

Intelligent Control of Automated Driving Systems in Vehicles Using Neural Networks and Genetic Algorithm

Dr. Bilal Chiha*
Zenab Bosheah**

(Received 4 / 1 / 2022. Accepted 13 / 2 / 2022)

□ ABSTRACT □

Evolutionary neural networks are a form of machine learning that uses genetic algorithms to train a neural network by estimating neural network weights, optimization of learning rules, as well as optimization of neural network architecture, thus obtaining more accurate and less human-dependent neural networks.

This research uses a genetic algorithm as an optimal way to choose the weights of the neural network in order to obtain the optimal steering angle for a self-driving car. Each car represents a different chromosome in the generation, in other words a unique set of neural network weights, which are evaluated and transmitted to the next generation by the fitness function (fitness score). The fitness function is the distance traveled by the vehicle along the path without colliding with the boundary of the path, so that the vehicle that stayed the longest period on the path is the best vehicle. The trained car was tested on several methods that differ from the training path, and according to different speeds, and the practical results proved the efficiency of the algorithm used to reach an appropriate steering angle.

Keywords: Genetic Algorithm, Neural Network, Self-driving vehicle.

*Associate Professor, Department of Computers and Control, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria. E-mail:(bilal.chiha@gmail.com)

**Postgraduate Student (Master), Department of computer and automatic control, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria. E-mail:(zenaboshea@gmail.com)

التحكم الذكي بنظم القيادة الآلية في العربات باستخدام الشبكات العصبية والخوارزمية الجينية

د. بلال شياح*

زينب بوشية**

(تاريخ الإيداع 4 / 1 / 2022. قَبْلَ للنشر في 13 / 2 / 2022)

□ ملخص □

تعتبر الشبكات العصبية التطورية شكل من أشكال التعلم الآلي الذي يستخدم الخوارزمية الجينية لتدريب الشبكة العصبية عن طريق تقدير أوزان الشبكة العصبية، وأمثلة قواعد التعلم، بالإضافة إلى أمثلة بنية الشبكة العصبية، وبذلك يتم الحصول على شبكات عصبية أكثر دقة وأقل اعتماداً على الإنسان.

يستخدم هذا البحث الخوارزمية الجينية كطريقة مثلى لاختيار أوزان الشبكة العصبية بهدف الحصول على زاوية التوجيه المثلى لعربة ذاتية القيادة، حيث تمثل كل عربة كروموسوم مختلف في الجيل، وبمعنى آخر مجموعة فريدة من أوزان الشبكة العصبية، والتي يتم تقييمها ونقلها إلى الجيل التالي عن طريق تابع اللياقة fitness score. تم اختيار تابع اللياقة ليكون المسافة التي تقطعها العربة على طول المسار دون اصطدامها بحدود المسار، وبذلك تكون العربة التي بقيت أطول مدة زمنية على المسار هي العربة الأفضل. تم اختبار العربة المدربة على عدة طرق تختلف عن مسار التدريب، ووفق سرعات مختلفة وقد أثبتت النتائج العملية كفاءة الخوارزمية المستخدمة في الوصول إلى زاوية توجيه مناسبة.

الكلمات المفتاحية: الخوارزمية الجينية، الشبكات العصبية، عربة ذاتية القيادة.

*أستاذ مساعد - قسم الحاسبات والتحكم الآلي - كلية الهندسة الكهربائية و الميكانيكية -جامعة تشرين - اللاذقية -سورية.

E-mail:(bilal.chiha@gmail.com)

**طالبة ماجستير - قسم الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية و الكهربائية - جامعة تشرين - اللاذقية - سورية.

E-mail:(zenaboshea@gmail.com)

مقدمة:

يفقد الملايين من الناس حياتهم بشكل سنوي بسبب حوادث السير، ويواجه 20 إلى 50 مليوناً إصابات خطيرة مع بعض الإعاقات التي لا يمكن علاجها بسبب إصابتهم على الطرق. تحدث أكثر من 80% من الحوادث بسبب خطأ السائق [1] وهو خطأ غير قابل للقياس حيث يحدث بشكل غير متوقع، بالتالي فإن زيادة أمن الطرق من خلال تحسين الطرقات لن يساعد في حل هذه المشكلة، وقد توصل الباحثون إلى أن أفضل حل لتخفيف خطر أخطاء الإنسان هو استخدام نظم القيادة الذاتية أو نظم القيادة المساعدة [2].

وضعت جمعية مهندسي السيارات (SAE) ستة مستويات مختلفة من الاستقلالية autonomy تبدأ من المستوى 0 حيث يقوم السائق بجميع مهام القيادة، إلى المستوى الخامس، والاستقلالية الكاملة التي لا تتطلب أي تدخل بشري على الإطلاق. حالياً، تمتلك العديد من المركبات الفاخرة المستوى الثالث مثل التحكم النشط في الممر active lane control، وتتمتع بعض المركبات بالمستوى الرابع من الاستقلالية [3].

لا يزال المستوى الخامس من التحكم الذاتي في السيارات قيد البحث والتطوير، ويكمن العائق أمام الوصول إلى ذلك المستوى في صعوبة جمع البيانات التي تتضمن قواعد القيادة الآمنة. تكمن مشكلة التطبيقات الحالية للعربات ذاتية القيادة في الحاجة إلى قواعد بيانات كبيرة الحجم والحاجة إلى تقييم القيادة وفقاً لها. في هذا البحث، نقترح نظاماً لا يتطلب أي بيانات لتدريبه. حيث تم تطبيق التطور العصبي Neuroevolution، وهو شكل من أشكال الخوارزمية الجينية، لتدريب وتطوير العربات ذاتية القيادة، ويعتبر من المستوى الثاني من مستويات التحكم.

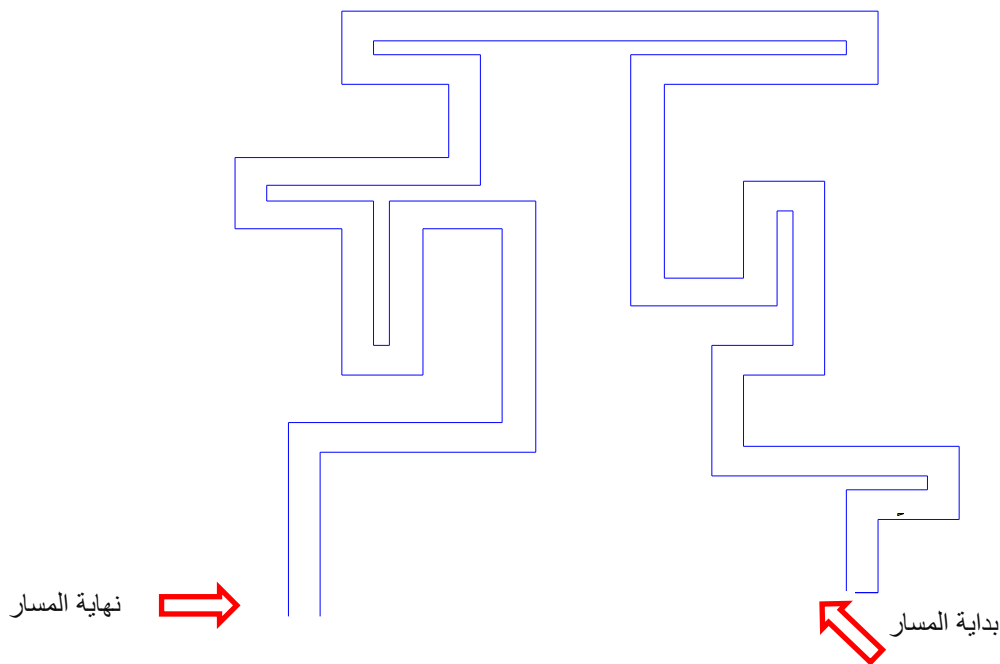
أهمية البحث وأهدافه:

يتعلم سائقي السيارات عملية التوجيه عن طريق التدريب المستمر والممارسة، وتكمن صعوبة القيادة في حالة السرعة العالية على الطرق الوعرة أو الطرق شديدة الانعطاف. على الرغم من أن السائق الماهر قد يسيطر على العربة في تلك الحالات، إلا أنه من الصعب على السائق العادي التحكم في العربة.

في هذا البحث، يتم تعلم عملية التوجيه عند الانعطاف باستخدام شبكة عصبية (NN) وخوارزمية جينية (GA).

طرائق البحث ومواده:

تمت المحاكاة باستخدام الماتلاب لعربة ذاتية القيادة على مسار شديد الانعطاف يمثل مجموعة من الحواف الأفقية والعمودية، موضح في الشكل (1).



الشكل(1): مسار التدريب لحركة المركبة [4].

1.1 الخوارزمية الجينية

هي إحدى أساليب الذكاء الاصطناعي، وبالتحديد فرع من فروع الحوسبة التطويرية، برزت أهمية هذا الأسلوب في إيجاد حلول للعديد من مسائل الأمثلة التي لم يكن بالإمكان إيجاد حلول لها في أزمنة معقولة مقارنة بالطرق التقليدية، استخدمت الخوارزمية الجينية لأول مرة في جامعة ميشيغان من قبل العالم Holland في العام 1975، ثم طورت وساهم في انتشارها العالم Goldberg في العام 1989 من خلال كتابه مقدمة في الخوارزميات الجينية [5]. تعتمد الخوارزمية الجينية (GA) على أفكار مستنبطة من نظرية داروين للتطور، وذلك من خلال محاكاة وتقليد التطور الطبيعي للأجيال في الكائنات الحية، حيث تعتمد الفكرة الأساسية على تحديد المتغيرات وإيجاد تمثيل مناسب لحل المشكلة قيد الدراسة من خلال عملية الترميز [6]. تبدأ فكرة عمل الخوارزمية بعملية التوليد العشوائي للمجتمع الابتدائي (Initial Population) الذي يتكون من عدد من الأفراد، وكل فرد (كروموسوم) يتكون من عدد من الجينات، ويمثل المجتمع بعض الحلول الممكنة للمشكلة. بعد ذلك يتم تقييم الحلول باستخدام تقييم اللياقة (Fitness evaluation) و انتقاء الحلول الأفضل من بينها، استناداً إلى مبدأ البقاء للأصلح من خلال قيمة اللياقة (Fitness value) التي ترتبط بدالة الهدف، وعادة ما تكون هذه الدالة إما تعظيم (Maximization) أو تقليل (Minimization) للمسائل المختلفة [7] الحلول الناتجة من عملية الانتقاء (Selection) يتم استخدامها في عملية التصلب (Crossover) أي خط الحلول المنتقاة لإنتاج حلول جديدة (جيل جديد) في محاكاة للتطور في الكائنات الحية، الحلول الناتجة من عملية التصلب تدخل أيضاً مرحلة التقييم و الانتقاء لمعرفة مدى اقترابها من الحل الأمثل. تستمر عملية التصلب والتقييم والانتقاء وتوليد الأجيال من خلال العمليات السابقة حتى يتحقق شرط الإيقاف الذي يحدده مصمم الخوارزمية، وعادة ما يكون عدد التكرارات أو العدد المطلوب من الأجيال أو الوصول إلى الحل الأمثل [7].

يمكن النظر الى الشبكات العصبية الاصطناعية على أنها مسألة أمثلة تبحث عن أفضل الأوزان لتحقيق بعض المهام، هذا هو السبب في أنه يمكن استخدام الخوارزمية الجينية لتدريب شبكة عصبية [8].

1.2. المتحكم العصبوني:

يقود المتحكم العربة بشكل مشابه للسائق العادي، يتحسس اتجاه وانحناء المسار، الدخول عبارة عن الانحراف الجانبي وزاوية الانحراف النسبية وانحناء المسار، أما الخرج عبارة عن زاوية التوجيه. المتحكم عبارة عن شبكة عصبونية بثلاث طبقات، إذا تمثل العربة شبكة عصبية خاصة بها، يتم تحديثها بواسطة خوارزمية التغذية الأمامية، الدخول عبارة عن المسافات بين العربة وحدود الطريق الجانبية والأمامية، لتكون طبقة الخرج عبارة عن عملية التوجيه، وبدلاً من استخدام خوارزمية الانتشار الخلفي back propagation في تعليم الشبكة العصبية، سنستخدم التعليم المعزز reinforcement learning، وسيتم تطبيق الخوارزمية الجينية على كل عربة. وحسب نظرية داروين في التطور:

العربة ذات الجينات الأفضل لها فرصة أكبر بالبقاء ونشر الجينات الى الجيل التالي.

تستخدم العربة عدة حساسات لمعرفة المسافات بين العربة وحدود الطريق، ليتم تغذية هذه القيم كمدخل الى الشبكة العصبية، ثم يتم تمريرها بعد المعالجة إلى طبقة الخرج المكونة من عصبونين: قوة توجيه يمين وقوة توجيه يسرى.

1.3. بنية الشبكة العصبية:

تم اختيار شبكة عصبية بدخل عبارة عن قيم الحساسات البالغ عددها 19 حساس، طبقتين مخفيتين بعدد عصبونات (18) في كل طبقة، وطبقة خرج مكونة من عصبونين. تابع التفعيل هو سيغمويد.

تعتبر الشبكات العصبية التطورية شكل من أشكال التعلم الآلي الذي يستخدم الخوارزمية الجينية لتدريب الشبكة العصبية، عن طريق تقدير أوزان الشبكة العصبية، تمثل كل عربة كروموسوم مختلف في الجيل، وبمعنى آخر مجموعة فريدة من أوزان الشبكة العصبية، والتي يتم تقييمها ونقلها الى الجيل التالي عن طريق تابع اللياقة fitness score. يتم اختيار تابع اللياقة ليكون المسافة التي تقطعها العربة على طول المسار دون اصطدامها بحدود المسار، وبذلك تكون العربة التي بقيت أطول مدة زمنية على المسار هي العربة الأفضل. سيتم تعليم الشبكة العصبونية عملية القيادة على الطريق المنحني.

1.4. استراتيجية التعلم GA learning strategy:

يمكن استخدام الخوارزمية الجينية GA لأمثلة الشبكة العصبية بثلاث طرق [9]:

1. أمثلة بنية الشبكة العصبية Architecture optimization.

2. أمثلة الأوزان Optimization of the weights.

3. أمثلة قواعد التعلم Optimization of the learning rules.


في هذا البحث، نستخدم الخوارزمية الجينية لأمثلة أوزان الاتصالات.

تبين الخطوات التالية كيفية الحصول على الأوزان المثلى للشبكة العصبية باستخدام الخوارزمية الجينية:

1.4.1. ترميز الحلول:

يقصد بالحلول أي قيمة مرشحة لتكون حل صحيح أو جواب نهائي، والحل قد يكون الحل الصحيح أو الخاطئ، ومن أجل إيجاد تمثيل مناسب للحل، يعد الترميز عاملاً أساسياً لنجاح الخوارزمية الجينية، وهناك عدة طرق لعملية الترميز وهذا يعتمد على المسألة المراد حلها لان الكروموسوم يجب ان يحتوي على معلومات حول الحل، إذاً كل كروموسوم هو حل ممكن للمشكلة المطروحة [10].

تم في هذا البحث اختيار صيغة الكروموسوم على شكل شعاع من الأعداد الحقيقية يمثل تسلسل جميع أوزان الشبكة العصبية، ويتم ترتيب أوزان كل طبقة بحيث تكون متتالية، باعتبار لدينا شبكة عصبية تمثل عربة، يدخل عبارة عن قيم الحساسات، وطبقتين مخفيتين، تحوي كل طبقة مخفية 18 عصبون، وطبقة خرج تحوي عصبونين، يكون الكروموسوم الخاص بها كما هو موضح في الشكل (2).



الكروموسوم المقابل لأوزان الشبكة العصبية:

$W_{1.20}$	$W_{1.21}$	$W_{19.37}$	$W_{20.38}$	$W_{37.55}$	$W_{38.56}$	$W_{55.57}$
طبقة الأوزان الأولى			طبقة الأوزان الثانية			طبقة الأوزان الثالثة			

الشكل(2) يمثل الشبكة العصبية والكروموسوم الخاص بها

1.4.2. تابع التقييم:

عندما يكون لدينا عدد من الحلول، نحن بحاجة لآلية فعالة ومدروسة توجهنا نحو الحل الأفضل من بين مجموعة الحلول المطروحة، أي نحن بحاجة لتابع تقييم يرشدنا نحو الحل الأمثل ويعطينا تقييم أولي أي من هذه الحلول هو أقدر على النجاة وأصلح لأن ينتقل للجيل التالي، وبالطبع فإن اختيار هذا التابع ذو علاقة وثيقة بالمسألة المطروحة، ولا يوجد تابع عام بشكل مطلق لحساب اللياقة [10].

1.4.3. المكون الثالث يتجلى بالعمليات الجينية Genetic Operators:

تتبع أهمية العمليات الجينية من إيجاد حلول لم تكن موجودة سابقاً في فضاء الحلول، ومن أهم العمليات الجينية [7] التصلب crossover والطفرة mutation، ويعتمد أداء الخوارزميات الجينية بشكل كبير على هذين المؤثرين كما أن أسلوب التمثيل المستخدم له دوره أيضاً.

1.5 اختيار الوالدين: (parent selection)

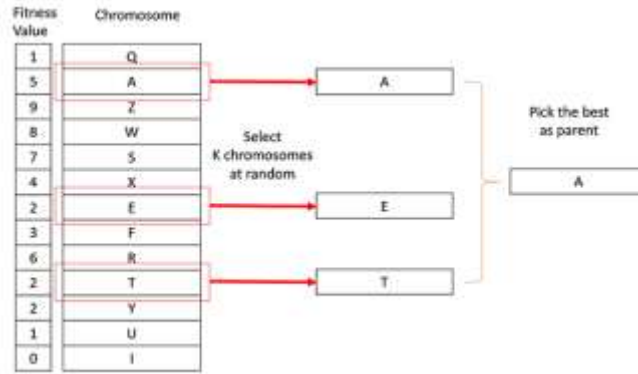
تبدأ عملية التوالد باختيار الوالدين والمقياس الوحيد في هذا الاختيار هو اللياقة، ورغم أن عملية الانتقاء، كغيرها من العمليات، تتم عشوائياً إلا أن فرص انتقاء كروموسوم معين مرتبطة ارتباطاً وثيقاً بلياقته. فأكثر الكروموسومات لياقةً مرشح للانتقاء مرات عديدة في حين أن الكروموسوم الضعيف قد لا ينتقى إطلاقاً. إن الهدف من عملية انتقاء الوالدين هو إعطاء الكروموسومات الجيدة فرصة أكبر للتوالد وبالمقابل، تقليل فرص التوالد أمام الكروموسومات ضعيفة اللياقة [2]. للقيام بهذه العملية توجد طرق عديدة وهي:

- اختيار بولتزمان Boltzmann selection [11].
- اختيار الأفضل من بين مجموعة أفراد Tournament selectin [12].
- اختيار المرتبة Rank selection [13].
- الاختيار المحلي Local selection [14].
- اختيار النسبة الأفضل من بين جميع الأفراد Truncation selection [15].
- العجلة الدوارة (roulette wheel) [3].

وقد تم تضمين الخوارزمية نوعين من الإجراءات للمقارنة بينهما هما: اختيار الأفضل من بين مجموعة أفراد Tournament selection واختيار النسبة الأفضل من بين جميع الأفراد Truncation selection.

1.5.1 إجرائية اختيار الأفضل من بين مجموعة أفراد Tournament selection:

هو طريقة لاختيار فرد من مجموعة من الأفراد في الخوارزمية الجينية. يتضمن إجراء عدة "دورات" بين عدد قليل من الأفراد (أو "الكروموسومات") الذين يتم اختيارهم عشوائياً من التعداد السكاني. يتم اختيار الفائز في كل دورة (أفضل لياقة) للعبور كما هو موضح في الشكل (3). يتم تعريف ضغط الاختيار Selection pressure، وهو مقياس احتمالي لاحتمال مشاركة الكروموسوم في الدورة بناءً على حجم مجموعة اختيار المشاركين، يمكن تعديله بسهولة عن طريق تغيير حجم الدورة [9].



الشكل (3) إجرائية اختيار الأفضل من بين مجموعة أفراد Tournament [11].

يمكن وصف طريقة اختيار الأفضل من بين مجموعة أفراد كما يلي:

1. اختر k (حجم دورة) أفراداً من السكان بشكل عشوائي.
2. اختر أفضل فرد من الدورة مع احتمال p .
3. اختر ثاني أفضل فرد باحتمالية $(1-p) * p$.

4. اختر ثالث أفضل فرد مع احتمال $(1-p)^2$ * p.

1.5.2. الاختيار وفق خوارزمية النسبة الأفضل من بين جميع الأفراد Truncation selection:

تعتبر طريقة فعالة يستخدمها الآباء لمجموعة كبيرة من السكان (الاختيار الجماعي)، يتم فرز الأفراد حسب لياقتهم وفق ترتيب تنازلي، يتم اختيار أفضل الأفراد فقط كأباء حيث يتم استخدام عتبة معينة Trunc كعامل يشير إلى عدد الأفراد الذين سيتم اختيارهم كأباء ويأخذ قيمة تتراوح من 10% إلى 50%، ويتم استبعاد الأفراد الذين هم دون تلك العتبة [12]، يمكن وصف تلك الإجرائية كما يلي:

1. فرز السكان حسب اللياقة.
2. تجاهل الأفراد الضعفاء.
3. إضافة النسبة المئوية الأعلى إلى تجمع السكان ليتم بعدها اختيار الآباء من أجل التصالب.

1.6. المتغيرات الخاصة بالخوارزمية الجينية:

هنالك عدة متغيرات لها تأثير مباشر على كفاءة عمل الخوارزمية الجينية، والحفاظ على درجة توازن بين هذه المتغيرات يجعل الخوارزمية أكثر كفاءة في الوصول للحل [16]:

1. نسبة العبور crossover rate: هي نسبة حدوث التداخل بين الأفراد المسؤولة عن توليد أفراد الجيل اللاحق . تعني % 100 أن جميع الأفراد الجديدة ناتجة عن التداخل و % 0 تعني أن جميع الأفراد في الجيل الجديد هي مستنسخة من الجيل السابق. تتراوح قيمة هذا المتغير بين الصفر والواحد [13] .
2. نسبة حدوث الطفرة mutation rate: تعبر عشوائي في جينات أفراد الجيل، % 100 تعني أن جميع الأفراد بكامل جيناتها حدث عليها تغيير و % 0 تعني عدم حدوث أي تغيير عشوائي في جينات الأفراد . تتراوح قيمة هذا المتغير بين الصفر والواحد [13]. يجب ان تبقى نسبة حدوث الطفرة صغيرة في الخوارزمية الجينية وإلا فإن زيادة نسبة الطفرة تؤدي إلى تحول طبيعة الخوارزمية الجينية إلى خوارزمية بحث عشوائية فقط [3].
3. حجم مجموعة الأفراد population size: يعبر عن عدد الأفراد في الجيل الواحد، اختيار عدد الأفراد يعتبر مسألة حساسة ففي حالة كان العدد قليل يؤدي إلى ضعف التنوع واختيار عدد أفراد كبير يؤثر أيضاً في زمن حل المسألة، لذلك يجب أن يكون عدد الأفراد متوازناً [13].

النتائج والمناقشة:

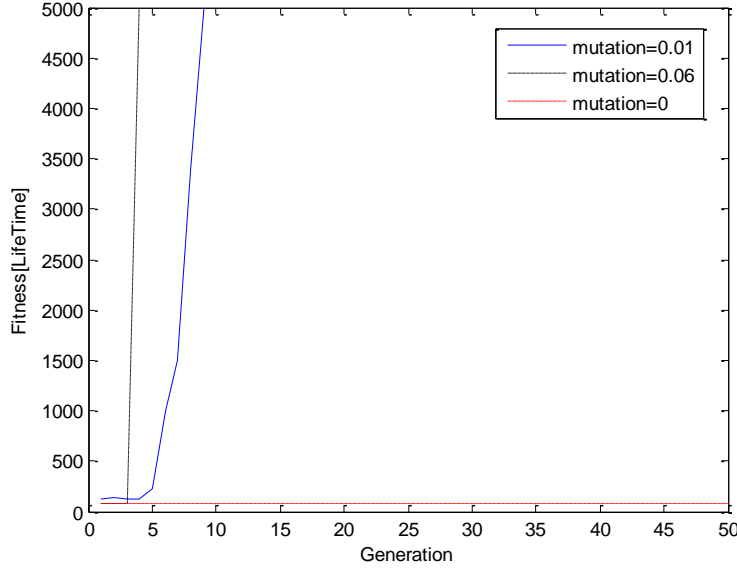
يتم العمل على مرحلتين، تبدأ من اختيار البارامترات المناسبة للخوارزمية الجينية من أجل تدريب العربة على طريق محدد في المرحلة الأولى، ثم يتم اختبار العربة المدربة وفق النتائج التي تم الحصول عليها في المرحلة الأولى على طريق جديد ووفق سرعات مختلفة في المرحلة الثانية.

1.7. المرحلة الأولى: تمثل دراسة تأثير كل من الطفرة وحجم الجيل وإجرائية الانتخاب على أداء الخوارزمية الجينية.

أولاً: تأثير الطفرة:

الطفرة عبارة عن تغيير إحدى متحولات الحل بشكل عشوائي وبنسبة معينة تسمى نسبة حدوث الطفرة. في الواقع فإن أهمية هذه العملية تكمن في منع حصول تشابه مطلق بين مجموعة الأفراد وتزيد من نسبة تفادي الوقوع في النهايات المحلية Local Minima [2]. قمنا بدراسة مدى تأثير قيمة هذا المتغير على الخوارزمية الجينية في البحث وذلك ضمن المجال [0,1]، حجم الجي (50) ، الانتخاب وفق خوارزمية النسبة الأفضل من بين جميع الأفراد Truncation.

كل عربة تمثل بشبكة عصبية وكل شبكة عصبية هي كروموسوم ضمن الخوارزمية الجينية. الشبكة العصبية عبارة عن 19 عقدة دخل وطبقتين مخفيتين، تحوي كل طبقة مخفية 18 عصبون وعقدتي خرج، سرعة العربة 30 م/ثا. يطلب من العربة القيادة ضمن المسار المحدد ذهاباً وإياباً عدة مرات دون أي اصطدام، وذلك لمدة 5000 ثانية. يمثل المحور الأفقي في الشكل (4) عدد الأجيال، أما المحور الشاقولي فيمثل اللياقة (زمن القيادة).




الشكل (4) تأثير الطفرة على أداء الخوارزمية الجينية

نلاحظ عند غياب الطفرة عدم تمكن العربة من اجتياز الانعطاف الأول والاختفاق في عبور المسار رغم تكرار 50 جيل، أما عندما استخدمنا الطفرة بنسب قليلة (0.01-0.06) تمكنت العربة من اجتياز المسار ذهاباً وإياباً لمدة 5000 ثانية دون الاصطدام بحدود المسار.

يتبين من خلال هذه التجربة أن أكبر خطأ هو عندما يكون احتمال الطفرة صفراً والاستغناء عن الطفرة يسيء للنتائج التي نحصل عليها، في حين أنه عند استخدام الطفرة بنسب قليلة تمكنت العربة من تعلم سلوك القيادة، وبناء على ذلك سيتم احداث طفرات خفيفة لكل عربة جديدة للحصول على العربات الأفضل، والسبب يعود لكون كلا الابوين الأفضل في الجيل وليس في جميع الأجيال.


ثانياً : دراسة تأثير الانتخاب:

تمت مقارنة تأثير خوارزميتي الانتخاب بالإضافة إلى تغيير حجم الجيل. نختار تعداد سكاني 200، طفرة 0.1، اللياقة المطلوبة هي القيادة لمدة 1200 ثانية بدون اصطدام بحدود المسار. يمثل المحور الأفقي في الشكل (6) عدد الأجيال، أما المحور الشاقولي فيمثل اللياقة التي تم الوصول إليها في كل جيل. تبين أنه عند استخدام اختيار الأفضل من بين مجموعة أفراد Tournament استغرقت الخوارزمية حوالي 25 تكرار من أجل الوصول إلى لياقة مقبولة، بينما عند استخدام مبدأ اختيار النسبة الأفضل من بين جميع الأفراد Truncation تمكنت العربة من عبور المسار عدة مرات دون أي اصطدام في التكرار السابع، والنتائج التي حصلنا عليها أدق وأفضل وأكثر استقراراً.



الشكل (6): مقارنة خوارزميتي الانتخاب عند تعداد سكاني 200

1.8. المرحلة الثانية: تمثل مرحلة اختبار العربة المدربة بواسطة الخوارزمية المقترحة وفق مسار مختلف عن مسار التدريب، وأيضاً وفق سرعات مختلفة، تم الاختبار بواسطة المسار الموضح في الشكل (7)، وتمكنت العربة من اجتياز المسار ذهاباً وإياباً دون أي اصطدام بحدود المسار.



الشكل (7): مسار الاختبار للعربة المدربة وفق المرحلة الأولى

كما تم اختبار قدرة العربة على عبور المسار ذهاباً وإياباً عند زيادة السرعة، وأثبتت النتائج قدرة العربة على اجتياز المسار حتى عند زيادة السرعة إلى 40 م/ثا، ويوضح الجدول (1) زمن اجتياز المسار وفق سرعات مختلفة.

الجدول (1): زمن اجتياز العربة وفق سرعات مختلفة

سرعة العربة (م/ثا)	20	30	40
زمن اجتياز المسار ذهاباً وإياباً (ثانية)	162.5	115.6	79.4

الاستنتاجات والتوصيات:

- تشير نتائج الدراسة التطبيقية إلى فعالية الخوارزمية الجينية في تدريب الشبكة العصبية، فقد تمكنت العربة من القيادة على طريق شديد الانعطاف عدة ساعات دون الاصطدام بحدود المسار، حيث لم يتجاوز انحراف العربة الجانبي عن وسط الممر 0.2 متر.
- تم مقارنة النتائج التي استخدمت فيها إجرائية اختيار الأفضل من بين مجموعة أفراد Tournament مع إجرائية اختيار النسبة الأفضل من بين جميع الأفراد Truncation، وتبين أنه يفضل استخدام إجرائية اختيار النسبة الأفضل من بين جميع الأفراد لما أبدته من ثبات واستقرار أعلى في النتائج التي حصلنا عليها من إجرائية اختيار الأفضل من بين مجموعة أفراد.
- يمكن استخدام الخوارزمية الجينية GA لأتمثلة بنية الشبكة العصبية وقواعد التعلم إضافة إلى أمثلة الأوزان.
- كما يمكن استخدام أنواع أخرى من خوارزميات التطور العصبي مثل البرمجة الجينية لتحسين أداء العربات ذاتية القيادة.

References:

1. SHARMA, H.P. *Self-directed Robot for Car Driving using Genetic Algorithm*. in *2021 3rd International Conference on Signal Processing and Communication (ICPSC)*. 2021. IEEE.
2. PARTOUCHE, D., *Intelligent speed adaptation in curves for autonomous vehicles*. 2006.
3. SAINATH, G. *Application of Neuroevolution in Autonomous Cars*. in *International Virtual Conference on Industry 4.0*. 2021. Springer.
4. ERAQI, H., EMADELDIN, Y; and M. Moustafa. *Reactive collision avoidance using evolutionary neural networks*. arXiv preprint arXiv:1609.08414, 2016.
5. Bye, R.T., et al., *A Comparison of GA Crossover and Mutation Methods for the Traveling Salesman Problem*, in *Innovations in Computational Intelligence and Computer Vision*. 2021
6. KRAMER, O., *Genetic algorithms*, in *Genetic algorithm essentials*. 2017
7. MIRJALILI, S., *Evolutionary algorithms and neural networks*, in *Studies in Computational Intelligence*. 2019, Springer.
8. MAHAJAN, R. and G. Kaur. *Neural networks using genetic algorithms*. International Journal of computer applications, 2013.
9. GJYLAPI, D., R. Lamllari, and V. Kasëmi, *Comparing Back Propagation and Genetic Algorithms in Neural Networks for Financial Time Series Forecasting*. International Journal of Arts & Sciences, 2013.
10. Stanley, K.O., et al., *Designing neural networks through neuroevolution*. Nature Machine Intelligence, 2019.
11. Galván, E. and P. Mooney, *Neuroevolution in deep neural networks: Current trends and future challenges*. IEEE Transactions on Artificial Intelligence, 2021.

12. Vargas-Hákim, G.A., E. Mezura-Montes, and H.-G. Acosta-Mesa, *A Review on Convolutional Neural Networks Encodings for Neuroevolution*. IEEE Transactions on Evolutionary Computation, 2021.
13. KUMAR, R., *Blending roulette wheel selection & rank selection in genetic algorithms*. International Journal of Machine Learning and Computing, 2012. 2(4): p. 365-370.
14. Li, Z., et al., *Intersection control optimization for automated vehicles using genetic algorithm*. Journal of Transportation Engineering, Part A: Systems, 2018.
15. Katoch, S., S.S. Chauhan, and V. Kumar, *A review on genetic algorithm: past, present, and future*. Multimedia Tools and Applications, 2021.
16. HASSANAT, A.; *Choosing mutation and crossover ratios for genetic algorithms—a review with a new dynamic approach*. Information, 2019. 10(12): p. 390.