^T r \quad (7)$$

ويحل مسألة التخمين وفق تابع الكلفة الموضح بالمعادلة (7) نحصل على حل لمسألة ضبط الحزمة [3].

ولكن كما أوضحنا سابقاً أن الطرائق التكرارية بشكل عام تعاني من مشكلة الوقوع في القيم الصغرى محلياً، وبالتالي يجب أن تكون التخمينات الأولية دقيقة إلى حد ما لتجنب تلك المشكلة ولكن لا توجد طريقة لضمان صحة تلك التخمينات وبالتالي ممكن إيجاد طرائق أنسب لحل مسألة ضبط الحزمة وهو ما سوف نوضحه في القسم الرابع من هذا المقال.

3. الأعمال السابقة:

تم اقتراح عدد من الطرائق لضبط الحزمة خلال العقدين الماضيين، وما زالت الأبحاث تسعى لتحسين طريقة ضبط الحزمة وتقسّم هذه الأبحاث إلى محورين أساسيين:

المحور الأول يركز على جعل ضبط الحزمة أكثر دقة وفعالية من خلال تقليل الخطأ.

في حين أن المحور الثاني يركز على تقليل حجم وتكرار ضبط الحزمة بحيث يجعلها أقل كلفة حسابية وأسرع. [3]

ولقد باتت العديد من برمجيات ضبط الحزمة مفتوحة المصدر ومتاحة للاستخدام بسهولة مثل [5][6][7] وغيرها، ومع ذلك لا تزال عملية ضبط الحزمة تمثل عنق الزجاجة في تطبيقات البنية من الحركة ضمن النطاقات الواسعة بسبب تخزين المصفوفات الضخمة والعمليات المتعددة عليها فعلى

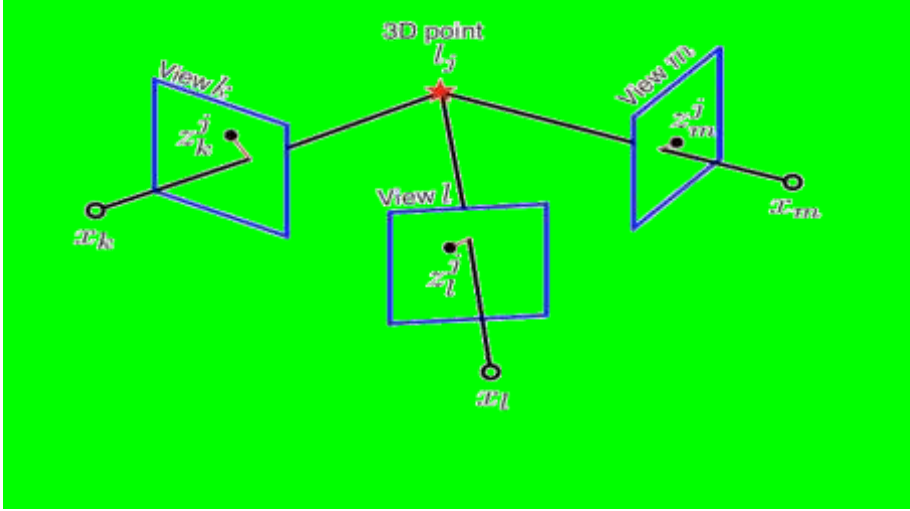
4. الخوارزمية المقترحة:

سوف نستعرض في هذا القسم تفاصيل الخوارزمية المقترحة وأسباب اختيار كل جزء منها باختصار تجنباً للإطالة .

1-4. ضبط الحزمة دون الاعتماد على البنية (Structure less bundle adjustment):

أول تحدي يواجه المطورين في أي مسألة أمثلة يكون عادة صياغة المسألة بالطريقة الأنسب، وكما بينا في المقطع الثاني من هذا المقال فإن تمثيل مسألة ضبط الحزمة يتطلب أمثلة متغيرات الكاميرا والنقاط المميزة وبالتالي فإن حجم متغير البحث سوف يكون من أجل n كاميرا و m صورة $6n + 3m$ وفي حال العمل على نطاق واسع سيكون لدينا آلاف النقاط أن لم يكن عشرات الآلاف ومئات المواضيع للكاميرا وبالتالي فإن استخدام هذه الصياغة للمسألة سيكون له كلفة حسابية عالية جداً لذلك تم البحث عن تمثيل بديل وهو ما وجدناه لدى الباحثين في [14] حيث أنهم اثبتوا جبرياً إمكانية الاستغناء عن نقاط البنية من خلال استخدام القيود ثلاثية المشاهد (three-view constraints) الموضحة بالشكل (2) والمعادلات (8-9-10) :

Demmel وأخرون [12] قاموا باستخدام تهميش الفضاء الصفري وتحليل المصفوفات اعتماداً على (QR decomposition). واتجه قسم آخر من الباحثين باتجاه ادخال تقنيات الذكاء الاصطناعي في حل مسألة ضبط الحزمة حيث قام الباحثون في [9] باستخدام الخوارزمية الجينية لإيجاد التوضع الصحيح للصور البانورامية المأخوذة جواً، حيث أن الخوارزمية الجينية تكون مسؤولة عن تخمين زوايا الدوران فقط كون ارتفاع الكاميرا يكون ثابت . في حين قام الباحثون في [13] باستخدام خوارزمية أمثلة سرب الجسيمات (PSO) من أجل معايرة الكاميرا وقد ساعد استخدام هذه الخوارزمية في تقليل الحاجة لنقاط تحكم من أجل المعايرة وهو ما يجعل تلك العملية أكثر كفاءة. ولكن وبحسب اطلاعنا من خلال الدراسات المرجعية لا يوجد حتى الآن طريقة اعتمدت على خوارزميات أمثلة متعددة الأهداف هجينة ومعظم الابحاث التي استخدمت خوارزميات الأمثلة سابقاً لم تكن موجهة لتطبيقات ضبط الحزمة عموماً، إنما لتطبيقات محددة كما رأينا في [9] و [13]. وبالتالي سيقدم هذا البحث خوارزمية أمثلة متعددة الأهداف هجينة من أجل ضبط الحزمة بشكل عام وهو ما سيمهد الطريق من أجل استخدام مثل هذه الخوارزميات في التطبيقات الهندسية المشابهة.



الشكل (2) توضيح للقيود ثلاثية المشاهد [14]

إن الخوارزمية الهجينة المقترحة في هذا البحث عبارة عن تطوير لخوارزمية أمثلة سرب الجسيمات متعددة الأهداف بالاعتماد على التخمينات الأولية وزاوية الازدحام (Guess Aided Multi Objective Particles Swarm Optimization) التي تم تقديمها في بحث سابق حيث تم إضافة مجموعة من التعديلات لتصبح قادرة على التعامل مع ضبط الحزمة وفيما يلي سنقوم بشرحها مع التعديلات التي طرأت عليها:

4-2-1- خوارزمية HGAMOPSO

يبين شبه الترميز (pseudo code) في الشكل

(3) الخطوات الأساسية لخوارزمية

Hybrid Guess Aided) HGAMOPSO Multi Objective Particles Swarm

Optimization حيث أن الخوارزمية تبدأ بعملية

تهيئة السرب الأولي بالاعتماد على التخمينات الأولية

وبنسبة مئوية من السرب تحدد بالمعامل

InitPercent، حيث أن هذه النسبة المئوية من

الجسيمات الأولية تُنشأ وفقاً لتوزيع غوسي في محيط

التخمين الأولي المعطى. بعد ذلك تبدأ عملية تحديد

الحلول المسيطرة بواسطة العملية **(Determine**

Domination)، حيث يعتبر الحل A مسيطراً على

الحل B في حال كانت قيم كل توابع الهدف ل A

$$g_{2v}(x_k, x_l, z'_k, z'_l) = q_k \cdot (t_{k \rightarrow l} \times q_l) \quad (8)$$

$$g_{2v}(x_l, x_m, z'_l, z'_m) = q_l \cdot (t_{l \rightarrow m} \times q_m) \quad (9)$$

$$g_{3v}(x_k, x_l, x_m, z'_k, z'_l, z'_m) = (q_l \times q_k) \cdot (q_m \times t_{l \rightarrow m}) - (q_k \times t_{k \rightarrow l}) \cdot (q_m \times q_l) \quad (10)$$

$$q_i = R_i^T K_i^{-1} p_i \quad (11)$$

حيث :

g_{2v} : قيد ثنائي المشاهد يربط بين مشهدين

g_{3v} : قيد ثلاثي المشاهد يربط بين ثلاثة

مشاهد.

$t_{k \rightarrow l}$: شعاع الانتقال الخطي من الإطار k إلى

الإطار l.

R_i : مصفوفة الدوران للكاميرا i.

K_i : مصفوفة البارامترات الداخلية للكاميرا i.

P_i : مواضع البيكسلات المقابلة للنقاط المميزة في

الكاميرا i.

يمكن ملاحظة أن هذا التمثيل يساعد بشكل كبير

في تخفيض حجم المتغيرات المراد أمثلتها فقد

اصبحت متغيرات الكاميرا فقط بدل من متغيرات

الكاميرا والنقاط المميزة، وبالتالي سيخفف هذا التمثيل

من العبء الحسابي ومن استهلاك الذاكرة بشكل

كبير.

4-2. خوارزمية أمثلة سرب الجزيئات

متعددة الأهداف الهجينة :

- تحريك الجسيم p وفق المعادلة :

$$x_{ij}(t + 1) = x_{ij}(t) + v_{ij}$$
- تطبيق الطفرة على الجسيم إذا كان ضمن النسبة **mutationPercent** وينتج عن ذلك جسيم جديد p'
- في حال كان p' أفضل من p وضع p' بدل من p ضمن السرب الجديد
- 3- دمج السرب القديم والجديد ضمن **Swarm**
- 4- حساب الترتيب **Ranks** وفقاً لعدد الحلول المسيطرة على كل حل ضمن **Swarm**
- 5- حساب مسافة الازدحام للحلول
- 6- حساب زاوية الازدحام للحلول
- 7- استخراج حلول جديدة بعدد يساوي **numberOfParticles** من الحلول الحالية المرتبة وفقاً لل **Rank** ومسافة وزاوية الازدحام من أجل استخدامها كسرب حالي للدورة القادمة.
- ايجاد جبهة الباريتو (pareto front) أو بمعنى آخر الحلول الأفضل من السرب الحالي.

أفضل أو تساوي قيم التتابع الهدف ل B وتوجد على الأقل قيمة واحدة لتتابع الهدف ل A هي أفضل من القيمة المقابلة لتتابع الهدف للحل B . وبهذا الشكل تكون قد انتهت عملية التهيئة للسرب الأولي وتبدأ بعد ذلك الدورة التكرارية للخوارزمية.

خلال كل دورة من دورات الخوارزمية تتم العمليات التالية:

- 1- ننشئ نسخة من السرب الحالي ونسميه **newSwarm** لكي يتم التعديل عليه في الخطوات اللاحقة.

2- من أجل كل جسيم p ضمن السرب الجديد نقوم بالخطوات التالية:

- نختار قائد للجسيم وفق الآلية الهجينة التي سيتم شرحها لاحقاً.

- نحسب السرعة وفق المعادلة :

$$v_{ij} = wv_{ij} + c_1r(p_{ij} - x_{ij}) + c_2r(p_{nj} - x_{ij})$$

حيث c_1 و c_2 هما معامل المعرفة والمعامل الاجتماعي و w هو عزم عطالة الجسيم.

Algorithm 1 HGAMOPSO

Input:

- (1) Guess : the initial guess.
- (2) InitPercent : the initial solutions percent.
- (3) maxIterations : maximum number of iterations.
- (4) numberOfParticles : the number of particles at the swarm.
- (5) mutationPercent : the mutation percentage.

Output:

- (1) ParetoFront : the optimal solution found by the algorithm.

```

1: start algorithm
2: Swarm = GenerateInitialSwarm(Guess, InitPercent)
3: Swarm = DetermineDomination(Swarm)
4: for itr=1:maxIterations do
5:   newSwarm = Swarm
6:   for i=1:numberOfParticles do
7:     p = newSwarm(i)
8:     pL = SelectLeader(p)
9:     V = computeVelocity(p, pL)
10:    p = moveParticle(p, V)
11:    if rand < mutationPercent then
12:      p' = mutate(p)
13:      if Dominates(p', p) then
14:        newSwarm(i) = p'
15:      else if Dominates(p, p') then
16:        newSwarm(i) = p
17:      else if rand > 0.5 then
18:        newSwarm(i) = p'
19:      end if
20:    end if
21:  end for
22:  Swarm = [Swarm newSwarm]
23:  Ranks = FindRankedParetoFronts(Swarm)
24:  Distances = CalculateCrowdingDistance(Swarm)
25:  Angles = CalculateCrowdingAngles(Swarm)
26:  Swarm = ExtractNextPopulation(Swarm, Ranks, Distances, Angles)
27:  ParetoFront = FindPareto(Swarm)
28: end for
29: end algorithm

```

الشكل (3) شبه الترميز خوارزمية

من توليد العدد المطلوب من الجسيمات حول التخمين يتم توليد باقي الجسيمات بشكل عشوائي على كامل المجال. يتم اختبار كل جسيم من الجسيمات في حال تجاوز حدود مجال البحث ويتم تصحيح القيم وجعلها ضمن مجال البحث، وبعد ذلك يتم احتساب قيم تابع الهدف للجسيم وتخزينها ضمن خانة Cost ليتم الاستفادة منها لاحقاً عند تقييم الحلول.


4-2-2- التهيئة المعتمدة على التخمين الأولي:

يبين شبه الترميز في الشكل (4) عملية التهيئة المعتمدة على التخمين الأولي حيث يتم في البداية احتساب عدد الجسيمات المكافئ للنسبة المطلوبة، ويتم توليد تلك الجسيمات حول التخمين الأولي ضمن مجال يحدد توزيع غوسي عشوائي، وبعد الانتهاء



```

Algorithm 2 Guess Aided Initialization
Input:
(1)numberOfSolutions : the number of solutions.
(2)InitPercent : the initial solutions percent.
Output:
(1)Swarm : the initialized swarm.
1: start algorithm
2: IGParticlesNum ← round(numberOfSolutions * InitPercent)
3: for i=1:numberOfSolutions do
4:   if i <= IGParticlesNum then
5:     Swarm(i).position = InitGuess + GaussianRand
6:   else
7:     Swarm(i).position = LowerBound + Rand*[UpperBound - LowerBound]
8:   end if
9:   Swarm(i).position = CheckBounds(Swarm(i).position)
10:  Swarm(i).Cost = objectiveFunction(Swarm(i).position)
11: end for
12: end algorithm
    
```

الشكل (4) شبه الترميز لعملية التهيئة المعتمدة على التخمين الأولي



الشكل (5) مفهوم زاوية الازدحام



الشكل (6) تعميم مفهوم زاوية الازدحام من أجل ثلاثة توابع هدف

التي تحوي عدد قليل من الحلول كي لا تبقى الحلول متركزة في قطاعات دون الأخرى.

ضمن هذا البحث تم تطوير مفهوم زاوية الازدحام بحيث أصبح قادر على التعامل مع أكثر من تابعي هدف، وذلك من خلال إسقاط قيمة التوابع الهدف على مستوي محدد بتابعي هدف في كل مرة بحيث تتولد زاوية ازدحام مستقلة بين كل محورين من محاور توابع الهدف كما يوضح الشكل (6) ، a_{12} هي الزاوية بعد إسقاط قيمة توابع الهدف على المحور المستوي المحدد بتابعي الهدف F_1 و F_2 وكذلك الأمر بالنسبة ل a_{13} و a_{23} . وتم اعتماد طريقة احتمالية لاختيار إحدى تلك الزوايا لتقييم توزع الحلول بالاعتماد عليها في كل مرة.

3-2-4 زاوية الازدحام **crowding** angle:

إن مفهوم زاوية الازدحام تم تطويره بالاعتماد على مفهوم تكميّة الزاوية (**angle**) (**quantization**) الذي تمت إضافته لخوارزمية NSGA-II [15] يوضح الشكل (5) مفهوم زاوية الازدحام، حيث أن الفكرة تقوم على تقسيم فضاء البحث إلى قطاعات زاوية متساوية ويتم احتساب عدد الحلول في كل قطاع ويتم اختيار الحلول الجديدة بحيث تغطي القطاعات المستكشفة بشكل أقل مما يساعد في تغطية مجال البحث بشكل أفضل وينتج توزع متوازن للحلول، أي أننا نركز في اختيار الحلول على الحلول التي تقع في القطاعات

الحزمة التقليدية المعتمدة على Levenberg-Marquardt [18] ونسخة أخرى معتمدة على Finite Deference [19] Approximation .

وكذلك تمت إعادة التجارب 5 مرات في كل مرة يتم فيها اخذ بذرة (seed) مختلفة لمولد الأرقام العشوائية ليتم اختبار أداء الخوارزمية احصائياً.

5-1- المسار الأول :

تم توليد مسار للكاميرا موزعاً على 20 إطار ترصد 200 نقطة مميزة كما هو موضح بالشكل (7). وتم المقارنة بين الخوارزمية المقترحة والخوارزميتين المرجعيتين وبينت النتائج تفوقاً واضحاً للخوارزمية المقترحة من حيث الدقة وزمن التنفيذ، حيث يبين الشكل (8) التمثيل الإحصائي لنتائج تجارب المسار الأول حيث يعبر الخط الأحمر عن المتوسط الحسابي لقيمة الخطأ خلال التجارب لكل خوارزمية في حين أن المستطيل الأزرق يمثل مجال القيم التي تراوح ضمنها الخطأ خلال التجربة. ومن الجدير بالذكر أن قيم الخطأ في التجارب الخمسة لكل من الخوارزميتين المرجعيتين تكون ثابتة كونها تعتمد معادلات محددة في حساب الطول بينما تعتمد الخوارزمية المقترحة تقنية البحث العشوائي لذلك هناك تفاوت بقيم الخطأ حسب البذرة ولكن بالرغم من ذلك فإن أعلى قيمة للخطأ في حالتنا أقل ب 5% من قيمة الخطأ الأدنى للخوارزميات المرجعية.

ويوضح الشكل (9) زمن التنفيذ للخوارزميات على المسار الأول حيث أن الخوارزمية المقترحة اسرع و تستهلك ما يقارب 50% من الزمن التي تستهلكه خوارزمية Levenberg و 60% تقريباً من زمن Finite Deference.

يوضح الشكلين (10) و(11) النتائج السابقة معروضة على شكل أعمدة يمثل كل عامود منها نتيجة التجربة عند البذرة المحددة على المحور X.

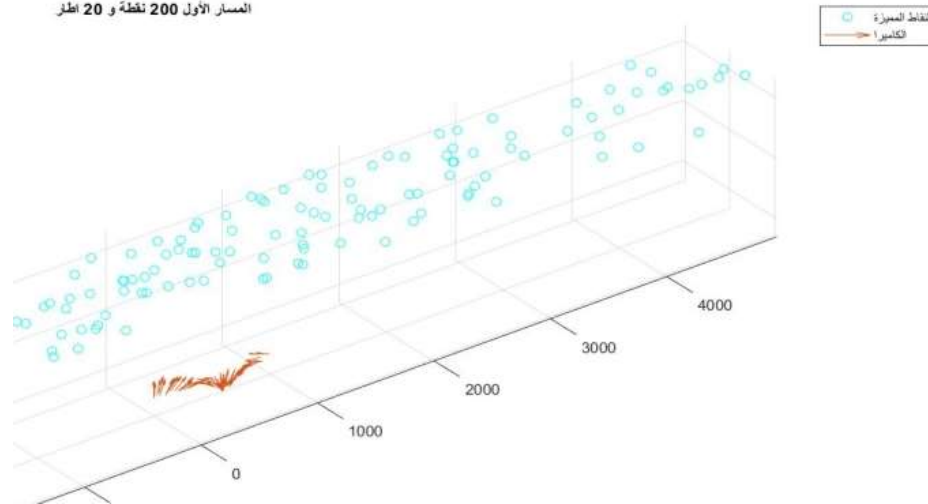
4-2-4- آلية اختيار القائد الهجينة :

يتم اختيار قائد السرب ضمن خوارزمية MOPSO التقليدية وفق آلية (roulette wheel) العجلة الدوارة حيث يتم اختيار حل من الحلول المتوقعة في الدورات السابقة ، ولكن هذه الآلية لا تضمن التقارب السريع للخوارزمية خاصة في التطبيقات المعقدة مثل ضبط الحزمة لذلك قمنا بتطوير آلية هجينة تساعد في ضمان التقارب من خلال دمج تقنيات التناقص المتدرج باستخدام خوارزمية (RADAM) [16] والتي تعد من أحدث وأفضل خوارزميات التدرج، حيث أننا نختار واحد من الحلول المتوقعة في الدورات السابقة ونقوم بتطبيق التدرج عليه من أجل تحسين قيمته ومن ثم نستخدمه كقائد لنسبة من جسيمات السرب وبالتالي نشر تأثير هذا التحسين والذي بدوره يساعد في اكتشاف حلول أفضل أثناء حركة باقي الجسيمات باتجاه القائد.


5. التطبيق العملي والنتائج :

من أجل تقييم أداء الخوارزمية المقترحة تم تطبيق ضبط الحزمة على مسارين الأول مؤلف من 200 نقطة موزعة على 20 إطار متداخل والثاني مؤلف من 200 نقطة موزعة على 50 إطار متداخل ، تم توليد هذين المسارين بالاعتماد على البرنامج الاختباري المقدم من قبل الباحثين في [17] من أجل تقييم أداء خوارزميات ضبط الحزمة المختلفة حيث يقوم البرنامج بتوليد نقاط مميزة وتوزيعها عشوائياً في الفراغ ، ثم يقوم بتوليد مسار محدد للكاميرا واسقاط النقاط المميزة ضمن كل إطار تظهر فيه تلك النقاط وفق بارامترات الكاميرا عند ذلك الإطار، ومن ثم يضيف ضجيج لمواضع الكاميرا والنقاط بحيث يحاكي الخطأ الحاصل في عملية الاسقاط . و تمت مقارنة الخوارزمية المقترحة HGAMOPSO مع نسخة من خوارزمية ضبط

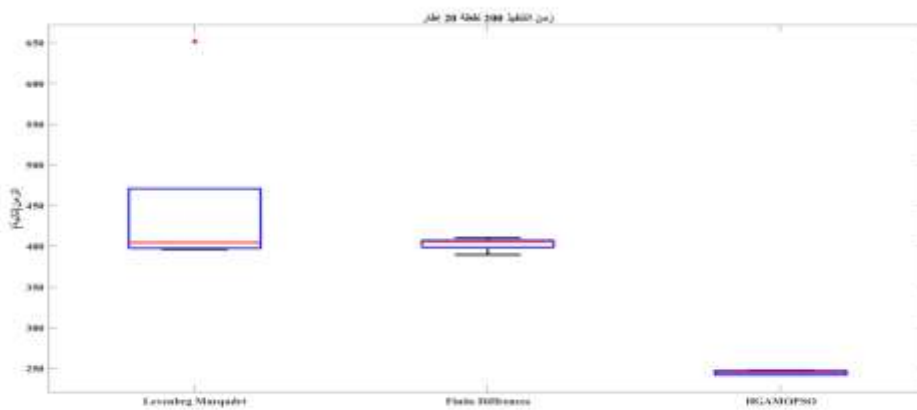
المسار الأول 200 نقطة و 20 إطار




الشكل (7) المسار الأول




الشكل (8) التمثيل الإحصائي لنتائج الخطأ على المسار الأول



الشكل (9) زمن التنفيذ للخوارزميات على المسار الأول



الشكل (10) نتائج الخطأ للمسار الأول على شكل أعمدة



الشكل (11) نتائج زمن التنفيذ للمسار الأول على شكل أعمدة


5-2- المسار الثاني:

القيم التي تراوح ضمنها الخطأ خلال التجربة. ومن الجدير بالذكر أن قيم الخطأ في التجارب الخمسة لكل من الخوارزميتين المرجعيتين تكون ثابتة كونها تعتمد معادلات محددة في حساب الحلول بينما تعتمد الخوارزمية المقترحة تقنية البحث العشوائي لذلك هناك تفاوت بقيم الخطأ حسب البذرة ولكن بالرغم من ذلك فإن أعلى قيمة للخطأ في حالتنا أقل ب 20% من قيمة الخطأ الأدنى للخوارزميات المرجعية.

ويوضح الشكل (14) زمن التنفيذ للخوارزميات على المسار الثاني حيث أن الخوارزمية المقترحة

تم توليد مسار للكاميرا موزعاً على 50 إطار ترصد 200 نقطة مميزة كما هو موضح بالشكل (12). وتم المقارنة بين الخوارزمية المقترحة والخوارزميتين المرجعيتين وبينت النتائج تفوقاً واضحاً للخوارزمية المقترحة من حيث الدقة وزمن التنفيذ، حيث يبين الشكل (13) التمثيل الإحصائي لنتائج تجارب المسار الثاني حيث يعبر الخط الأحمر عن المتوسط الحسابي لقيمة الخطأ خلال التجارب لكل خوارزمية في حين أن المستطيل الأزرق يمثل مجال

اسرع حيث أنها تستهلك مايقارب 56% من الزمن التي تستهلكه خوارزمية Levenberg و 58% تقريباً من زمن Finite Deference. نتيجة التجربة عند البذرة المحددة على المحور X.




الشكل (12) المسار الثاني




الشكل (13) التمثيل الإحصائي لنتائج الخطأ على المسار الثاني



الشكل (14) زمن التنفيذ للخوارزميات على المسار الثاني



الشكل (15) نتائج الخطأ للمسار الثاني على شكل أعمدة



الشكل (16) نتائج زمن التنفيذ للمسار الثاني على شكل أعمدة

ضبط الحزمة. ويمكن تفسير ذلك من خلال التحسينات التي تم اقتراحها فالتجهين مع خوارزمية RADAM ساعد في تحريك الحل باتجاه القيم المثلى دون حدوث تذبذب، والحصول على دقة أفضل وكون الخوارزمية تبحث خلال كل دورة باستخدام مجموعة من الحلول فإنها تستطيع التقارب بعدد دورات أقل من خوارزميات البحث التكرارية التي تعتمد على تحريك حل وحيد، وبالتالي زمن تنفيذ أقل كما أوضحت التجارب.

6. الخلاصة:

تم خلال هذا البحث تقديم خوارزمية HGAMOPSO الجديدة وتم استخدامها لضبط الحزمة ، حيث أنها تستثمر التقنيات المستخدمة في خوارزميات التحسين التقليدية مثل RADAM وتقنيات تخمين الخطأ الأصغر (LSE) الأخرى لتحسين حركة الحل وتقاربها، وأظهرت النتائج أن الخوارزمية المقترحة يمكن أن تساعد في تحسين الدقة بالإضافة للكفاءة في كل من الذاكرة والوقت لعملية

[11] L. Zhou *et al.*, “Stochastic Bundle Adjustment for Efficient and Scalable 3D Reconstruction,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12360 LNCS, no. Lm, pp. 364–379, 2020, doi: 10.1007/978-3-030-58555-6_22.

[12] N. Demmel, C. Sommer, D. Cremers, and V. Usenko, “Square Root Bundle Adjustment for Large-Scale Reconstruction,” no. 2, 2021, [Online]. Available: <http://arxiv.org/abs/2103.01843>.

[13] S. A. Fakhri and S. A. Fakhri, “Investigating the effect of PSO algorithm on reducing control points in camera calibration,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 42, no. 4/W18, pp. 363–369, 2019, doi: 10.5194/isprs-archives-XLII-4-W18-363-2019.

[14] V. Indelman and F. Dellaert, “Incremental light bundle adjustment: Probabilistic analysis and application to robotic navigation,” *Cogn. Syst. Monogr.*, vol. 23, pp. 111–136, 2014, doi: 10.1007/978-3-662-43859-6_7.

[15] A. Metiaf, Q. Wu, and Y. Aljeroudi, “Searching With Direction Awareness: Multi-Objective Genetic Algorithm Based on Angle Quantization and Crowding Distance MOGA-AQCD,” *IEEE Access*, vol. 7, pp. 10196–10207, 2019, doi: 10.1109/ACCESS.2018.2890461.

[16] L. Liu *et al.*, “On the Variance of the Adaptive Learning Rate and Beyond,” pp. 1–14, 2019, [Online]. Available: <http://arxiv.org/abs/1908.03265>.

[17] Riccardo Giubilato, “Bundle Adjustment using lsqnonlin.” 2016, [Online]. Available: https://github.com/RiccardoGiubilato/Test_BA.

[18] M. I. A. Lourakis and A. A. Argyros, “Is Levenberg-Marquardt the most efficient optimization algorithm for implementing bundle adjustment?,” in *Proceedings of the IEEE International Conference on Computer Vision*, 2005, vol. II, pp. 1526–1531, doi: 10.1109/ICCV.2005.128.

[19] A. Chambolle, T. Pock, A. Chambolle, T. Pock, and T. Variation, “Approximating the Total Variation with Finite Differences or Finite Elements,” 2020.

Abstract

[1] Q. Demoulin, F. Lefebvre-Albaret, A. Basarab, D. Kouamé, and J. Y. Tourneret, “Wing 3D reconstruction by constraining the bundle adjustment with mechanical limitations,” in *European Signal Processing Conference*, 2021, vol. 2021-Janua, no. December 2020, pp. 570–574, doi: 10.23919/Eusipco47968.2020.9287727.

[2] W. Song, S. Liu, X. Tong, C. Niu, and Z. Ye, “Combined Geometric Positioning and Performance Analysis of Multi-Resolution Optical Imageries from Satellite and Aerial Platforms Based on Weighted RFM Bundle Adjustment,” 2021.

[3] Y. Chen, Y. Chen, and G. Wang, “Bundle Adjustment Revisited,” 2019, [Online]. Available: <http://arxiv.org/abs/1912.03858>.

[4] B. Triggs *et al.*, “Bundle Adjustment – A Modern Synthesis To cite this version : Bundle Adjustment — A Modern Synthesis,” 2010.

[5] and O. S. Agarwal, K. Mierle, “Ceres solver.” 2010, [Online]. Available: <http://ceres-solver.org>.

[6] S. Agarwal, N. Snavely, S. M. Seitz, and R. Szeliski, “Bundle adjustment in the large,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6312 LNCS, no. PART 2, pp. 29–42, 2010, doi: 10.1007/978-3-642-15552-9_3.

[7] and S. M. S. C. Wu, S. Agarwal, B. Curless, “Multicore bundle adjustment.” The 24th IEEE Conference on Computer Vision and Pattern Recognition, 2011.

[8] K. Konolige, “Sparse Sparse Bundle Adjustment,” 2010, doi: 10.5244/C.24.102.

[9] C. Zhang, G. Wen, C. Wu, H. Wang, Z. Shang, and Q. Zhang, “Genetic algorithm for bundle adjustment in aerial panoramic stitching,” in *Sixth International Conference on Graphic and Image Processing (ICGIP 2014)*, 2015, vol. 9443, no. Icgip 2014, p. 94431G, doi: 10.1117/12.2178852.

[10] Å. Björck and T. Elfving, “Accelerated projection methods for computing pseudoinverse solutions of systems of linear equations,” *Bit*, vol. 19, no. 2, pp. 145–163, 1979, doi: 10.1007/BF01930845.