

**التجهات البحثية لقسم بحوث العمليات والتقنيات الذكائية**

يركز قسم بحوث العمليات والتقنيات الذكائية بشكل عام على عدة توجهات بحثية حديثة ومتقدمة، تستفيد من التطورات في مجالات الذكاء الاصطناعي، وتحليل البيانات، والتحسين، والمحاكاة، وذلك لحل المشكلات المعقدة في مختلف القطاعات

ويركز القسم على التوجهات التالية :-

**1- التكامل بين بحوث العمليات والذكاء الاصطناعي (OR-AI Integration)**

**التعلم الآلي في بحوث العمليات (Machine Learning in OR):** استخدام خوارزميات التعلم الآلي للتنبؤ بالبيانات، وتحديد الأنماط، وتحسين دقة النماذج الرياضية في بحوث العمليات. على سبيل المثال، التنبؤ بالطلب لتحسين إدارة المخزون، أو التنبؤ بالأعطال في الصيانة التنبؤية.

**التعلم العميق وتحسين العمليات (Deep Learning and Optimization):** تطبيق الشبكات العصبية العميقه لحل مشكلات التحسين المعقدة، خاصة تلك التي تتضمن بيانات كبيرة وغير منظمة، مثل تحسين المسارات في سلاسل التوريد الكبيرة أو جدولة الموارد المعقدة.

**2- تحليل البيانات الضخمة وبحوث العمليات (Big Data Analytics and OR):**

**التحليلات التنبؤية والوصفيّة (Predictive and Prescriptive Analytics):** استخدام تقنيات تحليل البيانات الضخمة لاكتشاف الرؤى من مجموعات البيانات الكبيرة، ثم تطبيق نماذج بحوث العمليات لتقديم توصيات قابلة للتنفيذ لتحسين الأداء.

**3- تطوير نماذج وطرق جديدة (Developing New Models and Methodologies):**

**نماذج التحسين الهجين (Hybrid Optimization Models):** دمج تقنيات التحسين التقليدية (مثل البرمجة الخطية) مع أساليب الذكاء الاصطناعي (مثل الشبكات العصبية) لتحقيق أداء أفضل.

#### 4 - بحوث العمليات في تطبيقات محددة: (Domain-Specific Applications of OR)

• الرعاية الصحية (Healthcare): تحسين جدولة المواقع، إدارة موارد المستشفيات، تحسين خطط العلاج، وتحليل البيانات الطبية باستخدام نماذج بحوث العمليات والذكاء الاصطناعي.

التمويل (Finance): نماذج المخاطر، تحسين محافظ الاستثمار، الكشف عن الاحتيال، والتنبؤ بالأسواق المالية.

#### 5- التكامل بين بحوث العمليات وذكاء الأسراب لتحسين النظم المعقدة:

تحسين نماذج بحوث العمليات باستخدام خوارزميات الأسراب:

الفكرة: استخدام خوارزميات ذكاء الأسراب مثل PSO, ACO, GWO, WOA كأدوات تحسين قوية لحل نماذج بحوث العمليات المعقدة وغير الخطية التي يصعب حلها بالطرق التقليدية (مثل البرمجة الخطية الصحيحة المختلطة ذات الأبعاد العالية)

#### 6- خوارزميات الأسراب متعددة الأهداف: (Multi-Objective Swarm Intelligence)

الفكرة: معظم مشكلات بحوث العمليات في الواقع لها أهداف متعددة ومتغيرة (مثلاً: تقليل التكلفة وزيادة الجودة وتقليل الوقت). يتم تطوير خوارزميات أسراب قادرة على إيجاد مجموعة من الحلول المثلثى (Pareto Front) بدلاً من حل واحد.

#### 7- دمج خوارزميات الأسراب مع المحاكاة: (Swarm Intelligence with Simulation)

الفكرة: استخدام خوارزميات الأسراب لتحسين معلمات نماذج المحاكاة المعقدة. تقوم المحاكاة بتقييم أداء نظام معين (مثلاً مستشفى أو سلسلة توريد) تحت ظروف مختلفة، وتستخدم خوارزميات الأسراب لإيجاد أفضل مجموعة من المعلمات التي تحسن أداء النظام.

## 8- التحليل الرياضي لسلوك خوارزميات الأسراب:

الفكرة: استخدام الأدوات الرياضية (مثل نظرية الأنظمة الديناميكية، نظرية التحكم، نظرية المجموعات الضبابية) لفهم سلوك تقارب خوارزميات الأسراب، تحليل استقرارها، وشرح سبب فعاليتها في حل المشكلات.

## 9- تحسين تصميم خوارزميات الأسراب باستخدام الرياضيات التطبيقية:

الفكرة: تطبيق مفاهيم رياضية متقدمة (مثل نظرية الفوضى Chaos Theory - ، المجموعات الضبابية Fuzzy Sets

المنطق الضبابي Fuzzy Logic - لتصميم آليات جديدة داخل خوارزميات الأسراب لتحسين أدائها، مثل التحكم في سرعة الجسيمات أو تعديل معدلات الفيرومونات..

## 10- التحليل الإحصائي لأداء خوارزميات الأسراب:

الفكرة: استخدام الاختبارات الإحصائية (مثل ANOVA ، اختبار ويلكوكسون (المقارنة أداء خوارزميات الأسراب المختلفة على مجموعة من مشكلات الاختبار، وتحديد ما إذا كانت الفروق في الأداء ذات دلالة إحصائية.

## استخدام النمذجة الإحصائية لخصائص مشكلة التحسين:

الفكرة: تطبيق تقنيات الإحصاء التطبيقي (مثل تحليل الانحدار، تحليل المكونات الرئيسية) لفهم خصائص فضاء البحث لمشكلة معينة، مما يساعد في اختيار أو تكيف خوارزمية السرب الأنسب.

## 11- التعلم الإحصائي لضبط معلمات خوارزميات الأسراب (Parameter Tuning):

الفكرة: استخدام تقنيات التعلم الإحصائي (مثل التعلم المعزز، أو النمذجة البيزية) لضبط معلمات خوارزميات الأسراب تلقائياً خلال عملية الحل أو للوصول إلى أفضل قيم للمعلمات لمجموعة من المشكلات.

## 12- تميز الأنماط في تحليل البيانات الضخمة وبحوث العمليات:

اكتشاف الأنماط في البيانات التشغيلية: استخدام تقنيات تميز الأنماط (مثل خوارزميات التصنيف والتجميع) لتحليل كميات هائلة من البيانات التشغيلية (بيانات العملاء، بيانات الإنتاج، بيانات سلسلة التوريد) للكشف عن سلوكيات وأنماط خفية.

تميز الأنماط للتصنيف والتجميع: تطوير خوارزميات تصنيف (Classification) لتصنيف البيانات إلى فئات محددة (مثل عميل جيد/سيء، منتج معيب/صالح) وخوارزميات تجميع (Clustering) لتجميع البيانات المتشابهة معًا (مثل تجميع العملاء إلى شرائح، تجميع المستندات المتشابهة).