



مجلة الإدارة والاقتصاد Journal of Administration & Economics

Mustansiriyah
University

College of
Administration &
Economics

P-ISSN: 1813 - 6729

E-ISSN: 2707-1359

تحسين البرمجة الخطية باستخدام تقنيات الذكاء الاصطناعي : دراسة تجريبية

منى شاکر سلمان

قسم تقنيات المحاسبة ، المعهد التقني الصويرة ، الجامعة التقنية الوسطى ، العراق

Email: muna.shaker@mtu.edu.iq, ORCID ID: <https://orcid.org/0000-0002-6664-8411>

المستخلص

يعد مجال بحوث العمليات احد المجالات الرئيسية في علوم الإدارة والهندسة الصناعية، ومن اهم تلك المجالات هي البرمجة الخطية (Linear Programming) والتي تضمنت تقنيات مهمة منها : (تحسين العمليات الانتاجية من خلال تطبيق تقنيات وادوات مثل تحليل الشبكات وتحليل العوامل الرئيسية وتحليل الانحدار اضافة الى تصميم نماذج لتحسين الامداد بالموارد الاولية والتخطيط والتحكم بسلاسل الامداد كذلك تحسين تقنيات تحليل البيانات والذكاء الاصطناعي في اتخاذ القرارات الاستراتيجية مثل البيانات الكبيرة Big Data، Machin Learning، التعليم العميق Deep learning). كما ساهمت تقنيات البرمجة الخطية في تحسين الجودة وادارة المخاطر من خلال تقليل المخاطر المرتبطة بالعمليات مثل ادارة الجودة الشاملة، تصميم التجارب، تحليل المخاطر وتصميم النظم المرنة لتساعد على الابتكار وتطوير المنتجات. وتعد تقنيات ربط البرمجة الخطية بالذكاء الاصطناعي ذات اهمية كبيرة اذ ساعدت على تطوير الانظمة والتقنيات التي تتميز بالقدرة على تعلم والتفكير واتخاذ القرارات بشكل مشابه للإنسان على سبيل المثال (استعمال الذكاء الاصطناعي في تحسين عمليات التخطيط والتحليل في مشكلات البرمجة الخطية). في دراستنا تم تسليط الضوء على احدى تقنيات الذكاء الاصطناعي في مجال البرمجة الخطية وهي الخوارزمية الجينية (Genetic Algorithm (GA)) اذ يهدف البحث ايجاد القيم المثلى لمتغيرات دالة الهدف في ظل القيود المفروضة على مشكلة البرمجة الخطية ومن خلال التحسين (Optimization) غان قيمة دالة الهدف حقت اعظم الارباح مقارنة بدالة الهدف المحسوبة ضمن طريقة السمبلكس (Simplex Method)، كما تم حساب دالة اللياقة على ضوء المعطيات في المسألة ، وتم ايجاد النتائج بالاستعانة ببرنامج [MATLAB R2019a].

معلومات البحث

تواريخ البحث:

تاريخ تقديم البحث: 2024 / 2 / 7

تاريخ قبول البحث: 2024 / 3 / 7

عدد صفحات البحث 56 - 68

الكلمات المفتاحية:

البرمجة الخطية ، الخوارزمية الجينية ، الذكاء الاصطناعي ، التعلم الآلي ، التعلم العميق .

المراسلة:

أسم الباحث: منى شاکر سلمان

Email :

muna.shaker@mtu.edu.iq

1. المقدمة

تم تطوير اساليب البرمجة الخطية في الاصل بين عامي (1945-1955) من قبل علماء الرياضيات لحل المشكلات الناتجة في الصناعة والتخطيط الاقتصادي والعديد من هذه المشكلات تتضمن قيودا. وتعد البرمجة الخطية هي تعميم للجبر الخطي. وتمتلك القدرة على التعامل مع مجموعة متنوعة من المشكلات والسبب في هذا التنوع الكبير هو السهولة التي يمكن فيها دمج القيود في الانموذج. [8]

ان تقنيات الذكاء الاصطناعي متعددة منها: (تحسين العمليات، تصميم نماذج لتحسين الامداد بالموارد الاولية وتحسين تقنيات تحليل البيانات والذكاء الاصطناعي على سبيل المثال البيانات الكبيرة Big Data ، التعلم الآلي Machin Learning والتعليم العميق Deep learning). اذ ساهمت تقنيات البرمجة الخطية في تحسين الجودة وادارة المخاطر من خلال تقليل المخاطر المرتبطة بالعمليات مثل ادارة الجودة الشاملة، تصميم التجارب، تحليل المخاطر وتصميم النظم المرنة لتساعد على الابتكار وتطوير المنتجات . ان ربط تقنيات البرمجة الخطية بالذكاء الاصطناعي والذي ساعد على تطوير الانظمة والتقنيات التي تتميز بالقدرة على تعلم وتفكير واتخاذ القرارات بشكل مشابه للإنسان على سبيل المثال (استعمال الذكاء الاصطناعي في تحسين عمليات التخطيط والتحليل في مشكلات البرمجة الخطية ، اذ يمكن للنظم الذكية تحليل البيانات وتحديد النماذج والعلاقات الرياضية المعقدة التي تسيطر على المشكلة بالتالي يمكن للنظام الذكي اقتراح حلول محتملة وتحسين الخطط القائمة) . في دراستنا تم تسليط الضوء على اهم تقنيات الذكاء الاصطناعي في مجال البرمجة الخطية وذلك من خلال اختيار القيم المثلى للمعطيات الداخلة في دالة الهدف والقيود والتي تساهم في تعظيم او تصغير دالة الهدف وتم اجراء المحاكاة للوصول الى أفضل انموذج أمثل .

تتلخص مشكلة البحث بكيفية تحسين قيمة دالة الهدف البرمجة الخطية في ظل قيود مفروضة على الانموذج باستعمال تقنيات الذكاء الاصطناعي (الخوارزمية الجينية) من خلال تمكين البرنامج في القيام بأنشطة ذكية وتفاعلية في بيئة المحاكاة ويتكيف مع تغييراتها ويتفاعل مع العوامل المحيطة لتحقيق التحسين المطلوب .

يستند هذا البحث على النتائج والاستنتاجات التي توصلت إليها الدراسات السابقة، مما يسلب الضوء على الأسس التي اعتمدت إليها الدراسات السابقة عن الذكاء الاصطناعي والخوارزمية الجينية ويعزز استكمال البحث الحالي. ففي عام (1963) طور الباحث G.B. Dantzig [5] نموذج GA الذي يعتمد على خوارزمية الجينات لاستخلاص سياسة التشغيل المثلى وقد اثبتت الخوارزمية كفاءتها من خلال مقارنة النتائج. اما في عام (1975) طور الباحث De Jong, K. A [4] الخوارزمية الجينية من خلال استعمال برامج الحاسوب اذ تم تحديد اوليات الإباء والابناء والانتقال الطبيعي وتوظيف مجموعة تكاثر متعدد الأجيال. اما في عام (1992) تمكن الباحث Holland, J. H. [10] من توليد برامج تحل المشكلات المعقدة حتى عندما لا يتمكن الباحث من فهم بنية المشكلة بشكل كامل وهذا ما يسمى بالخوارزميات الجينية التي اثبتت بالفعل قدرتها على تحقيق اختراقات في تصميم أنظمة معقدة بالإضافة الى تمكنها من اكتشاف نطاق اكبر من الحلول المحتملة لمشكلة معينة بالمقارنة مع البرامج التقليدية. كما قدم الباحثان Bergkvist, L. Marcel A, Damaschke, and [2] في عام (2006) دراسة لتقييم قواعد التشغيل لأنظمة الخزانات المتعددة باستخدام الخوارزمية الجينية ، مما يدل على أنه يمكن استخدام GA لتحديد سياسات التشغيل الفعالة. كما قام أيضا بمراجعة موجزة لتطبيقات GA لمشاكل الموارد المائية في العمل. كما طبق الخوارزمية الجينية لتحسين نظام الخزانات المتعددة في إندونيسيا (حوض Brantas) من خلال النظر في الوضع المتنامي الحالي في الحوض واقتروا سيناريو مستقبلي لتنمية موارد المياه. وقد أثبتوا أن GA قادرة على إنتاج حلول قريبة جداً من تلك التي تنتجها البرمجة الديناميكية. وفي عام (2007) قدم الباحث H. Md. Azamathulla [6] صياغة للبرمجة الخطية وتوظيفها في مشاكل التخطيط في عمليات القوات الجوية الأمريكية، كما يعد أحد المساهمين الرئيسيين في تطور برمجة الأعداد الصحيحة اذ قام بصياغة مشكلة البائع المتجول، والتي هي عبارة عن خوارزمية تمثل التفرع والتحديد (Branch and Band) وشكلت أساس أنظمة الأعداد الصحيحة المستخدمة لحل النماذج في مجالات متنوعة مثل النقل والاتصالات والتصنيع وسلاسل التوريد. كما درس الباحثان Datta, C. Garai, C. Das [3] في عام 2012 الخوارزمية الجينية وبيّنوا ان الخوارزمية تعتمد على اليات الانتقال الطبيعي وعلم الوراثة الطبيعي عن طريق صياغة مشكلة النقل باعتبارها مشكلة برمجة خطية وتوصلت الدراسة الى حل مشابه جداً للخوارزمية البسيطة، كما قدم الباحثان M. Joao, C. Eernsto, M. Lino [12] عام (2016) دراسة استعمالها فيها بيانات ديناميكية في تطبيقات عديدة بهدف اجراء مقارنة بين أداء GA مع البرمجة الديناميكية وتوصلت الدراسة أن أداء GA كان أفضل. وفي عام 2017 اقترح الباحثان Singh L.S, Damaschke and L, Mehrotra.R. [20] إجراء منهجياً للحصول على الحل الأمثل لمشكلة برمجة الأعداد الصحيحة بالكامل وقاموا بتوسيع هذه الطريقة لحل الحالات الأكثر تعقيداً لمشكلة برمجة الأعداد الصحيحة المختلطة بدءاً بتطبيق الخوارزمية الجينية GA على مشاكل تشغيل الخزان في العقد الأخير من القرن الحادي والعشرين.

2. هدف البحث:

تحسين قيمة داله الهدف وذلك من خلال اجراء تجربة محاكاة لتوليد الاجيال (السكان) واختيار الوالدين لتكوين جيل جديد واختبار قيمة الدالة المستهدفة باستخدام هذه المتغيرات لإيجاد القيم المثلى من خلال حساب دالة اللياقة (Fitness Function) اللياقة. فإذا كانت تلك القيم الجديدة أفضل من القيم الحالية من حيث تحسين دالة الهدف (تعظيم (ارباح)) يتم تحديث القيم المثلى للمتغيرات وقيم الدالة المثلى.

3. المفاهيم النظرية

1.1 تعريف البرمجة الخطية Define Linear programming

يمكن تعريف البرمجة الخطية (Linear Programming (LP)) على انها التعبير عن العلاقة المتبادلة بين أنشطة النظام بدلالة مجموعة من القيود الخطية في المتغيرات غير السالبة. اذ يتم اختيار برنامج ، أي قيم المتغيرات ، الذي يفي بالقيود ويحسن دالة الهدف الخطية في هذه المتغيرات . اما مشكلة البرمجة الخطية فهي مشكلة تصغير (Minimum) أو تعظيم (Maximum) دالة خطية في (n) من المتغيرات تخضع لقيود خطية (m) ، مع تقييد المتغيرات لتكون غير سالبة . رياضياً ، لدينا Min (max) cX يخضع لـ $AX = b$, $X \geq 0$ بوجود مصفوفة A وابعادها (mxn) من المعاملات (الثابت). يمكن أيضاً كتابة القيود $AX = b$ من حيث عدم المساواة، أي $AX \leq b$ أو $AX \geq b$ أو مجموعة مختلطة من هذه القيود . وتشترك جميع نماذج البرمجة الخطية (LP) في اربع خصائص اساسية: [8]

- تسعى جميع نماذج LP إلى تعظيم أو تقليل بعض الكميات ، وعادة ما تكون الربح أو التكاليف .
- تحتوي جميع نماذج LP على قيود تحد من الدرجة التي يمكن بها تحقيق الهدف.
- يجب أن يكون هناك مسار بديل للاختيار من بينها ، على سبيل المثال . إذا كان هناك 4 منتجات مختلفة، فقد تقرر الإدارة كيفية تخصيص الموارد المحدودة فيما بينها .
- يجب التعبير عن الأهداف والقيود في نموذج (LP) في المعادلات الخطية والمتباينات .
- اما اهم فرضيات (LP) فتتص على ما يأتي: [9,8] .
- **حالة التأكد Certainty** : اذ نفترض أن الأرقام في دالة الهدف وقيودها معروفة بشكل مؤكد ولا تتغير خلال فترة الدراسة.

- النسبية **Proportionality** : وتعني الزيادة أو النقص في قيم المتغيرات في دالة الهدف تتناسب تناسباً طردياً مع الزيادة أو النقص في قيمة أي من المتغيرات المفردة . أي أنه إذا كان إنتاج وحدة واحدة من المنتج يربح \$2 فإذا أنتج خمس وحدات من هذا المنتج يتم ربح \$10 .
- التجميع **Additivity** : وهذا يعني أن مجموع جميع الأنشطة يساوي مجموع كل نشاط على حدة .
- قابلية القسمة **Divisibility** : هذا يعني أن الحل قد يأخذ قيمة كسرية ولا يلزم أن يكون أعداد صحيحة .
- عدم السالبية **non-negativity** : اذ نفترض أن جميع الإجابات أو المتغيرات غير سالبة، اذ ان القيم السالبة للكميات تعني الحل غير ممكن .

ولصياغة نموذج تحسين البرمجة الخطية يمكن اتباع الخطوات الآتية: [1, 11]

الخطوة 1 : اختيار المتغيرات والرموز التي سيتم استخدامها لتشكيل دالة الهدف والقيود.

الخطوة 2 : تحديد دالة الهدف إما لتعظيمها أو تصغيرها على سبيل المثال. زيادة الربح أو تخفيض التكلفة.

الخطوة 3 : تفصيل العلاقات الرياضية لوصف الأهداف والقيود.

الخطوة 4 : استخدام المعادلات في أي طريقة لحل مشكلة LP، على سبيل المثال طريقة Graphical أو Simplex.

ويتم استعمال الانموذج القياسي لوصف مشكلة البرمجة الخطية (LP) وهي الصيغة الأكثر استعمالاً لوصف مشكلة البرمجة الخطية. ويتكون من الأجزاء الأربعة كما في المعادلة (1) التالية:

$$\begin{aligned} \max_{x_1, x_2} f(x_1, x_2) &= c_1x_1 + c_2x_2 && \text{دالة خطية مطلوب تعظيمها} \\ a_{11}x_1 + a_{12}x_2 &\leq b_1 && \text{قيود المشكلة على سبيل المثال:} \\ a_{21}x_1 + a_{22}x_2 &\leq b_2 \\ a_{31}x_1 + a_{32}x_2 &\leq b_3 \\ x_1 &\geq 0; x_2 &\geq 0 && \text{متغيرات غير سالبة} \\ b_i &\geq 0, i = 1, 2, 3 && \text{ثوابت الجانب الايمن للقيود غير سالبة} \end{aligned} \quad (1)$$

كما يمكن إعادة صياغة الانموذج القياسي لمشاكل البرمجة الخطية مثل مشكلات التقليل (Min)، ومشاكل القيود على النماذج البديلة، بالإضافة إلى المشكلات التي تتضمن متغيرات سالبة إلى صيغة مكافئة إلى الانموذج القياسي، اذ يمكن تحويل أي صيغة للبرمجة الخطية إلى الصيغة القياسية كما في المعادلة (2):-

$$\begin{aligned} \text{Minimise } x_0 &= c_1x_1 + c_2x_2 + \dots + c_nx_n \\ \text{Subject to} \\ a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n &= b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n &= b_2 \\ \dots + \dots + \dots + \dots &= \dots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n &= b_m \end{aligned} \quad (2)$$

اذ ان: $x_1 \geq 0, x_2 \geq 0, x_n \geq 0$.
قيم حقيقية ثابتة. b_i, c_j, a_{ij}

$x_i = 0, 1, \dots, n$: الأعداد الحقيقية التي سيتم تحديدها، وبافتراض ان $b_i > 0$ (يتم ضرب كل معادلة ب (1) لتحقيق ذلك)، ولتوضيح ذلك ليكن لدينا المثال الآتي: [18, 19].

تقوم شركة لتصنيع الاغذية الصحية للحيوانات الاليفة (الكلاب) بتصنيع نوعين من الاغذية: علب اللحوم (M) و علب الغذاء الصحي (Y). تحتوي كل عبوة من اللحوم على (2 كيلو) من الحبوب و (3 كيلو) من اللحوم؛ تحتوي كل عبوة من الاغذية الصحية على 3 كيلو من الحبوب و 1.5 كيلو من اللحم. تعتقد الشركة أنها تستطيع بيع أكبر قدر ممكن من طعام الحيوانات الاليفة. اذ تباع اللحوم بسعر 2.80 دولاراً أمريكياً لكل عبوة، بينما تباع الاغذية مقابل 2.00 دولاراً أمريكياً لكل عبوة. تستطيع الشركة شراء ما يصل إلى 400 ألف كيلو فقط من الحبوب كل شهر بسعر 0.20 دولار للكيلو. ويمكنها شراء ما يصل إلى 300 ألف كيلو فقط من اللحوم شهرياً بسعر 0.50 دولار للكيلو الواحد. فضلاً عن ذلك، يلزم وجود آلة خاصة لتصنيع اللحوم، وتبلغ القدرة الانتاجية لهذه الآلة 90,000 عبوة شهرياً. تبلغ التكلفة لخلط وتعبئة طعام الكلاب 0.25 دولاراً أمريكياً لكل عبوة من اللحوم و 0.20 دولاراً أمريكياً لكل عبوة من منتجات الاغذية الصحية. لنفترض ان الشركة تحاول تعظيم الارباح قدر الامكان، ونستطيع تحديد متغيرات القرار والتي نتحكم بها وفي هذه المشكلة لدينا تحكم مباشر في كميتين: عدد عبوات اللحوم التي يجب تحضيرها كل شهر، وعدد عبوات الاغذية الصحية التي يجب

حضيرها كل شهر. تظهر هاتان الكميتان في النموذج بشكل متكرر، لذلك نمثلهما بطريقة بسيطة نشير إلى هذه المتغيرات بالرمزين M و Y.

M: عدد عبوات اللحوم التي يجب تحضيرها كل شهر.

Y: عدد عبوات الاغذية الصحية التي يجب إعدادها كل شهر.

ولتحديد دالة الهدف. يعد اي زوج من القيم الرقمية للمتغيرين M و Y هو خطة إنتاج. على سبيل المثال، اذا كان لدينا، $M=10000$ و $Y=20000$ يعني أننا نصنع 10,000 عبوة من اللحوم و 20,000 عبوة من الاغذية الصحية كل شهر. ولكن كيف نعرف ما إذا كانت هذه خطة إنتاج جيدة؟ نحن بحاجة إلى تحديد معيار للتقييم، دالة الهدف الأكثر ملاءمة هي تحقيق أعظم كمية من الربح الشهري. إن الربح الذي تحققه شركة الاغذية الصحية هو دالة مباشرة لكمية طعام للكلاب الكلية التي يتم تصنيعها وبيعها، متغيرات القرار. يتم صياغة دالة الهدف (الربح الشهري) والمسمى بـ Z ، على النحو الآتي:

Z (الربح لكل عبوة من اللحوم) = (عدد عبوات اللحوم التي يتم تصنيعها وبيعها شهرياً) * (الربح لكل عبوة من وجبات Yummies) * (عدد عبوات Yummies التي يتم تصنيعها وبيعها شهرياً). ويتم حساب كل عبوة كما ب(الجدول 1) كالآتي:

جدول (1): يبين تفاصيل سعر البيع وصافي الربح لكل عبوة

التفاصيل	اللحوم	الاكل الصحي
سعر البيع	2.80	2.00
مطروح منه		
اللحم	1.50	0.75
رقائق الذرة	0.40	0.60
كلفة المزج	0.25	0.20
صافي الربح لكل عبوة	0.65	0.45

دالة الهدف هي تعظيم الارباح (Z) كما في المعادلة (3)

$$z = 0.65M + 0.45Y \quad (3)$$

ولجعل قيمتها اكبر مايمكن فيجب جعل كميات M و Y كميات كبيرة وهذا لايمكن بسبب وجود قيوداً تتعلق بتوفر الحبوب واللحوم والقدرة الانتاجية للحوم، بالتالي يتم تعظيم قيمة (Z) بشرط تحقيق القيود السابقة، لذا سيتم بناء القيود وهي كالآتي : قيد توفر الحبوب : ((عدد كيلوات الحبوب المستخدمة في الإنتاج كل شهر هي 400000 كيلو. يتم تحديد الجانب الأيسر (Left Hand Side (L.H.S) من القيد من خلال عدد عبوات اللحوم والاغذية الصحية المصنعة، وكالاتي المعادلة(4) : (كيلو من الحبوب لكل عبوة من اللحوم) * (عبوات من اللحوم يتم تصنيعها وبيعها شهرياً) + (كيلو من الحبوب لكل عبوة من الوجبات الصحية) * (عبوات من الوجبات الصحية يتم تصنيعها وبيعها شهرياً).

$$2M + 3Y \leq 400000 \quad (4)$$

قيد توفر اللحوم: بنفس الاسلوب السابق المعادلة(5)

$$3M + 1.5Y \leq 300000 \quad (5)$$

بالإضافة الى ذلك فان قيد كميات انتاج عبوات اللحوم يجب ان لا تتجاوز 90000 عبوة شهرياً معادلة (6)، اي

$$M \leq 90000 \quad (6)$$

ويجب ملاحظة في حالة ان مستويات الإنتاج تكون سلبية فان ذلك غير منطقي، لذلك يتطلب ان تكون كلا من $M_0 > 0$ و $Y_0 > 0$. إن تجميع دالة الهدف والقيود المفروضة عليها معاً يعطي نموذج التحسين المقيد الآتي معادلة (7):

$$\begin{aligned} \text{Maximize } z &= 0.65M + 0.45Y \\ \text{s. t. } 2M + 3Y &\leq 400000 \\ 3M + 1.5Y &\leq 300000 \\ M &\leq 90000 \\ M, Y &\geq 0 \end{aligned} \quad (7)$$

هذا النوع من النماذج يسمى بالنموذج البرمجة الخطية لأن دالة الهدف خطية والدوال في جميع القيود خطية. الحل الأمثل لمشكلة أغذية الحيوانات الأليفة الصحية استناداً لطريقة السمبلكس (Simplex Method) هو $M=50000$ و $Y=100000$ بالتالي فإن $Z=77,500$ \$. وهذا يعني أن شركة الاغذية الصحية يجب أن تنتج 50000 عبوة من اللحوم و 100000 عبوة من الاغذية الصحية كل شهر، وستحقق ربحاً شهرياً قدره 77500 دولار.

2.3 نماذج التحسين :

ان نماذج التحسين بشكل عام تمتلك مزايا وعيوب بنفس الوقت ، اذ تتمثل الفائدة الرئيسية لنماذج التحسين في القدرة على تقييم الحلول الممكنة بطريقة سريعة وأمنة وغير مكلفة دون بنائها وتجربتها فعلياً. الفوائد الأخرى هي على النحو التالي [13, 14] بيني عملية التفكير . إن بناء نموذج تحسين للمشكلة يجبر صانع القرار على التفكير في المشكلة بطريقة موجزة ومنظمة . ويمكن صانع القرار من تحديد العوامل التي يتحكم فيها؛ أي ما هي متغيرات القرار. ويحدد صانع القرار كيفية تقييم الحل (دالة الهدف). وأخيراً، يصف صانع القرار بيئة القرار (القيود). اذ تعد النمذجة كوسيلة لتنظيم المشكلة وتوضيحها.

1- يزيد من الموضوعية. تعد النماذج الرياضية أكثر موضوعية حيث أن جميع الافتراضات والمعايير محددة ومعروفة. على الرغم من أن النماذج تعكس تجارب وتحيزات أولئك الذين يقومون ببنائها، إلا أن هذه التحيزات يمكن تحديدها من قبل مراقبين خارجيين.

- وباستخدام النموذج كنقطة مرجعية، يمكن للأطراف تركيز مناقشاتهم وخلافاتهم على افتراضاته ومكوناته. بمجرد الاتفاق على النموذج.
- 2- يجعل المشكلات المعقدة أكثر قابلية للحل. العديد من المشكلات في إدارة المنظمة كبيرة ومعقدة وتتعامل مع علاقات متبادلة دقيقة ولكنها مهمة بين الوحدات التنظيمية. على سبيل المثال، عند تحديد الكميات المثلى من المنتجات المختلفة التي سيتم شحنها من مستودعات متفرقة جغرافياً إلى عملاء متفرقين جغرافياً والطرق التي ينبغي سلوكها، لا يستطيع العقل البشري إجراء مليارات المقايضات المتزامنة الضرورية. في هذه الحالات، غالباً ما يستخدم صانع القرار قواعد بسيطة، مما قد يؤدي إلى حلول أقل من المثالية. تعمل نماذج التحسين على تسهيل حل المشكلات المعقدة على مستوى المؤسسة.
- 3- جعل المشكلات قابلة للحل الرياضي والحاسوبي.
- 4- تجعل النماذج الرياضية من السهل نسبياً العثور على الحل الأمثل لنموذج وسيناريو محدد. كما أنها تجعل تحليل " What If " أمراً سهلاً. ومن خلال تحليل " What If "، ندرك أن الأسعار والطلبات وتوافر المنتجات المفترضة في بناء النموذج هي مجرد تقديرات وقد تختلف في التطبيقات العملية. ولذلك، نريد أن نعرف كيف يتغير الحل الأمثل حيث تختلف قيمة هذه المعلمات عن التقديرات الأصلية. أي أننا نريد أن نعرف مدى حساسية الحل الأمثل لافتراضات النموذج. ويسمى تحليل " What If " أيضاً بالتحليل الحسي أو المعلمي (Sensitivity or Parametric Analysis).

اما عيوب نماذج التحسين تتلخص:[7، 14]

- 1- إمكانية سوء توصيف صياغة المشكلة الحقيقية بسبب كون المشكلات معقدة بشكل كبير وبما ان بناء الانموذج هي الخطوة الأكثر أهمية في النمذجة الرياضية فمن الممكن إساءة صياغة المشكلة الحقيقية. فقد يتم حذف متغيرات القرار أو العلاقات المهمة أو قد يكون النموذج غير مناسب للمشكلة مما يؤدي ان الحل الأمثل للمشكلة الخاطئة لا قيمة له.
- 2- عدم فهم دور النمذجة في عملية صنع القرار. إن الحل الأمثل للنموذج ليس بالضرورة هو الحل الأمثل للمشكلة الحقيقية. النماذج الرياضية هي أدوات تساعدنا على اتخاذ قرارات جيدة. ومع ذلك، فهي ليست العامل الوحيد الذي يجب أن يدخل في القرار النهائي. في بعض الأحيان يقوم النموذج بتقييم الحلول فقط فيما يتعلق بالمعايير الكمية. وفي هذه الحالات، يجب أيضاً أخذ العوامل النوعية في الاعتبار عند اتخاذ القرار النهائي. وعليه فإن الهدف من تحسين النموذج هي ما إذا كان يساعد صانع القرار على تحديد حلول أفضل وتنفيذها أم لا. إذ يجب أن يزيد النموذج من ثقة متخذ القرار في القرار واستعداده لتنفيذه.

3.3 الذكاء الاصطناعي ونماذج البرمجة الخطية: Artificial Intelligence and Linear Programming Models

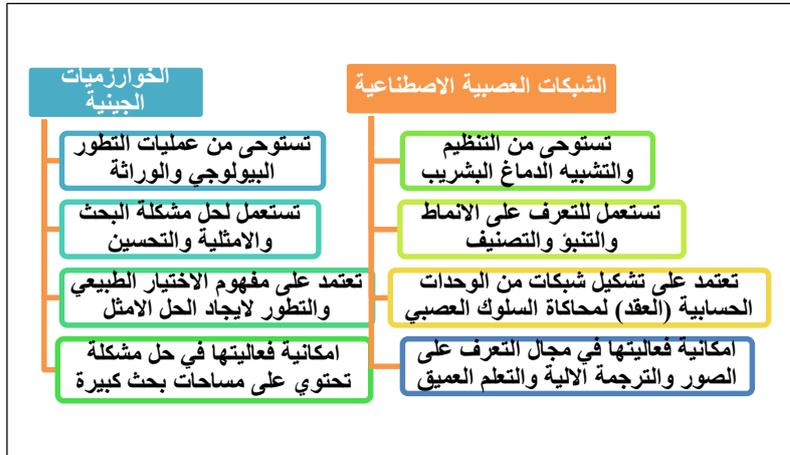
تهتم كل من منهجيات الذكاء الاصطناعي (Artificial Intelligence (AI)) ومنهجيات بحوث العمليات (Operations Research (OR)) بتطوير تقنيات لحل المشكلات الرياضية الصعبة، لا سيما في مجال التخطيط والجدولة. وتتضمن مناهج الذكاء الاصطناعي (AI) على مجموعة غنية من صيغ تمثيل النماذج للتعامل مع مجموعة واسعة من المشكلات الواقعية. على سبيل المثال نماذج البرمجة المقيدة، والنماذج المنطقية، ولغات البرمجة البيانية والدالية مثل Prolog وLisp، والنماذج Bayesian، والصيغ القائمة على القواعد، وما إلى ذلك. الجانب السلبي لهذه الصيغ هو أنها تؤدي بشكل عام إلى مشاكل مستعصية، من ناحية أخرى، ركزت منهجيات بحوث العمليات على صيغ أكثر سهولة، مثل تركيبات البرمجة الخطية (LP). إذ أثبتت التقنيات المعتمدة على LP القدرة على تحديد الحلول المثلى للمشكلات المحددة جيداً. بشكل عام، فإن توفر تقنيات الذكاء الاصطناعي صيغ متنوعة وذات مرونة عالية لمشاكل معقدة، كما وتدعم آليات التفكير الفعالة القائمة على القيود فضلاً عن ذلك هيكله القيود المختلفة. ويمكن التحدي في تقديم صيغ معرّفة بما يكفي لوصف المشكلات الحقيقية وفي نفس الوقت ضمان حلول جيدة وسريعة. يقدم الشكل (1) تصور دقيق المستوى لمفهوم تكامل الذكاء الاصطناعي وOR.[15]

الطرائق الرئيسية لنماذج LP تشمل على برمجة الأعداد الصحيحة (Integer Programming (IP)) وبرمجة الأعداد الصحيحة المختلطة (Mixed Integer Programming (MIP)) والبرمجة العشوائية (Stochastic Programming (SP)). تعد طرائق IP وMIP الأكثر شيوعاً للتعامل مع قيود محددة والقيود الفرعية المتصلة بها. أما البرمجة العشوائية (SP) تعالج المواضيع المتعلقة بعدم اليقين (حالة عدم التأكد) وتتطلب البرمجة العشوائية (SP) حل العديد من نماذج LP التي تمثل سيناريوهات مختلفة في المستقبل، إذ يمكن تحديد أفضل مسار للمشكلة في الوقت الحاضر من خلال تحسين الأداء المتوقع للسيناريوهات المختلفة. وتعد الثنائية Duality احد النماذج المهمة في بحوث العمليات (OR) ويمثل نموذج مشتق ويسمى بالنموذج المقابل (Dual Model) لنموذج البرمجة الخطية (LP) الأصلي والذي يسمى بالنموذج الأولي (Primal Model)، الفكرة الأساسية هي ان كل مشكلة يمكن النظر إليها من منظور ثنائي (تعظيم الربح يقابله تقليل التكاليف) اي ان كل مشكلة تعظيم في (LP) يقابلها مشكلة تصغير بالتالي فهي مشكلة ثنائية. وتمتاز (Duality) بسهولة الحصول على الحل الأمثل وكذلك الحصول على نموذج يحتوي على عدد قليل من القيود إضافة الى التخلص من الاشارة السالبة من المصادر في الجانب الايمن (ان وجد). ويتم استعمال النموذج المقابل (Dual Model) عندما يراد دراسة التأثير على دالة الهدف في حالة اختلاف مستوى الموارد او في حالة كون معاملات دالة الهدف في النموذج الاصلي متغيرة وتسمى هذه الخاصية تحليل الحساسية (Sensitivity Analysis).

ان الربط بين الذكاء الاصطناعي (AI) ومشاكل البرمجة الخطية (LP) يمكن من خلال استعمال تقنيات الذكاء الاصطناعي بشكل أكثر فاعلية. إذ تعد تقنيات الذكاء الاصطناعي مثل الخوارزميات الجينية (Genetic Algorithms) والشبكات العصبية الاصطناعية (Artificial Neural Networks) والبحث الذكي (Intelligent Search) تساهم في حل مشكلة البرمجة الخطية بشكل أكثر فاعلية ودقة، مثلاً يمكن استعمال (GA) في البحث عن الحل الأمثل لمشاكل البرمجة الخطية، ويمكن استعمال (ANN) لتحسين الاداء وتسريع عمليات الحساب. ويعتمد الذكاء الاصطناعي (AI) على منهجية التعلم الآلي (Machine Learning) والذي يهتم بتطوير تقنيات الحاسوب من خلال تعلم البيانات واكتساب معرفة دون الحاجة الى برمجة صريحة مما يساهم في اكتساب الخبرة وتحسين الاداء مع الوقت. اما بالنسبة للتعلم العميق (Deep Learning) هو احد فروع التعلم الآلي (Machine Learning)

ويستخدم في الشبكات العصبية الاصطناعية (Artificial Neural Networks) متعددة الطبقات لفهم وتحليل البيانات ، وتعتمد تقنيات التعلم العميق (DL) على تدريب النماذج العصبية على مجموعة كبيرة من البيانات لتحسين الاداء في تحليل الصور والصوت والنصوص.[16, 17]

- ولحل مشكلة البرمجة الخطية (LP) باستعمال التعلم الآلي (ML) والتعلم العميق (DL) من خلال اتباع الخطوات الاتية:[16]
1. **تحديد المشكلة (Identify Problem):** يجب تحديد المشكلة بدقة ووضوح، اي تحديد دالة الهدف والقيود المتعلقة بها.
 2. **تحويل المشكلة (Transformation Problem):** لحل مشكلة البرمجة الخطية يجب تحويل الى صيغة رياضية مناسبة قابلة للتطبيق في اطار التعلم الآلي والتعلم العميق.
 3. **تدريب النماذج (Train Model):** يتم تدريب النماذج العصبية الاصطناعية (NA) او الخوارزميات الجينية (AG) على مجموعة البيانات التي تمثل المشكلة الخطية المحددة.
 4. **تقييم الاداء (Evaluate Model):** يتم التقييم اداء النماذج وقياس قدرته على حل المشكلة الخطية بدقة عالية وفعالية.
 5. **ضبط النموذج (Tune Model):** تحسين النموذج وضبطه لتحقيق اداء افضل في حل المشكلة.
 6. **تطبيق النموذج (Apply Model):** بعد تدريب وضبط النموذج ، يمكن استعماله لحل مشكلة البرمجة الخطية بشكل فعال .
- ان الفرق بين الخوارزميات الجينية (AG) والشبكات العصبية الاصطناعية (ANN) يمكن تلخيصه كما في الشكل (1) الاتي:



شكل (1): الفرق بين الشبكات العصبية الاصطناعية والخوارزميات الجينية

ان عملية اختيار اي من التقنيات الذكاء الاصطناعي (AI) تستعمل في حل مشكلة البرمجة الخطية فيرجع ذلك الى السياق والمتطلبات المحددة للمشكلة، ومن خلال الشكل (1) قد تكون الخوارزميات الجينية (AG) الاختيار الافضل اذا كانت المشكلة تتطلب حلاً دقيقاً ودورياً لمشكلة البرمجة الخطية (LP) اما اذا كانت مشكلة (LP) معقدة وتحتاج الى تعلم من البيانات والانماط فان الشبكات العصبية الجينية (ANN) قد تكون مفيدة. واستناداً لما تقدم سيتم استعمال الخوارزميات الجينية (GA) في عملية التحسين وايجاد الحل الامثل لمشكلة البرمجة الخطية.

4.3 الخوارزمية الجينية (Genetic Algorithm Programming (GAP)) :

هي تقنية حسابية تطويرية (Evolutionary Computation (EC)) تعمل على حل المشكلات تلقائياً دون الحاجة الى تعريف الكمبيوتر بكيفية القيام بذلك. از تعد GA طريقة منهجية مستقلة تجعل أجهزة الكمبيوتر تحل المشكلات تلقائياً . از اجتذبت GA في العقد الماضي اهتمام الباحثين في جميع أنحاء العالم. يهدف هذا الفصل إلى تقديم لمحة وتلخيص العمل المهم الذي أعطى التوجيه والزخم للبحث. ولبناء نموذج الخوارزمية الجينية يشترط أن يتم توفير مشكلة قابلة للحل از تعد الخوارزمية الجينية طريقة إرشادية وتقنية تحسين (Optimization) لحل مشكلة البرمجة الخطية من خلال محاكاة عملية التطور الطبيعي. مبدأ الانتقاء الطبيعي (Natural Selection) هو القدرة على التحمل والتكاثر حسب الافضلية للأفراد بسبب الاختلافات في النمط الظاهري. وهو الآلية الرئيسية للتنمية، والتغيير في السمات الأبوية للسكان مع مرور الوقت. وعليه يجب معرفة بعض المصطلحات الخاصة بمفهوم الخوارزمية الجينية.[15, 16]

- الكروموسوم **Chromosome**: مجموعة من الجينات تحتوي على الحل على شكل جينات.
- الجين **Gene**: الجين جزء من الكروموسوم ويحتوي الجين على جزء من الطول. وهو يقيم الحل. مثال: 13426 هو كروموسوم ثم 1,3,4,2 و 6 هي جيناته.
- الفرد **Individual**: يشابه الكروموسوم.
- السكان **Population**: عدد الأفراد الموجودين بنفس طول الكروموسوم.
- مساحة البحث: عندما نحل أي مشكلة، نريد معرفة بعض هذه الحلول التي تعد الأفضل من بين الحلول الأخرى. لذا فإن المساحة المخصصة لكل الحلول الممكنة تسمى مساحة البحث.
- (اللياقة) **Fitness**: هي قيمة مخصصة للفرد وتعتمد على مدى بعد الفرد أو قربه من الحل.
- دالة اللياقة **Fitness function**: دالة لتقييم مدى قرب الحل المعطى من الحل الأمثل للمشكلة المطلوبة. وهي مهمة فهي تعد دالة ربط بين المشكلة والخوارزمية . وكلما كانت قية الدالة كبير فهذا يعني كفاءة الكروموسوم اكبر.

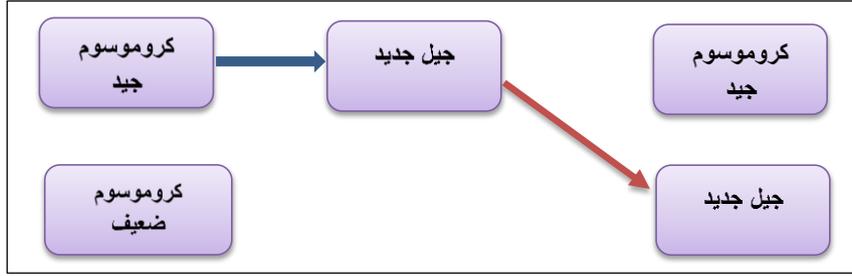
- التطور: اختيار الأفراد لتكوين الجيل القادم.
 - إعادة التركيب أو العبور الكروموسومي **Recombination or crossover**: الجينات من الوالدين تشكل بطريقة ما الكروموسوم الجديد بالكامل.
 - الترميز **Encoding**: تسمى العملية المستخدمة لتمثيل الحل في شكل سلسلة بالترميز وهو يحمل المعلومات الضرورية. وكما هو الحال في الكروموسوم، يمثل كل جين خاصية معينة للحل.
 - طريقة الترميز **Encoding method**: هناك عدة طرق للترميز، ولكن في الخوارزمية الجينية الطريقة الأكثر استخداماً للترميز هي الترميز الثنائي. الكروموسومات عبارة عن سلسلة من 1 و 2. يمثل كل موضع في الكروموسومات خاصية معينة للمشكلة .
 - الطفرة **Mutation**: تطور ذرية جديدة في كل نقطة (موضع في الكروموسوم).
- 5.3 عامل الاختيار (اختيار الوالدين) ، العبور و الطفرة Operator Selection, Crossover and Mutation :**
يقصد بالاختيار هو العملية التي تحدد الحلول التي يجب الحفاظ عليها والسماح لها بالتكاثر وكذلك تحديد الحلول التي تستحق الاستبعاد. الهدف الرئيس من الاختيار هو إعطاء أهمية للحل الجيد والقضاء على الحل السيئ في مجتمع حيث يكون حجم السكان ثابتاً. اختر الأفضل وتجاهل الباقي.
ويوجد العديد من التقنيات لتطبيق اختيار العوامل منها :

- 1- اختيار المباراة (المنافسة) **Tournament Selection**: في تقنية اختيار المباراة ، يتم لعب العديد من المباريات بين بعض الأفراد. إذ يتم أخذ الأفراد بشكل عشوائي من السكان واختيار الفائز في كل مباراة للجيل القادم. صعوبة الاختيار يختلف وفقاً لحجم المباراة فإذا كانت المباراة صغيرة فإن ضغط الاختيار سينخفض أيضاً والعكس صحيح، أما إذا كان حجم المباراة كبيراً، فإن الأفراد الضعفاء سيكون لديهم فرص ضئيلة للاختيار في جيل السكان القادم.
- 2- عجلة الروليت (عجلة الحظ) والاختيار المتناسب **Roulette wheel and proportionate selection** :
يتم اختيار الآباء وفقاً لقيم اللياقة (مدى بعد الفرد أو قربه من الحل) . إذ تتمتع الكروموسومات الأفضل بفرص أكبر للاختيار. أما خطوات الطريقة فهي :
- يتم تجميع قيم اللياقة (المجموع الكلي)
- يتم توليد ارقام عشوائية محصورة بين الصفر والمجموع الكلي لقيم اللياقة.
- وتحسب نسبة عجلة الروليت $RW\%$ من (حاصلة قسمة قيمة اللياقة (Fitness Value) لكل كروموسوم على المجموع الاجمالي لقيم اللياقة لجميع الكروموسومات $i=1,2,\dots$ وكما مبين ب(الجدول 2) :

جدول (2) : يبين آلية حساب عجلة الروليت (عجلة الحظ)

العدد الحقيقي Actual count	العدد المتوقع Expected count	% من عجلة الروليت % Of roulette wheel	قيمة اللياقة Fitness Value	الكروموسومات Chromosomes
2	2.61	25.46	55	1
0	0.19	5.09	11	2
1	2.16	18.98	41	3
1	0.97	16.2	35	4
1	2.16	18.98	41	5
1	0.90	15.27	33	6
			216	المجموع

- وعندما تتباين قيم الكروموسومات بشكل كبير، تحدث مشاكل أكبر في تشكيل عجلة الروليت وفقاً لقيم اللياقة. على سبيل المثال، إذا كان الكروموسوم الأفضل يتمتع بقيمة لياقة أكبر وإذا كانت نسبة RW لهذا الكروموسوم 90%، فإنه سيشغل محيط 90% من RW وستكون فرص اختيار الكروموسومات الأخرى أقل. عندها يتم استعمال تقنية اختيار الرتبة (Rank Selection) ويستند على تصنيف السكان وفقاً لقيمة اللياقة ثم يقوم بتعيين رتبة لكل كروموسوم وفقاً لقيمة اللياقة . الكروموسوم الذي يتمتع بقيمة لياقة عالية للغاية سيحصل على المرتبة الأولى والكروموسوم التالي سيحصل على المرتبة الثانية وهكذا. [14,15]
- 3- اختيار الحالة المستقرة **Steady state selection**: في اختيار الحالة المستقرة، يتم أولاً أخذ الجزء الأكبر من السكان ثم يتم اختيار عدد قليل من الكروموسومات الجيدة لإنشاء ذرية جديدة في كل عملية. لذلك يتم استبعاد بعض الكروموسومات الضعيفة ويتم وضع ذرية جديدة مكانها ويهاجر باقي السكان إلى الجيل التالي. وكما مبين في (الشكل 2).



شكل (2): يبين تقنية اختيار الحالة المستقرة لاختيار العوامل

6.3 العبور الكروموسومي Crossover: [22,21]

بعد تطبيق تقنيات عامل الاختيار لإنشاء حلول جديدة من الحلول الموجودة المتوفرة يعد ترميز الحل امرأ ضروريًا، لذلك تظهر الحلول شبيهة بالكروموسوم ويعمل عامل التقاطع (Crossover Operator) على مستوى الافراد، كل فرد في المجتمع هو نقطة في مساحة البحث. بشكل عام، يتم تمثيل الفرد كسلسلة Bit بطول n (اذ يمثل n الجيل $n=0,1,2,\dots,N$). وبالتالي يمثل كل فرد نقطة واحدة في مساحة بحجم 2^n . واستناداً الى سلسلة Bit، تنتج الخوارزمية الجينية ذرية (اطفال Children) باستخدام العوامل الجينية المتقاطعة والطفرة (Mutation). [13] وتأتي الطفرة مباشرة بعد العبور الكروموسومي، اذ تعمل الطفرة على مستوى Bit عن طريق التدوير العشوائي لـ Bits ضمن المجموعة الحالية. ولتوضيح ذلك يتم اختيار نقطة التقاطع (العبور) بشكل عشوائي لشخصين (زوج) يتم اختيارهما عشوائيًا يطلق عليهم (الوالدين Parents). تعمل نقطة العبور الى تقسم كل فرد الى قسمين يسار ويمين ولنفترض ان نقطة العبور تحدث بشكل عشوائي عند $Bit=6$. يقوم Crossover بعد ذلك بتبديل القسم الأيسر (أو الأيمن) من الشخصين اذ يحصل كل طفل على نصف جزء الوالدين الاخرين. وكالاتي:

Parent 1: 110110|0001110011

Child 1: 110110|1011110010

Parent 2: 001010|1011110010

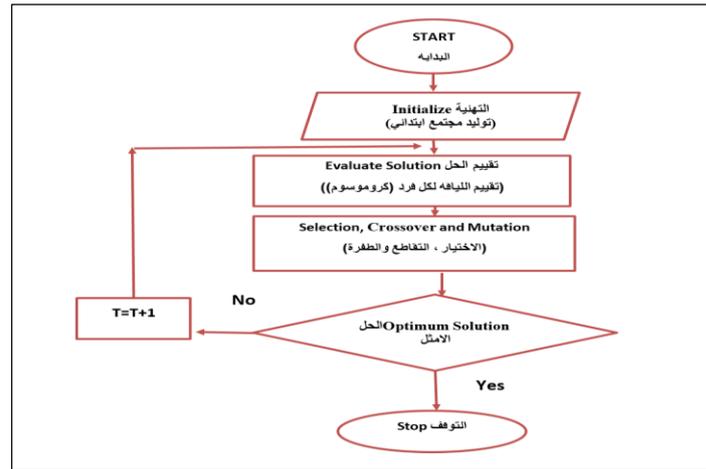
Child 2: 001010|0001110011

وتعمل الطفرة (Mutation) على إدخال خصائص جديدة في سلسلة الحل من السكان للحفاظ على التنوع في السكان. بينما يتحمل التقاطع المسؤولية الرئيسية في البحث عن الحل الأمثل (Optimum Solution) ويتم استخدام الطفرة لهذا الغرض.

Before: 1101100001110011

After: 1101110001110011

الطفرة اعلاه تسمى عامل الطفرة الثنائية (Binary mutation operator) يتحول بها 0 الى 1 والعكس صحيح. بعد تنفيذ عامل الطفرة والتقاطع في السكان يتم تدمير بعض أفضل الحلول للمجتمع والتي يطلق عليها النخبة (Elitism) وذلك نتيجة لعشوائية الكثير من العمليات والنخبة تعني الحفاظ على أفضل الحلول لتجمع السكان ويمكن تعيين النخبة كنسبة مئوية أو عدد. ثم يتم وضع جيل جديد في المجموعة السكانية الجديدة وهي مقبولة (Acceptance)، [9], [11]، ويتم استخدام الجيل السكاني الجديد لتشغيل الخوارزمية مرة اخرى ويطلق على هذه المرحلة بالاستبدال (Replace). ويمكن تلخيص العملية بالمخطط الانسيابي في شكل (3).



4. العمل التجريبي أو التطبيقي / استعمال الخوارزمية الجينية لحل مشكلة البرمجة الخطية 1.4 اجراء تجربة المحاكاة :

لاجراء عملية التحسين (Optimization) على مشكلة البرمجة الخطية باستعمال الخوارزمية الجينية تم الاستعانة ببرنامج (MATLAB R2019a) اذ تم تطبيق مشكلة البرمجة الخطية المذكور آنفأ، اذ تم الحصول على الحل الامثل باستعمال طريقة Simplex method، وكالاتي معادلة (8) :

$$\text{Maximize } z = 0.65M + 0.45Y$$

(8)

$$s. t. 2M + 3Y \leq 400000$$

$$3M + 1.5Y \leq 300000$$

$$M \leq 90000$$

$$M, Y \geq 0$$

الحل الأمثل لمشكلة أغذية الحيوانات من اللحوم هو $M=50000$ و علب الاغذية الصحية $Y=100000$ بالتالي فإن الارباح الشهرية ستبلغ (دالة الهدف) $z=77,500$ \$. تم تطبيق الخوارزمية الجينية (GA) وترميز متغيرات القرار كسلسلة ذات طول محدد (عدد صحيح ثنائي (1-0)) على نطاق الاعداد الصحيحة والمحصورة بين (0-31) بطول (Bit-5) والهدف تعظيم الدالة (Z) بوجود المجتمع السكاني الابتدائي والذي يتم اختياره بشكل عشوائي .

الخطوة 1: ترميز متغيرات القرار كسلسلة ذات طول محدد لاستخدام الخوارزمية الجينية. يتم ترميز المتغير x كعدد صحيح ثنائي بطول خمسة بتات (رقم ثنائي)، يمكننا الحصول على أرقام بين 0(00000) و 31(11111).

الخطوة 2: يتم اختيار مجتمع السكان الابتدائي بشكل عشوائي في شكل سلاسل ثنائية. يتم تحويل هذه السلاسل إلى القيم العشرية المقابلة لها لحساب قيمة دالة اللياقة المقابلة لكل من متغيرات القرار (M, Y). وتم تنفيذ برنامج المحاكاة لتجربة وفق المعطيات الآتية

- التعداد السكاني للكروموسومات = 75

- عدد الأجيال (عدد التكرار) = 50

- نسبة العبور الكروموسومي = 50

- نسبة الطفرة = 9%

- عدد البتات لكل كروموسوم = 5 Bit.

اذ لا يوجد قانون محدد لتعيين هذه القيم، فبإمكاننا اختيار قيم أخرى حسب طبيعة المشكلة وتعقيدها دون أن يؤثر على نتائج الخوارزميات. تتركز الاهمية في اختيار دالة اللياقة (Fitness Function)، اختيار هذه الدالة مرتبط بفعالية الخوارزمية التي لا تتوفر معلومات عن طبيعة المشكلة إلا عن طريق دالة اللياقة وما تتطلبه من ضوابط اذ يجب أن تعكس هذه الدالة وبكل دقة طبيعة المشكلة المدروسة:

2-3: المشكلة المدروسة:
قبل عرض الدالة التي تم اختيارها لنحدد بعض المتغيرات والثوابت ضمن مشكلة البرمجة الخطية كما مبين ب(الجدول 1 ادناه:-

جدول (3): تفاصيل مشكلة البرمجة الخطية

الرمز	التفاصيل	الرمز	الكمية	الرمز	التفاصيل
PS	سعر شراء الحبوب شهرياً	PM1	\$ 400000		سعر بيع علبه اللحوم الواحدة \$2.80
PM	سعر شراء اللحوم شهرياً	PS1	\$ 300000		سعر بيع علبه الغذاء الصحي الواحدة \$ 2
nY	عدد العبوات من الاغذية الصحية المنتجة شهرياً	MaxA	100000		الحد الاقصى للماكنة لانتاج العبوات اللحم 90000 علبه
nM	عدد العبوات من اللحوم المنتجة شهرياً		50000		

وعليه يمكن حساب دالة اللياقة (Fitness Function) وفق العلاقة (9) الآتية :

$$Fitness = \left(\frac{Value}{(Total Value - Max_A)^2 + 1} \right) \quad (9)$$

وان القيمة المالية للعبوات يمكن احتسابها في المعادلة (10):

$$Value = ((n_Y) \times P_{S1} + (n_M) \times P_{M1}) \quad (10)$$

والقيمة المالية الاجمالية تحتسب بالمعاد (11):

$$Total Value = (n_Y) \times P_S + (n_M) \times P_M \quad (11)$$

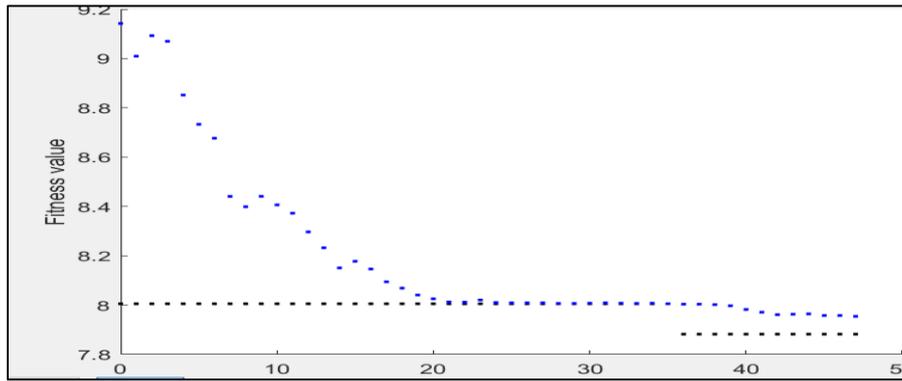
وبعد تنفيذ تجربة المحاكاة كانت النتائج كما مبينة ب(الجدول 4) :

جدول (4) : نتائج تجربة المحاكاة لتحسين دالة الهدف باستعمال الخوارزمية الجينية

التسلسل	Z	Y	M	التسلسل	Z	Y	M
1	77940	100000	50670	26	77550	100000	50070
2	77640	100000	50220	27	80640	100000	54830
3	77600	100000	50160	28	78310	100000	51250
4	77550	100000	50070	29	78460	100000	51470
5	80840	100000	55150	30	78000	100000	50770
6	77500	100000	50010	31	77510	100000	50020
7	78200	100000	51070	32	78040	100000	50830
8	77550	100000	50080	33	77790	100000	50450
9	77930	100000	50660	34	78490	100000	51520
10	77540	100000	50070	35	78100	100000	50920
11	78080	100000	50900	36	77580	100000	50120

12	77630	100000	50200	37	78840	100000	52070
13	79100	100000	52460	38	78490	100000	51520
14	77630	100000	50200	39	78350	100000	51300
15	78060	100000	50860	40	78720	100000	51880
16	78080	100000	50890	41	78320	100000	51270
17	77520	100000	50030	42	77980	100000	50740
18	78070	100000	50880	43	78920	100000	52180
19	77710	100000	50320	44	78610	100000	51700
20	77740	100000	50370	45	78280	100000	51200
21	77990	100000	50760	46	78180	100000	51050
22	77900	100000	50620	47	77910	100000	50630
23	77930	100000	50660	48	80040	100000	53910
24	78160	100000	51020	49	77720	100000	50340
25	77630	100000	50210	50	77560	100000	50100

من خلال النتائج التي تم التوصل لها في جدول (4) فإن التحسين (Optimization) لدالة الهدف باستعمال الخوارزمية الجينية (GA) عندما تكون عدد عبوات اللحوم (55150) وعدد عبوات الغذاء الصحي (100000) اذ ان دالة الهدف حققت اعظم ربح لها بلغ (80840) الف دولار شهرياً وهي اعلى من المتحقق باستعمال طريقة السملكس والبالغة (77500) الف دولار شهرياً، ويلاحظ ان عدد عبوات الغذاء الصحي كانت ثابتة عند الحد 100000 وذلك لان الحد الاعلى للماكنة انتاج اللحوم هو 90000 فان الحد الاقصى يبقى ثابت بالنسبة لعدد عبوات الاغذية الصحية وهو (100000) الف عبوة. كما ان افضل دالة لياقة تم حسابها كما(في الشكل 4) ادناه :-



شكل (4) : افضل دالة لياقة عند (M=55150)

5. المناقشات :

- 1- أن افراد السكان متمثلة بالكروموسومات (المشاهدات) يمكن تطبيقها على طرائق الخوارزمية الجينية GAS التي تم ذكرها سابقا، على الرغم من الاختلافات بين الطرائق GAS. وهذا يدل على عمومية المشاهدات . اذ ان جميع طرائق الخوارزمية الجينية GAS قوية فيما يتعلق بالعديد من تفاصيل التنفيذ.
- 2- تتطلب الأنواع المختلفة من المشكلات عادةً صياغة مختلفة، مثل تحديد الجينات والكروموسومات، وتقييم اللياقة البدنية، وما إلى ذلك. وبعض المشكلات لها قيود أكثر من غيرها. وفي العديد من مشاكل العالم الحقيقي، فإن الحصول على حل شبه مثالي أفضل من عدم وجود حل على الإطلاق. اذ ان تطبيق الذكاء البشري للتوصل إلى افضل حل استناداً الى الحل الأولي الذي تقدمه الخوارزمية الجينية.

6. الاستنتاجات :

- ان اهم الاستنتاجات التي تم التوصل اليها تتلخص بالاتي :
- 1- عندما يتم تطبيق الخوارزمية الجينية على المشكلة قيد الدراسة، يتم إنتاج سلسلة من الحلول وعند جيل معين يحصل على القيمة الأكبر للكروموسوم الأول أي M=55150 مقارنة بالكروموسوم السابق والذي بلغ M=50000. وتعد فائدة ملحوظة لاستخدام الخوارزمية الجينية. أفضل لياقة، وأفضل فرد، وأفضل الرسوم البيانية للاختيار يتم تحديدها من خلال الخوارزمية الجينية.
 - 2- على الرغم من حدوث تحسينات سريعة في الأداء مع حجم سكاني أصغر، إلا أن وجود عدد أكبر من السكان يساعد الخوارزمية الجينية على إيجاد حلول أفضل. يحدث هذا بسبب التراكم البطيء للإحصائيات الأكثر دقة عند استخدام عدد أكبر من السكان. ومن الواضح أن التراكم السريع للإحصائيات الدقيقة من شأنه أن يسمح بأفضل النتائج.

3- إمكانية استخدام الخوارزميات الجينية لحل مجموعة واسعة من مشاكل التحسين وتوجد خوارزميات مختلفة لكنها تتبع نفس الإجراء القياسي. إذ تُستخدم عملية "التجربة والخطأ" أيضًا بشكل كبير في تحديد معالم GA المختلفة، بما في ذلك حجم السكان واحتمال التقاطع واحتمال الطفرة.

المصادر:

- [1] Abdul Ameer, Y. R., Salman, Sh. M. and Kamel, A., (2022). "A hybrid algorithm to bypass some weak features in the particle swarm and firefly algorithms...with an application to the travelling salesman problem". Tikrit Journal of Administrative and Economic Sciences; Vol. 18, No. 60, Part (1): 635-652.
- [2] Bergkvist. A, Damaschke, and L. Marcel. (2006), "Linear Programs for Hypotheses Selection in Probabilistic Inference Models", Journal of Machine Learning Research 7 (2006) 1339–1355.
- [3] Datta, C. Garai, C. Das, (2012), "Efficient Genetic Algorithm on linear programming problem for fittest Chromosome", Journal of Global Research in Computer Science, Vol , pp T – 7.
- [4] De Jong, K. A. (1975). "An Analysis of the Behavior of a Class of Genetic Adaptive Systems", Doctoral dissertation, Dept. Computer and Communication Sciences, University of Michigan, Ann Arbor.
- [5] G.B. Dantzig, (1963), "Linear programming and extensions", Princeton University Press and the Rand Corporation.
- [6] H. Md. Azamathulla , Fu-Chun Wu, Aminuddin Ab Ghani. (2008), "Comparison between genetic algorithm and linear programming.", Journal of Hydro-environment Research 2 (2008) 172e181.
- [7] Hadi, H. A. and Shaheed, A. S.(2020)" Using the Expectation Maximization Algorithm in Estimating the General Linear Regression Model When the Data Are Distributed Skew Normal with The Application". The Journal of Administration & Economics, Issue: 124/June/2020, Pages: 186-200.
- [8] Haupt, R. L., & Haupt, S. E. (1998). "Practical Genetic Algorithms". New York: Wiley Inter science.
- [9] Frederick S. Hillier, Gerald J. Lieberman., "Introduction to operations research", 9th ed. p. cm. Includes index. ISBN 978-0-07-337629-5 .
- [10] Holland, J.H. (1992), "Genetic Algorithms". Scientific American, 267, 66-72. <http://dx.doi.org/10.1038/scientificamerican0792-66>.
- [11] Lewis, (2008), "Linear Programming: Theory and Applications, <https://www.whitman.edu/lewis>.
- [12] M. Joao, C. Eernsto, M. Lino (2016), "Genetic Programming Algorithms for Dynamic Environments", doi.org/10.1007/978-3-319-31153-1_19.
- [13] Malasri, S., "Genetic Algorithms," Cagill's Survey of Science: Applied Science, Supplement, pp. 3050-3057, May 1998.
- [14] Malasri, S., Martin, J. R., and Medina, R. A. (1996), "Solving Mathematical Programming Problems Using Genetic Algorithms", Proceedings of the Third Congress on Computing in Civil Engineering, ASCE, pp. 233-239.
- [15] Markland, Robert. (1989), "Topics in Management Science", 3rd ed., New York: Wiley. (16)
- [16] Michalewicz, Z. (1992) "Genetic Algorithms + Data Structures = Evolution Programs", Springer-Verlag.
- [17] N. Karmarker, (1984), "A New Polynomial Time Algorithm for Linear Programming", Combinatorica, Vol 4, nr. 4, p. 373–395.
- [18] Ravindran, A., Don. T. Philips, and James J. Solberg. (1986). "Operations Research: Principles and Practice, 2nd ed., New York: Wiley.
- [19] S.R. Hejazia, A. Memariania; *G. Jahanshaloob, M.M. Sepehri. (2002), "Linear bilevel programming solution by genetic algorithm", Computers & Operations Research 29 (2002) 1913–1925 .
- [20] Singh1.S, Damaschke, and L Mehrotra.R. (2017), "GENETIC ALGORITHM: APPLICATIONS TO LINEAR AND INTEGER PROGRAMMING PROBLEMS", International Journal of

Research in Engineering and Applied Sciences (IJREAS), Vol. 7 Issue 9, September-2017, pp. 48~58 ISSN (O): 2249-3905, ISSN(P): 2349-6525 | Impact Factor: 7.196.

- [21] Steven J. Miller, (2007),” An Introduction to Linear Programming”, Mathematics Department, Brown University.
- [22] Whitley, D., K. Mathias, S. Rana, and J. Dzuber. (1996), “Evaluating Evolutionary Algorithms”. Artificial Intelligence Journal 85:1–32.
- [23] Winston, Wayne L. (1991), “Operations Research: Applications and Algorithms”, 2nd ed., Boston: PWS-Kent.



**Journal of Administration
& Economics**

**Mustansiriyah
University**

**College of
Administration &
Economics**

P-ISSN: 1813 - 6729

E- ISSN: 2707-1359

**Improving Linear Programming via Artificial Intelligence Techniques: An
Experimental Study**

Muna Shaker Salman

Dep. of Accounting Techniques, Technical Institute- Suwaira, Middle Technical University, Iraq

Email: muna.shaker@mtu.edu.iq, ORCID ID: <https://orcid.org/0000-0002-6664-8411>

Article Information

Article History:

Received: 7 / 2 / 2024

Accepted : 7 / 3 / 2024

Available Online: 22 / 7 / 2024

Page no : 56 – 68

Keywords:

Linear Programming , Genetic Algorithm Artificial Intelligence , Machine Learning , Deep Learning

Correspondence:

Researcher name:

Muna Shaker Salman

Email:

muna.shaker@mtu.edu.iq

Abstract

Operations research is one of the main fields in management sciences and industrial engineering. One of the most important of these fields is Linear Programming, which includes essential techniques, including: (improving production processes through applying techniques and tools such as network analysis, principal factor analysis, and regression analysis, in addition to designing... Models for improving the supply of primary resources, planning and controlling supply chains, and improving data analysis techniques and artificial intelligence in making strategic decisions, such as Big Data, Machine Learning, and Deep Learning. Linear programming techniques also contributed to improving quality and risk management by reducing risks associated with operations, such as total quality management, experiment design, risk analysis, and designing flexible systems to help innovate and develop products. Techniques for linking linear programming with artificial intelligence are of great importance, as they have helped develop systems and technologies that are characterised by the ability to learn, think, and make decisions like humans, for example (using artificial intelligence to improve planning and analysis processes in linear programming problems). In our study, one of the artificial intelligence techniques in linear programming was highlighted: the Genetic Algorithm (GA). The research aims to find the optimal values for the variables of the objective function in light of the restrictions imposed on a specific linear programming problem and, through optimisation, the value of the function. The objective achieved the most excellent profits compared to the objective function calculated within the Simplex Method. The fitness function was also calculated based on the data in the problem, and the results were found using the MATLAB R2019a program.