



الجمهورية العربية السورية

جامعة دمشق

كلية الهندسة الميكانيكية والكهربائية

قسم هندسة الحواسيب والأتمتة

تحسين نظم التصنيف الاستباقية القابلة للتعلم

Improve Anticipatory Learning Classifier Systems

رسالة أعدت للحصول على درجة الماجستير في هندسة التحكم الآلي والأتمتة

إعداد:

م. أحمد القصاص

إشراف:

د. أكرم مذكور

2019

ملخص الرسالة

Thesis Abstract

الهدف من هذا البحث هو دراسة إحدى التقنيات في مجال الذكاء الصناعي Artificial Intelligence AI هذه التقنية هي أنظمة المصنفات القابلة للتعلم Learning Classifier Systems (LCS) ، تقدم هذه الرسالة فكرة عامة عن نظم المصنفات و أنواعها وكذلك عن التقنيات المختلفة المتعلقة بها كالخوارزمية الجينية Genetic Algorithm GA والتعلم المعزز Reinforcement Learning RL ، ثم يقوم البحث بالتركيز على إحدى الخوارزميات من عائلة نظم المصنفات الاستباقية Anticipatory Learning Classifier Systems ALCS وهي ACS2 ويحتوي البحث على شرح كامل لهذه الخوارزمية، وتم أيضاً دراسة إحدى الخوارزميات وهي XCSR والتي تنتمي إلى عائلة نظم المصنفات المعتمدة على الدقة XCS والتي سبق وأن استخدمت في التعامل مع الأوساط المستمرة.

من خلال الدمج بين الخوارزميتين ACS2 و XCSR، وإضافة مجموعة من التعديلات تم الحصول على خوارزمية جديدة قادرة على التعامل مع التطبيقات والمسائل ذات المداخل المستمرة، أي أصبح لدينا نظام مصنفات استباقي جديد قادر على التعامل مع الأوساط المستمرة، ثم يقوم البحث بمقارنة نظم المصنفات الاستباقية وتقنية التحكم من خلال النموذج التنبؤي Model-Predictive Control MPC، وأثبتت المقارنة بأن نظم المصنفات الاستباقية قادرة على التعامل مع إحدى أهم مشاكل أنظمة التحكم وهي التحكم بالأنظمة ذات أزمنة التأخير الميت Dead-time processes.

وقد تم اختبار أداء الخوارزمية الجديدة مع تطبيق عملي ومقارنة النتائج مع إحدى أهم أنواع المتحكمات المستخدمة وهم المتحكم التناسبي التكاملي التفاضلي PID، ومن الاختبار وجدنا أن الخوارزمية الجديدة فعالة وأكثر سرعة ودقة في مجال التحكم.

قرار لجنة الحكم

لجنة الحكم المشكلة بناء على قرار مجلس البحث العلمي والدراسات العليا في جامعة دمشق رقم /1047/ المتخذ بالجلسة رقم /6/ التي انعقدت بتاريخ 2018/11/26 ، لمناقشة رسالة الماجستير في كلية الهندسة الميكانيكية والكهربائية قسم هندسة الحواسيب والأتمتة التي أعدها الطالب أحمد القصاص بعنوان تحسين نظم التصنيف القابلة للتعلم.

د. محمد مازن المحاييري

الأستاذ المساعد في قسم هندسة الحواسيب والأتمتة كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: تنظيم الحاسبات وبنيتها عضواً

د. أكرم مذكور

المدرس في قسم هندسة الحواسيب والأتمتة كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: السبرناتيك الرياضي والبرمجة عضواً مشرفاً

د. هيام خدام

المدرس في قسم هندسة الحواسيب والأتمتة كلية الهندسة الميكانيكية والكهربائية
جامعة دمشق الاختصاص: التحكم الرقمي عضواً

كلمة شكر

الحمد لله الذي منّ علينا بسابغ فضله وأجلّ نعمه، حيث هدانا للعلم وبلغنا مناهله، ومن ثم فإن وافر شكري وكثير امتناني أقدمه إلى من مد لي يده داعماً جهودي المبذولة ومباركاً خطا هذا العمل.

وأخص بالشكر الدكتور أكرم مذكور الذي تفضل بالإشراف على هذا البحث ومنحني وقته وجهده.

وأقدم ببالغ الشكر وكثير الامتنان إلى أعضاء لجنة التحكيم الموقرين الدكتور محمد مازن محاييري والدكتورة هيام خدام على ما تكبدوه من عناء في قراءة وتدقيق هذا البحث المتواضع وإغنائهم بمقترحاتهم القيمة.

أما فيض شكري وفائق تقديري للدكتور سمير كرمان رئيس قسم الحواسيب والأتمتة لرعايته ودعّمه المتواصل.

الإهداء

إلى من أنار لي الدرب

إلى من رضاه معنى وجودي

إلى من علمني معنى الإخلاص

إلى من كلماته شكّلت منهاج حياتي

إلى من أحمل اسمه بكل فخر واعتزاز

إلى من لولاه لم يُكتب حرف في هذا البحث

إلى والدي الغالي الدكتور محمد بشير القصاص

لائحة الاختصارات

A	Action Set	مجموعة الإجراء
ACS	Anticipatory Classifier System	نظام المصنفات الاستباقي
AI	Artificial Intelligence	الذكاء الصناعي
AIS	Artificial Immune Systems	النظم المناعية الاصطناعية
ALCS	Anticipatory Learning Classifier Systems	نظم المصنفات الاستباقية القابلة للتعلم
ALP	Anticipatory Learning Process	عملية التعلم الاستباقي
ANN	Artificial Neural Networks	الشبكات العصبونية الاصطناعية
EC	Evolutionary Computing	والحوسبة التطورية
FZ	Fuzzy Systems	الأنظمة العائمة
GA	Genetic Algorithm	الخوارزمية الجينية
LCS	Learning Classifier Systems	نظم المصنفات القابلة للتعلم
M	Match Set	مجموعة التطابق
MDP	Markov Decision Process	إجرائية القرار لماركوف
MIMO	Multi-input-multi-output	الأنظمة متعددة المداخل ومتعددة المخارج
ML	Machine Learning	التعلم الآلي
MPC	Model Predictive control	التحكم من خلال النموذج التنبؤي
OOP	Object Oriented Programming	البرمجة كائنية التوجه
PID	Proportional Integral Derivative controller	المتحكم التناسبي التفاضلي التكاملية
RL	Reinforcement Learning	التعليم المعزز
SISO	Single-input-single-output	الأنظمة ذات المدخل الواحد والمخرج الواحد
TD	Temporal Difference learning	التعليم باستخدام الفروقات
XCS	Accuracy-based Systems	نظم المصنفات القائمة على الدقة
ZCS	Strength-based systems	نظم المصنفات القائمة على القوة

المصطلحات العلمية

A

Action Chunking	تجزئة الإجراء
Action Planning	تخطيط الإجراءات
Action Selection	انتقاء الإجراء
Adaptive Mechanisms	آليات المواءمة والتكيف
Aliasing state	حالة زائفة
Anticipation Learning	التعليم الاستباقي
Anticipatory Behavioral control	التحكم السلوكي الاستباقي
Automatic Classification	التصنيف التلقائي

B

Backwards-directed breadth-first search	البحث الموجه الخلفي الموسع
Bids	الأوزان

C

Classification	التصنيف
Classifier Population evaluation mechanism	آلية تطوير مجموعة المصنفات
Clustering	العنقدة
Cognitive System	النظام الإدراكي
Covering Operator	معامل التغطية
Crossover	معامل العبور

D

Dead-time process	الأنظمة ذات أزمنة التأخير الميتة
Deterministic environments	أوساط حتمية
Differentiation	التمايز

E

Evolutionary Learning	التعليم التطوري
-----------------------	-----------------

Evolutionary Processes	الإجرائيات التطورية
Exploration and Exploitation	الاستثمار والاستكشاف
F	
Feedback / Reward	الربح أو المردود
Fitness	الملاءمة
Fitness Measure	مقياس للملاءمة أو الكفاءة
Forwards-directed breadth-first search	البحث الموجه الأمامي الموسع
G	
Goal-Directed learning	التعليم الموجه بالأهداف
Goal-generator	مولد الأهداف
Greedy classifier	المصنف الجشع
I	
Interval predicates	محددات المجالات
L	
Latent learning	التعلم الكامن
Learning with Critic	التعليم بالنقد
M	
Macro-classifier	المصنف الضمني / الفرعي
Mark	العلام
Model of transitions	نموذج الانتقالات
Model-based RL	التعليم المعزز المعتمدة على نموذج
Multi-step environments	الأوساط متعددة الخطوات
Mutation	معامل الطفرة
N	
Natural Selection	الانتقاء الطبيعي
Non-deterministic environment	الأوساط غير الحتمية
Non-Markov stats	حالات لا تخضع لخاصية ماركوف

R

Real Multiplexer	الناخب المنطقي ذو المداخل الحقيقية
Recombination	إعادة التركيب
Replacement	نظام الاستبدال
Reproduction	الاستتساخ
Roulette Wheel Mechanism	آلية عجلة روليت

S

Selection	الاختيار أو الانتقاء
Specificity	درجة التخصيص
Subsumption	التكافؤ / التصنيف الضمني
Supervised Learner	التعليم الموجه (بمعلم)

T

The perceptual aliasing problem	مشكلة الإدراك الزائف
Trial-and-error	التجربة والخطأ

لائحة الأشكال

11	مراحل الخوارزمية الجينية بأبسط أشكالها	الشكل (1-2)
13	المخطط الصندوقي لمسائل التعليم المعزز RL	الشكل (2-2)
22	المخطط العام لنظام ZCS	الشكل (1-3)
31	المخطط العام لنظام XCS	الشكل (2-3)
40	المخطط العام لبنية DYNA	الشكل (1-4)
41	التعليم السلوكي الاستباقي	الشكل (2-4)
42	التفاعل بين الوسط والعميل ACS	الشكل (3-4)
44	الأفعال السلوكية في نظام ACS	الشكل (4-4)
48	Woods Environment	الشكل (5-4)
57	المخطط الصندوق للنظام ACS2	الشكل (1-5)
60	خوارزمية برنامج التهيئة	الشكل (2-5)
62	خوارزمية حلقة التنفيذ العامة	الشكل (3-5)
63	خوارزمية تشكيل مجموعة التتابع	الشكل (4-5)
63	خوارزمية اختبار التتابع مع حالة الوسط	الشكل (5-5)
64	خوارزمية اختيار الإجراء	الشكل (6-5)
64	خوارزمية تشكيل مجموعة الإجراء [A]	الشكل (7-5)
66	الخوارزمية العامة الخاصة بعملية التعليم الاستباقي	الشكل (8-5)
66	خوارزمية تعديل معدل التطبيق	الشكل (9-5)
67	خوارزمية اختبار التوقع الصحيح	الشكل (10-5)
69	خوارزمية معالجة حالة التوقع الصحيح	الشكل (11-5)
70	خوارزمية إيجاد الفروقات بين حالة وعلام المصنف	الشكل (12-5)
71	خوارزمية معالجة حالة التوقع غير الصحيح	الشكل (13-5)

72	خوارزمية التغطية	الشكل (5-14)
73	خوارزمية لإضافة المصنفات الناتجة من إجرائية ALP	الشكل (5-15)
74	خوارزمية التعليم المعزز	الشكل (5-16)
76	الخوارزمية الجينية	الشكل (5-17)
76	خوارزمية انتقاء مصنفات النسل الجديد	الشكل (5-18)
77	خوارزمية تطبيق معامل الطفرة	الشكل (5-19)
78	خوارزمية تطبيق معامل العبور	الشكل (5-20)
79	خوارزمية حذف المصنفات	الشكل (5-21)
80	خوارزمية إضافة المصنفات الناتجة من الخوارزمية الجينية	الشكل (5-22)
81	خوارزمية التحقق من تكافؤ المصنفات	الشكل (5-23)
84	مجموعة خزانات التعبئة الأسطوانية	الشكل (6-1)
88	مخطط زمني يظهر آلية التحكم التنبؤي	الشكل (6-2)
90	الآلية العامة لتطبيق طريقة النموذج التنبؤي	الشكل (6-3)
97	آلية تحديث المصنف وفق العلام	الشكل (7-1)
102	مثال عن استجابة الأنظمة ذات أزمنة التأخير الميتة	الشكل (7-2)
110	المخطط العام للجملة العملية	الشكل (8-1)
111	المخطط الصندوقي للجملة	الشكل (8-2)
111	المخطط الصندوقي المختصر للجملة	الشكل (8-3)
112	المخطط العام للجملة مع نظام المصنفات	الشكل (8-4)
116	مخطط الصفوف للخوارزمية	الشكل (8-5)
117	استجابة خرج جملة التحكم في التجربة (1) بعد 500 دورة تدريب	الشكل (8-6)
118	استجابة خرج جملة التحكم في التجربة (1) بعد 1000 دورة تدريب	الشكل (8-7)
119	استجابة خرج جملة التحكم في التجربة (2) بعد 500 دورة تدريب	الشكل (8-8)
120	استجابة خرج جملة التحكم في التجربة (3) بعد 500 دورة تدريب	الشكل (8-9)

120	استجابة خرج جملة التحكم في التجربة (4) بعد 500 دورة تدريب	الشكل (8-10)
121	استجابة خرج جملة التحكم باستخدام متحكم PID	الشكل (8-11)
122	استجابة خرج الجملة باستخدام متحكم PID بعد المعايرة الإضافي	الشكل (8-12)

الفهرس

II	ملخص الرسالة	
III	قرار لجنة الحكم	
IV	كلمة شكر	
V	الإهداء	
VI	لائحة الاختصارات	
VII	المصطلحات العلمية	
X	لائحة الأشكال	
XIII	الفهرس	
1	الفصل الأول: المقدمة	-1
2	1-1- الدافع إلى البحث	
3	2-1- فكرة الرسالة	
4	3-1- محتويات الرسالة	
7	الفصل الثاني: مفاهيم عامة	-2
8	1-2- نظم المصنفات القابلة للتعلم	
8	1-1-2- لمحة تاريخية	
8	2-1-2- تعريف	
9	3-1-2- مميزات نظم المصنفات القابلة للتعلم	
10	2-2- الخوارزمية الجينية	
11	3-2- التعليم المعزز	
14	4-2- إجرائية القرار لماركوف	
16	الفصل الثالث: نظم المصنفات القابلة للتعلم	-3
17	1-3- أساسيات	
18	1-1-3- تكوين وتشكيل المصنف	
19	2-1-3- انتقاء الإجراء	
20	3-1-3- آليات تطوير مجموعة المصنفات	

20	العائلات الرئيسية لنظم المصنفات القابلة للتعلم	-2-3
20	Strength-based systems	-1-2-3
	ZCS	
24	Accuracy-based Systems	-2-2-3
	XCS	
33	استخدام نظام XCS مع قيم دخل مستمرة	-3-3
34	مثال عن الأنظمة ذات المداخل المستمرة	-1-3-3
35	الاختلافات عن نظام XCS	-2-3-3
38	الفصل الرابع: نظم المصنفات الاستباقية	-4
39	مقدمة	-1-4
40	النظام ACS	-2-4
41	التحكم السلوكي الاستباقي	-1-2-4
42	المكونات الرئيسية	-2-2-4
43	الخوارزمية العامة	-3-2-4
45	خوارزمية التعليم الأساسية	-4-2-4
47	تطبيق عملي	-5-2-4
49	تحديد المكونات الثابتة (غير المتغيرة)	-6-2-4
50	الأوساط غير الحتمية	-7-2-4
52	تخطيط الإجراءات	-8-2-4
53	التعليم الموجه بالأهداف	-9-2-4
55	الفصل الخامس: النظام ACS2	-5
56	التفاعل مع الوسط	-1-5
57	تمثيل المعرفة	-2-5
58	مجموعة بارامترات النظام	-3-5
60	الخوارزمية العامة	-4-5
60	التهيئة	-1-4-5
60	حلقة التنفيذ العامة	-2-4-5

62	تشكيل مجموعة التتابع	5-4-3-
63	اختيار الإجراء	5-4-4-
64	تشكيل مجموعة الإجراء	5-4-5-
65	عملية التعليم الاستباقي ALP	5-4-6-
73	التعليم المعزز في النظام ACS2	5-4-7-
74	التعميم باستخدام الخوارزمية الجينية	5-4-8-
80	التكافؤ أو التصنيف الضمني	5-4-9-
82	الفصل السادس: أنظمة الزمن الميت	6-
83	مقدمة	6-1-
83	صعوبات التحكم بأنظمة الزمن الميت	6-2-
84	مثال	6-3-
86	التحكم من خلال النموذج التنبؤي MPC	6-4-
87	لمحة عامة عن التحكم من خلال النموذج التنبؤي	6-4-1-
88	مفهوم التحكم المعتمد على النموذج التنبؤي	6-4-2-
90	مكونات المتحكم المعتمد على النموذج التنبؤي	6-4-3-
90	الخلاصة	6-5-
92	الفصل السابع: تصميم نظام مصنفات استباقي بمدخل ذات قيم مستمرة	7-
93	مقدمة	7-1-
93	بنية المصنفات	7-2-
93	التفاعل مع الوسط وجزء الشرط في المصنف	7-2-1-
94	جزء الإجراء	7-2-2-
94	جزء النتيجة	7-2-3-
96	العلام	7-2-4-
98	الخوارزمية العامة	7-3-
98	تشكيل مجموعة التتابع	7-3-1-
98	اختيار الإجراء	7-3-2-
99	عملية التعليم الاستباقي	7-3-3-

104	إضافة المصنفات الناتجة عن إجرائية ALP	7-3-4-
106	التعليم المعزز RL في النظام الجديد	7-3-5-
106	الخوارزمية الجينية	7-3-6-
107	المراقب ومخطط الإجراءات	7-4-
108	الخلاصة	7-5-
109	الفصل الثامن: التطبيق العملي والنتائج	8-
110	الجملة المستخدمة في التطبيق	8-1-
112	الربط بين نظام المصنفات والتطبيق	8-2-
113	الأدوات المستخدمة	8-3-
113	البناء الخوارزمي	8-4-
114	البناء البرمجي	8-5-
117	التطبيق العملي	8-6-
121	المقارنة مع المتحكم التناسبي التفاضلي التكامل PID	8-7-
123	نتائج البحث	8-8-
123	الآفاق المستقبلية	8-8-
125	المراجع	
129	ملحق (A): المخططات الصندوقية	
130	1- حلقة التشغيل العامة	
131	2- حلقة التنفيذ العامة	
133	3- التطابق	
133	4- تشكيل مجموعة التطابق	
134	5- اختيار الإجراء	
135	6- تشكيل مجموعة الإجراء	
135	7- تحديث معدل التطبيق	
136	8- عملية التعليم الاستباقي	
137	9- اختبار التوقع الصحيح	
138	10- معالجة الحالة المتوقعة	

139	ايجاد الفروقات بين حالة وعلام	-11
140	معالجة الحالة غير المتوقعة	-12
141	التغطية	-13
142	إضافة المصنف الناتج من إجرائية ALP	-14
143	التعميم باستخدام الخوارزمية الجينية	-15
144	اختيار مصنفات النسل الجديد	-16
145	التعميم باستخدام معامل الطفرة	-17
146	تطبيق معامل العبور	-18
147	حذف المصنفات	-19
148	إضافة المصنف الناتجة من الخوارزمية الجينية	-20
149	التحقق من مكافأة المصنفات	-21
151	Abstract	

الفصل الأول: المقدمة

مدخل البحث

1. المقدمة:

1-1 - الدافع إلى البحث:

يعتبر الذكاء الصناعي (Artificial Intelligence (AI من أهم المجالات التي تتطور بشكل سريع، وهو مجال له العديد من التطبيقات في الحياة العملية.

يهتم الذكاء الصناعي بجعل الآلة تمتلك القدرة على اتخاذ القرار الصحيح وبالتالي التصرف مثل الإنسان، ويمكن القول بأنه يشمل آليات التفكير وتمثيل المعرفة والمعطيات وكذلك القدرة على التواصل مع الأوساط المحيطة والإدراك والتعلم [16].

من أهم المفاهيم المرافقة للذكاء الصناعي التعلم الآلي (Machine Learning (ML، وهو القدرة على التعلم بدون التوصيف أو البرمجة الصريحة لذلك، فبدلاً من إنشاء البرامج الذكية التي تمتلك التعليمات المحددة لإنجاز مهام العالم الحقيقي، توفر تقنيات التعلم الآلي ML الخوارزميات والطرق من أجل تعلم كيفية إنجاز المهام بشكل تلقائي [3].

ومنذ أواخر القرن الماضي إلى يومنا هذا تشهد تقنيات التعلم الآلي تطوراً وتتنوع كبيرين، ويتم استخدامها في تطبيقات واسعة في مختلف المجالات، وهي تسعى لتطوير الأنظمة المتكيفة والقادرة على التعلم واكتساب الخبرة من المعطيات المتوفرة بحيث تستطيع إعطاء الحلول الجديدة بدون الاعتماد الصريح على المعرفة البشرية. وتتملك هذه النظم بعض صفات المنطق مثل: التعميم والاكتشاف والاستثمار والتجريد.

تستخدم أنظمة التعلم الآلي العديد من التقنيات والأبحاث في مجال الأنظمة العائمة Fuzzy Systems (FZ) والشبكات العصبونية الاصطناعية Artificial Neural Networks (ANN) والحوسبة التطورية Evolutionary Computing (EC) والنظم المناعية

الاصطناعية (Artificial Immune Systems (AIS)، وأحد أهم التقنيات التي ظهرت وتنوعت بشكل كبير منذ بدايات القرن الحالي هي نظم المصنفات القابلة للتعلم Learning Classifier Systems (LCS) [12]، وهي تركز على تطوير خوارزميات بالاعتماد على بنى برمجية قائمة على القواعد شرط $\leftarrow$ فعل $(IF \rightarrow Then)$ ، والتي يمكن من خلالها تمثيل المعرفة والخبرات البشرية [1, 7].

وقد اثبتت هذه الخوارزميات جدارتها في العديد من المجالات كالتصنيف Classification [1] والتقيب عن المعطيات Data Mining [2] وعمليات التحكم Control Process وغيرها، ومن هذا المنطلق كان هدف هذا البحث وهو دراسة أنظمة المصنفات القابلة للتعلم LCS واستخدامها في أحد أهم مجالات التحكم وهو التحكم بالأنظمة ذات أزمنة التأخير الميت Dead-Time Process، من خلال تطوير أحد الخوارزميات الموجودة لتلائم هذا النوع من التطبيقات.

1-2 - فكرة الرسالة:

يعتمد البحث على دراسة نظم المصنفات القابلة للتعلم LCS بأنواعها المختلفة وكيفية الاستفادة من خصائص أو ميزات الخوارزميات المختلفة لنظم المصنفات، من أجل تصميم نظام جديد يحمل صفات وقدرات جديدة بهدف إيجاد حلول فعالة في مجالات تطبيقية جديدة.

وتعرض هذه الرسالة أهم النماذج والخوارزميات المبنية على نظم المصنفات LCS، وتحتوي على شرح كامل للأنواع الرئيسية لهذه الأنظمة والإضافات التي تمت عليها، وكذلك تستعرض أهم التقنيات المرتبطة بهذه النظم كالخوارزمية الجينية Genetic Algorithm (GA) وتقنيات التعليم المعزز Reinforcement Learning (RL).

وانطلاقاً من دراسة خوارزميات نظم المصنفات المختلفة تم تصميم نظام يمتلك خوارزمية ناتجة من دمج وتعديل نظامين مختلفين من أنظمة المصنفات الموجودة، حيث تم تعديل الهيكلية العامة للنظام ACS2 [9] لتلائم مجال تطبيقات لها مداخل مستمرة continues values، باستخدام التوصيف المقدم من النظام XCSR [13] من أجل التعامل مع هذا النوع من قيم مدخلات الوسط، ومن ثم تم تطبيق الخوارزمية المعدلة على تطبيق من أجل التحكم بنظام يعاني من تأخير زمني كبير يتصف بالزمن الميت.

1-3- محتويات الرسالة:

تم تنظيم محتوى هذه الرسالة ضمن عدة فصول وذلك على النحو التالي:

- الفصل الأول: يتضمن مدخلاً عن هذه الدراسة وأهميتها وفكرتها العامة وعرض هيكلية البحث.
- الفصل الثاني: يتضمن مقدمة مبسطة عن نظم المصنفات القابلة للتعلم LCS، وكذلك يستعرض مجموعة من المفاهيم والتقنيات المستخدمة ضمن إطار نظم المصنفات.
- الفصل الثالث: يشرح البنية الأساسية لنظم المصنفات LCS وبعض المكونات والعمليات الأساسية المكونة لها، وكذلك يفصل في البنية الأساسية لاثنتين من عوائل نظم المصنفات، ويتطرق أيضاً إلى النظام XCSR وبنيته القادرة على التعامل مع قيم المدخلات المستمرة.

- **الفصل الرابع:** يقدم الفصل الرابع العائلة الثالثة من نظم المصنفات وهي نظم المصنفات الاستباقية ALCS ذات القدرات التنبؤية، حيث يتحدث عن بنيتها الأساسية وكذلك يستعرض بعض الإضافات إلى هذه النظم التي عالجت بعض النقاط المتعلقة بالتطبيقات العملية.
- **الفصل الخامس:** يشرح الفصل الخامس الخوارزمية العامة للنظام الاستباقي ACS2 والذي تم الاعتماد عليه لاحقاً في تطوير الخوارزمية الجديدة محور هذا البحث.
- **الفصل السادس:** يقوم هذا الفصل بالتمهيد إلى مجال التطبيق المعتمد في هذه الدراسة وهو التحكم بالأنظمة ذات أزمنة التأخير الميتة dead-time، وكذلك إلى أحد أهم التقنيات المستخدمة لمعالجة هذا النوع من التطبيقات وهو التحكم من خلال النموذج التنبؤي Model Predictive، ومن ثم يقوم بإجراء عملية إسقاط أو مطابقة عامة بين نظم المصنفات الاستباقية والأنظمة ذات النموذج التنبؤي.
- **الفصل السابع:** يشرح هذا الفصل خوارزمية النظام الجديد المصمم والنقاط الأساسية التي تم إضافتها إلى الآلية العامة لنظم المصنفات الاستباقية من أجل أن تلائم مجال التطبيقات المقترح.
- **الفصل الثامن:** يظهر نتائج تطبيق واختبار الخوارزمية الجديدة وكذلك الآفاق المستقبلية والتوصيات المقترحة من هذا البحث.

- ملحق (A): يستعرض البناء الخوارزمي لأجزاء النظام الجديد.

الفصل الثاني: مفاهيم عامة

نظم المصنفات القابلة للتعلم

والتقنيات ذات الصلة

2. مفاهيم عامة:

2-1- نظم المصنفات القابلة للتعلم Learning Classifier Systems (LCS):

2-1-1- لمحة تاريخية:

يعود أصل نظم المصنفات LCS إلى سبعينيات القرن الماضي في الأبحاث المقدمة من قبل [John Holland 1975, 1978] حيث قام بتطبيق أول نظام تعليم آلي بالاعتماد على الخوارزمية الجينية وكان يدعى النظام الإدراكي ذو المستوى الأول Cognitive System (CS-1) Level one [2] ، وعلى نحو متناقض فإن نظم المصنفات أقل شهرة وانتشار من الخوارزمية الجينية GA [1] بالرغم من أن الخوارزمية الجينية تعد جزء من نظم المصنفات LCS ، حيث أن النظام الأول لهولاند (CS-1) كان يتكون من مجموعة من القواعد المحرفية البسيطة وتستخدم التمثيل الرقمي من الثلاثية {0, 1, #} للقيم، وتدعى هذه القواعد المصنفات Classifiers واستخدمت الخوارزمية الجينية كآلية بحث ضمن هذا النظام [2]، وكذلك استخدم تقنيات التعليم المعزز RL كآليات تحديث وتقييم للمؤشرات الدالة على أداء المصنفات [7]. وفي السنوات الأخيرة فإن الأبحاث التي تركز على نظم المصنفات القابلة للتعلم LCS ظهرت للعيان بشكل أكبر.

2-1-2- تعريف:

نظم المصنفات القابلة للتعلم هي نظم قائمة على مجموعة من القواعد أو المصنفات والتي تقوم ببناء أو تشكيل هذه القواعد الخاصة بها بشكل تلقائي. في البدايات تم النظر إلى نظم LCS على أنها نماذج بقدرات إدراكية cognitive abilities مكتسبة بفضل آليات المواءمة والتكيف Adaptive Mechanisms المتضمنة في هذه النظم، وعلى الأخص الإجراءات التطورية

Evolutionary Processes ثم أصبح التركيز أكثر في هذه النظم على موضوع التعلم واكتساب الخبرات، تعتبر LCS حالياً على أنها نظم حل معضلات اتخاذ القرار التسلسلية (Sequential decision problems) وتتميز بخاصية المقدرة على التعميم .generalization property.

ومن وجهة نظر التعليم المعزز Reinforcement Learning RL يمكن النظر إلى LCS على أنها نظم تعليمية (قابلة للتعلم) تقوم ببناء تمثيل أو نموذج مضغوط للمعضلات وذلك بفضل خاصية التعميم [1].

وفي الآونة الأخيرة أثبتت نظم LCS كفاءة في حل مهمات التصنيف التلقائي Automatic Classification [1].

2-1-3- مميزات نظم المصنفات القابلة للتعلم LCS:

تمتلك نظم المصنفات مجموعة من الخصائص تجعلها أكثر سهولة ووضوح بالمقارنة مع تقنيات التعليم الآلي الأخرى [12]:

1- البنية المعتمدة على القواعد والتي تجعلها أكثر قابلية للفهم والشمولية، وكذلك استخراج وتمثيل المعرفة يكون بشكل مباشر.

2- إمكانية التعليم بشكل مباشر أثناء التشغيل online.

3- بسبب استخدام التعليم التطوري Evolutionary Learning تكتسب نظم المصنفات القدرة على اكتشاف الحلول الجديدة والتغلب على المحدودية الناتجة عن عدم توفر المعطيات الكافية.

4- إمكانية تمثيل وتطوير الحلول الموزعة للمعضلات.

5- إمكانية التعامل مع المعضلات الكبيرة ذات المعطيات الضخمة.

2-2- الخوارزمية الجينية Genetic Algorithm GA:

تعتبر الخوارزمية الجينية من خوارزميات البحث القوية والتي تقوم على أفكار الانتقاء الطبيعي وعلم الوراثة للكائنات الحية، تعتمد الفكرة الأساسية في هذه الخوارزمية على مبدأ أن معظم الكائنات الحية المعقدة تتطور في الطبيعة كناتج لعمليتين هما الانتقاء الطبيعي Natural Selection والاستتساخ Reproduction.


من خلال الانتقاء الطبيعي تكون الأفراد الأقوى في المجموعة أكثر أرجحية للبقاء، قوة الفرد (Strength) هي مقياس على مقدرة الفرد على التكيف مع البيئة، ومن خلال الاستتساخ يتم المزج بين جينات الآباء وإعادة تركيب جديد للجينات في أفراد النسل الجديد، بالنتيجة جينات الأبناء تحوي على مزيج من جينات الآباء لذلك من المحتمل الحصول على أفراد تمثل حلول جديدة أفضل ومتفوقة على الحلول السابقة من خلال الخوارزمية الجينية وذلك بالاعتماد بشكل رئيسي على المزج بين الجينات [2].

عند تطبيق الخوارزمية الجينية يجب أن يكون عدد الأفراد Population ثابت وكل فرد ذو طول أو حجم ثابت ويتمثل من خلال مجموعة من الجينات ويكون لدينا مقياس للملاءمة أو الكفاءة Fitness Measure، هذا المقياس يُستخدم من قبل الخوارزمية لتقدير مدى جودة الفرد، ويتم اخذه بعين الاعتبار خلال عملية البحث.

يأخذ الجين قيمه من مجموعة التعريف أو مجموعة القيم الممكنة له المعرفة مسبقاً، في كثير من الحالات تكون مجموعة التعريف تعتمد على الترميز الثنائي (0,1) ومن الممكن أن تأخذ قيم صحيحة من غير التأثير على فعالية هذه الخوارزمية، سنحاول في هذا البحث تطبيق الخوارزمية الجينية على قيم مستمرة (مجالات التعريف ستكون عبارة عن جهود التحكم لنظام تحكم ما).

تتخذ الخوارزمية الجينية لعدد معين من الاجيال وعلى أساس معيار توقف معرف مسبقاً، تحوي هذه الخوارزمية على أربع مراحل:

- الاختيار أو الانتقاء Selection
- إعادة التركيب Recombination
- الطفرات أو التغيير Mutation
- نظام الاستبدال Replacement



الشكل (2 - 1): مراحل الخوارزمية الجينية بأبسط اشكالها

2-3 - التعليم المعزز Reinforcement Learning RL:

تعريف (1): عندما تواجه العميل معضلة يتعلم فيها السلوك الصحيح من خلال تفاعلات التجربة والخطأ Trial-and-error مع البيئة الديناميكية [2].

تعريف (2): في التعليم المعزز المتعلم هو عميل اتخاذ القرار يقوم باتخاذ اجراءات في الوسط المحيط ويتلقى مردود أو ربح على ذلك الإجراء محاولاً حل معضلة ما، وبعد مجموعة أشواط

من التجربة والخطأ يجب أن يكون العميل قد تعلم المنهجية الأفضل لحل المشكلة التي تزيد أو تحقق الربح الإجمالي [3].


أمثلة:

1- بفرض أن المطلوب بناء نظام قادر على لعب الشطرنج بفعالية، في هذه الحالة لا نستطيع استخدام معلم موجه (Supervised Learner) (اعتماد مجموعة تدريب أو تعليم للنظام). وذلك لسببين:

- a. من المكلف جداً الحصول على معلم (مجموعة التدريب) لهذه المعضلة يقوم باتخاذ القرارات الأفضل لكافة الحالات والوضعيات الممكنة في لعبة الشطرنج.
- b. في الكثير من الحالات لا يمكن في لعبة الشطرنج تقييم أفضلية إجراء أو حركة مفردة، لأن جودة أو فعالية الإجراء تعتمد على الحركات التالية، أي لا يمكن تقييم الإجراء بشكل مفرد ولكن تقييم سلسلة إجراءات بأنها جيدة إذا أدت إلى الفوز باللعبة. المردود لا نحصل عليه إلا في نهاية اللعبة إما ربح أو خسارة.

2- بفرض أنه لدينا روبوت موضوع في متاهة، يستطيع الروبوت التحرك بأربعة اتجاهات وعليه تنفيذ سلسلة من الحركات للوصول إلى المخرج، طالما أن الروبوت ضمن المتاهة لن يكون هناك أي مردود ويحصل الروبوت على المردود عند الوصول إلى المخرج، في هذا النوع من المعضلات لا يوجد منافسة ولكن من المهم الأخذ بعين الاعتبار المسارات القصيرة والزمن اللازم لحل المعضلة.

في كلا المثالين السابقين يمكن وضع المخطط التفاعلي للتعلم مع الوسط المحيط كما في الشكل (2-2).



الشكل (2- 2) : المخطط الصندوقي لمسائل التعليم المعزز RL

في أي لحظة زمنية تكون البيئة في حالة محددة، هذه الحالة تكون من إحدى الحالات الممكنة للبيئة التواجد فيها على سبيل المثال الحالات الممكنة لتوضع الروبوت في المتاهة، وكذلك متخذ القرار لديه مجموعة من الإجراءات الممكنة عليه الاختيار منها، كما هو الحال في لعبة الشطرنج حيث الإجراءات الممكنة هي مجموعة الحركات القانونية في اللعبة وفي حال الروبوت التحركات الممكنة للروبوت وهي التحرك بإحدى الاتجاهات الأربعة من غير الاصطدام بأي عائق.

عند إنجاز إجراء ما تتغير حالة البيئة، حل المعضلة سيكون عبارة عن سلسلة من الإجراءات وعلى العميل أن يتعلم التسلسل الأفضل للإجراءات حتى الوصول إلى الهدف المطلوب مع تحقيق ربح تراكمي أعظمي [3].

يختلف التعلم المعزز عن بقية تقنيات التعليم، والذي يعتمد على "التعليم بالنقد" Learning with Critic على عكس التعليم بمعلم Supervised Learning.

الناقد يختلف عن المعلم بأنه لا يخبرنا بما يجب فعله ولكن يزودنا بمعلومات عن كيفية الأداء في الماضي، المردود feedback في هذا النوع من التعليم نادر أو قليل وعندما يأتي متأخراً. هذا الكلام يقودنا إلى تعريف Problem Credit Assignment: بعد تنفيذ العديد من الإجراءات والحصول على المردود علينا أن نكون قادرين على تقييم كل إجراء على حدى، وإيجاد تسلسل الإجراءات الذي يؤدي إلى المردود الأفضل وإمكانية إعادة استدعاء الإجراءات لاحقاً لتحقيق ذلك.

ما تقوم به تقنية التعليم المعزز هو توليد قيم داخلية للحالات الراهنة وللإجراءات، تشير هذه القيم إلى مدى جودة وفعالية الحالة أو الإجراء للوصول إلى الهدف أو تحقيق المردود الأفضل، بالنتيجة عندما يتعلم العميل مثل هذه القيم الداخلية أو بكلام آخر يكون لديه آلية لتقييم المردود الداخلي للحالات والإجراءات، عندها يمكنه اختيار الإجراءات واتخاذ قرارات محلية أو مرحلية لتعظيم المردود النهائي المطلوب.

2-4 - إجرائية القرار لماركوف Markov Decision Process MDP:

من الضروري توضيح أحد أهم المفاهيم المرتبطة مع تقنيات التعليم المعزز RL وهو إجرائية القرار الخاضعة لخاصية ماركوف MDP، تتكون هذه الإجرائية من العناصر التالية:

- S: مجموعة منتهية من الحالات الممكنة للعميل
- A: مجموعة منتهية تمثل الإجراءات الممكنة تنفيذها من قبل العميل
- P: تابع الانتقال $P: S \times A \rightarrow \Pi(S)$ ، حيث $\Pi(S)$ يمثل التوزيع الاحتمالي للحالات S، أو يمكن القول باعتبار حالة محددة s أن $P_r(s_{t+1}|s_t, a_t)$ هو عبارة عن احتمال انتقال العميل إلى الحالة s_{t+1} عند التواجد في الحالة s_t وتنفيذ الإجراء a_t .

- R : تابع الربح $R : S \times A \rightarrow \mathcal{R}$ يعطي هذا التابع المردود الذي سيتلقاه العميل عند كل تشكيل ممكن للحالات والإجراءات (s_t, a_t) .

إن نموذج ماركوف MDP يتعامل مع أحد أنواع المسائل المعقدة حيث لا يوفر أي معلومات عن سلوك العميل في الوسط، وإنما يخبرنا فقط عن الحالة المستقبلية والمردود باعتبار الحالة الراهنة والإجراء المتخذ فيها.

بكلام آخر عندما تكون الحالة التالية التي سيتواجد فيها العميل معتمدة فقط على الحالة الراهنة والإجراء المتخذ فيها أي:

$$P_r(s_{t+1}|s_t, a_t, s_{t-1}, a_{t-1}, \dots, s_0, a_0) = P_r(s_{t+1}|s_t, a_t)$$

نقول هنا أن العميل يحقق خاصية ماركوف Markov Property [1]، ويمكن القول إن معرفة ماضي العميل لن يقدم أي معلومات مفيدة عن الحالات التالية أو مستقبل العميل.

الفصل الثالث: نظم المصنفات القابلة للتعلم

Learning Classifier Systems LCS

البنية والأنواع المختلفة

3. نظم المصنفات القابلة للتعلم LCS:

3-1 - أساسيات:

يمكن تقديم الإطار العام لنظم المصنفات القابلة للتعلم LCS على أنها نظم تعليم معزز RL تتمتع بخاصية التعميم، ومن أهم تقنيات التعليم المعزز هي خوارزمية Q-learning وتهدف إلى تعلم الآلية الأفضل للعمل، حيث يجب أن يكون العميل قادر على اتخاذ الإجراء الأفضل ضمن اعتبار أي ظرف للوسط المحيط، ومن ما يميز هذه الخوارزمية أنها لا تتطلب وجود نموذج للوسط حيث تعتمد على الانتقالات ومردود الإجراءات في التعلم.

إحدى طرق تنفيذ خوارزمية Q-learning البسيطة تعتمد على بناء جدول يدعى Q-table يحتوي على الثلاثيات $\langle s, a, p \rangle$ حيث أن s تمثل الحالة الراهنة للوسط s ، a تمثل الإجراء المتخذ من قبل العميل، p تمثل التقدير الحالي للربح النهائي المتوقع في حال تنفيذ الزوج $\langle s, a \rangle$ أي اختيار الإجراء a في حال وجود البيئة في الحالة s [1].

الإجرائية العامة لهذه الخوارزمية تتضمن إضافة سطر جديد للجدول يمثل ثلاثية $\langle s, a, p \rangle$ في كل مرة يواجه فيها العميل وضع جديد (حالة + إجراء)، أو تحديث قيم الربح P في حال وجود الزوج (حالة + إجراء) من قبل وذلك وفق المعادلة [2]:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [r_{t+1} + \gamma \max_a Q(s_{t+1}, a_t) - Q(s_t, a_t)] \quad (3-1)$$

حيث أن:

α : معدل التعليم ($0 \leq \alpha \leq 1$)

γ : معامل الخصم

r : الربح أو المردود الذي يتلقاه العميل من تنفيذ الإجراء a_t في الحالة s_t

المشكلة في التمثيل على شكل جدول أنه من الممكن أن يصبح هذا الجدول كبيراً جداً، ولتجنب هذه المشكلة علينا استخدام تمثيل يتمتع بخاصية التعميم [6]، ويمكن ذلك من خلال استخدام الثلاثية $\langle c, a, p \rangle$ ، حيث أن c لا ترمز إلى حالة وحيدة فقط إنما يمكن القول إنها ترمز إلى شرط من الممكن أن يتحقق في العديد من الحالات للوسط.

إذاً من الأمور الأساسية التي تميز نظم المصنفات هي طريقة تمثيل جزء الشرط C ، وأيضاً العمليات أو الإجراءات المستخدمة من أجل الحصول على التمثيل المختزل الفعّال لهذا الجزء.

3-1-1-1- تكوين وتشكيل المصنف (التوصيف العام لبنية المصنف):

نظم المصنفات القابلة للتعلم LCS عبارة عن تجمع من المصنفات أو القواعد، يكون المصنف عبارة عن الثلاثية $\langle c, a, p \rangle$ يحتوي على جزء الشرط c وجزء الإجراء $Action$ a وأيضاً تخمين الربح المتراكم المتوقع في حال اختيار أو اعتماد المصنف (تنفيذ الإجراء المحدد من قبل المصنف).

جزء الشرط يمثل سلسلة من الاختبارات، يمكن تقدير عددها بالخواص المتضمنة في توصيف المعضلة (القراءات من البيئة أو الدخل)، كل اختبار يُطبق على خاصية دخل محددة حيث يحدد القيمة الواجب تحقيقها في الخاصية المعينة حتى يتم التطابق الكامل لجزء الشرط المكون من مجموعة من الخاصيات، بالتالي يمكن اعتماد أو اختيار المصنف.

هناك نوع خاص من الاختبارات عندما تكون الخاصية أو متغير الدخل غير مهم في اتخاذ القرار أو بكلام آخر اختلاف قيمة الخاصية لا يؤثر على القرار، بالتالي يمكن اعتبار هذه الخاصية معمة في المصنف ويشار إليها بالرمز "#" ويدعى غير مهم "don't care"، بالنتيجة جزء الشرط سوف يطابق الدخل أو حالة الوسط عند كل الخاصيات المعمة.

وبشكل عام يكون الشرط مطابق إذا كانت كافة الاختبارات فيه موافقة للحالة الراهنة للوسط وعندها يمكن تفعيل المصنف.

في البدايات استخدمت نظم المصنفات LCS الترميز الثنائي فقط $\{0, 1, \#\}$ ولكن حديثاً طورت العديد من نظم المصنفات للتعامل مع القيم العددية والقيم المستمرة حيث تحتوي هذه النظم آليات مناسبة للتعامل مع أنواع القيم.

3-1-2- انتقاء الإجراء Action Selection:

من المهم جداً بالنسبة لنظم المصنفات تحديد آلية انتقاء الإجراء، وكذلك أيضاً تحديد آلية لتطوير مجموعة المصنفات في النظام Classifier Population evaluation mechanism من أجل ضمان المستوى المثالي من التعميم في مجموعة المصنفات العامة. مجموعة المصنفات التي يطابق جزء الشرط لها الحالة الراهنة في لحظة زمنية ما تدعى مجموعة التطابق "Match Set" ويشار إليها بالرمز $[M]$ وكذلك ندعو مجموعة المصنفات الجزئية من $[M]$ التي يوافق جزء الإجراء فيها الإجراء a المختار بمجموعة الإجراء "Action Set" ويرمز لها بالرمز $[A]$.

بفضل ميزة التعميم من الممكن أن تتطابق العديد من المصنفات متمثلة بجزء الشرط مع الحالة الراهنة في الوقت ذاته، هذه المصنفات ليس بالضرورة أن تحدد نفس الإجراء لذلك يجب أن يتضمن النظام آلية لاختيار الإجراء من المجموعة $[M]$ لينفذ، من وجهة نظر التعليم المعزز هذه الآلية يجب أن تستخدم الربح المراكم المتوقع لكل مصنف، وأيضاً يجب أن تتضمن آلية ما للموازنة بين الاستثمار والاستكشاف (Exploration and Exploitation).

3-1-3- آليات تطوير مجموعة المصنفات:

من المهم جداً في نظم المصنفات ضمان وصول المصنف إلى المستوى المثالي من التعميم، وعلى النظام إيجاد المجموعة الأفضل من المصنفات التي تقوم بتغطية كامل فضاء الحالة للمعضلة بشكل مختزل (مضغوط) قدر الإمكان.

الآليات المسؤولة عن هذه الإجرائية تختلف من نظام لآخر، ولكنها جميعاً تقوم على مبدأ واحد وهو إضافة وحذف المصنفات، أحد أكثر الخوارزميات استخداماً في نظم المصنفات LCS هي الخوارزمية الجينية Genetic Algorithm GA.

3-2- العائلات الرئيسية لنظم المصنفات القابلة للتعلم LCS

3-2-1- النظم القائمة على القوة ZCS Strength-based systems:

تعد نظم المصنفات القائمة على القوة الأبسط بين نظم المصنفات، وفيها كل مصنف يحتوي على متغير تقييم وحيد، هذا المتغير مسؤول عن تقدير الربح المتراكم الذي ينتج من تنفيذ المصنف وكذلك مقدار الملاءمة من أجل عملية تطوير مجموعة المصنفات، من أشهر نظم المصنفات المعتمدة على القوة نظام ZCS والذي يعتمد على مجموعة مصنفات عامة [P] ذات حجم ثابت [1]، يبين الشكل (3-1) البنية والآلية العامة للنظام ZCS [2].

3-2-1- اختيار الإجراء:

في نظام ZCS عند تحديد المجموعة [M] يجب أن يتم اختيار إجراء معين منها ليُنفذ، عملية الاختيار هذه تعتمد على آلية عجلة روليت Roulette Wheel Mechanism والتي تسعى لاستكشاف المصنفات، حيث بدلاً من تنفيذ الإجراء المحدد من قبل المصنف الأقوى في المجموعة [M] يتم اختيار الإجراء بشكل احتمالي، حيث يكون لكل مصنف احتمال للتنفيذ

تعتمد قيمته على القوة النسبية للمصنف بالنظر إلى المجموعة [M] كما هو موضح في العلاقة (3-2)، ويتم الاختيار بشكل عشوائي احتمالي بالاعتماد على الاحتمالات المحددة في المجموعة [M].

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (3-2)$$

3-2-1-2- تطوير مجموعة المصنفات:

تعتمد عملية تطوير وتعزيز المصنفات في نظام ZCS على خوارزمية تدعى Bucket Brigade ويختلف تطبيقها هنا عن النظام الأول لهولاند LCS 'Holland حيث لا يتم أخذ أوزان bids للمصنفات [1, 7].


$$\text{Bid}(C,t) = \beta \cdot \text{specificity}(C) \cdot \text{fitness}(C,t) \quad (3-3)$$

وإنما مباشرة يتم الاعتماد على قيم الملاءمة fitness، وتكون آلية العمل لها بالشكل التالي:

- في كل دورة للنظام يتم الاحتفاظ بقيم الملاءمة للمصنفات ضمن المجموعة [A]، وكذلك يجب أن يكون لدينا سجل بمجموعة الإجراء السابقة $[A]_{-1}$ في حال لم تكن خالية حيث سوف تتلقى عناصرها أجزاء متساوية من قيم الملاءمة المحتفظ فيها (للمجموعة [A] الحالية)

- كذلك في حال تلقي مردود من الوسط يتم توزيع جزء ثابت منه بشكل متساوي بين أعضاء المجموعة [A]

- أخيراً هناك ضريبة تُخصم من أعضاء المجموعة [M] التي لا تنتمي للمجموعة [A]، وبالطريقة هذه نقوم بتعزيز فرص الاستفادة من المصنفات ذات الملاءمة الأكبر.



الشكل (3-1): المخطط العام لنظام ZCS

ملاحظة: يختلف نظام ZCS عن نظام هولاند الأول حيث لم يتم اعتبار التخصصية Specificity (وهي عدد الخاصيات غير المعممة في جزء الشرط)، وبالنتيجة النهائية يكون التعديل على قيم ملائمة يخضع للعلاقة التالية:

$$\text{fitness}([A]) \leftarrow \text{fitness}([A]) + \beta [\text{Reward} + \gamma \text{fitness}([A]_{+1}) - \text{fitness}([A])] \quad (3-4)$$

تسمى مثل هذه الآليات التي تستخدم معلومات الحالة الراهنة وكذلك مردود النظام لتعديل معلومات الحالة السابقة بخوارزميات التعلم باستخدام الفروقات المؤقتة Temporal Difference learning TD [3].

3-2-1-3- إنشاء وحذف المصنفات:

في نظام ZCS إضافة وحذف المصنفات يكون من خلال الخوارزمية الجينية ومعامل التغطية Covering Operator.

- في كل لحظة زمنية يوجد احتمال p لتنفيذ الخوارزمية الجينية، وفي حال التنفيذ يتم انتقاء مصنفين من المجموعة العامة باستخدام آلية عجلة روليت معتمدة على قيم الملاءمة fitness للمصنفات، يتم تطبيق الخوارزمية الجينية على هذين المصنفين وينتج اثنين من المصنفات الجديدة يمثلان النسل الجديد وذلك من خلال استخدام معامل العبور بنقطة واحدة one-point crossover وكذلك معامل الطفرة mutation ، قيم الملاءمة في النسل الجديد تكون مساوية لمتوسط الملاءمة في الآباء، ويوضع النسل الجديد في المجموعة العامة للمصنفات [P] حيث تتم عملية استبدال للمصنفين الجدد مع مصنفين يتم اختيارهما باستخدام آلية عجلة روليت معتمدة على قيم مقلوب الملاءمة.
- يتم استدعاء معامل التغطية عندما تكون المجموعة [M] خالية أو في حال أنها تحتوي على مصنفات معدل الملاءمة لهم أصغر من معدل الملاءمة للمجموعة العامة بمقدار يحدد من خلال بارامتر معدل تشغيل معامل التغطية Φ ، حيث يقوم معامل التغطية بإضافة مصنف جديد للمجموعة العامة يكون متطابق مع الحالة الراهنة للوسط والإجراء الخاص به يتم اختياره بشكل عشوائي وقيمة الملاءمة له تكون مساوية لمعدل الملاءمة للمجموعة العامة.

ملاحظة: من أجل تكوين جزء الشرط كل اختبار مرتبط بخاصية لديه احتمال أن يكون # "معظم" بنسبة 33%.

بشكل عام تراجعت الأبحاث المتعلقة بهذا النوع من الأنظمة على حساب عائلة نظم المصنفات المعتمدة على الدقة.

السيئة الرئيسية لنظم ZCS أنه يتم الاحتفاظ بالمصنفات أحياناً بشكل مفرط من دون ضرورة لذلك مما يؤثر على أداء النظام وكذلك على اتخاذ القرارات المثلى، على سبيل المثال لدينا مصنف يمكن تنفيذه في حالتين، في الحالة أولى يكون الإجراء مثالي ويكون النظام قريب لتحقيق الهدف (ربح كبير) وفي الحالة الثانية يكون الإجراء غير مثالي ويكون النظام بعيد عن تحقيق الهدف (ربح قليل)، وبالتالي تكون القوة لهذا المصنف المتوسط بين القيمة المرتفعة والقيمة المنخفضة، قيمة قوة هذا المصنف من الممكن أن تكون أعلى من القيمة المتوقعة للربح في مصنف آخر أكثر تخصص من المصنف الأول ويحدد إجراء مثالي عندما يكون النظام بعيد عن الهدف، بالنتيجة عند تطبيق الخوارزمية الجينية سيكون احتمال الاحتفاظ بالمصنف الأول أكبر من المصنف الثاني الذي هو أكثر فعالية في حالة النظام مازال بعيد عن الهدف. أظهرت بعض الأبحاث أنه من خلال الاختيار الصحيح لبارامترات النظام ZCS يمكن تخطي هذه المشكلة، ولكن نظم XCS المعتمدة على الدقة تعد أكثر فعالية وذكاء ويمكنها التغلب على هذه المشكلة بسهولة، ولذلك تقدمت نظم المصنفات المعتمدة على الدقة أكثر من تلك المعتمدة على القوة.

3-2-2- النظم القائمة على الدقة XCS Accuracy-based Systems:

كما ذكرنا أن المشكلة الأساسية في النظم المعتمدة على القوة ZCS تلك الناتجة عن العمل أو التنفيذ في الأوضاع أو الحالات التي لا تعكس مردود كبير للنظام وبالتالي المصنفات الخاصة بهذه الحالات سيكون احتمال إعادة انتاجها أو تطبيق الخوارزمية الجينية عليها أقل بكثير من

المصنفات المتعلقة بالحالات ذات المردود المرتفع وهنا يظهر لدينا مفهوم المصنف الجشع greedy classifier.

تقوم الفكرة الأساسية لنظم المصنفات المعتمدة على الدقة على الفصل بين إجراءات التعليم المعزز RL وبين عملية تطوير مجموعة المصنفات العامة من خلال تقديم تابع جديد للملاءمة fitness function، والذي لا يتعلق بالربح المتوقع من تنفيذ المصنف وإنما يتعلق بدقة تقدير أو توقع هذا الربح، إذا لم يعد من الضروري بقاء المصنفات ذات الربح الأعلى ولكن المصنفات ذات الدقة الأعلى في تقدير الربح هي التي لديها الاحتمال الأكبر للبقاء، بالنتيجة فإن نظام XCS يتعامل مع الحالات التي لا تعكس مردود كبير بفعالية أكثر من نظام ZCS.

ملاحظة: بالنسبة لآلية التعميم في نظام XCS يتم جمع عدة حالات لها نفس الترميز في جزء الشرط للمصنف الواحد، وبالتالي يجب أن يكون لهذه الحالات قيم مردود أو ربح متقاربة وإلا فإن التنبؤ لن يكون دقيق باستخدام هذا المصنف دوماً.

3-2-1- البنية العامة لنظام XCS:

قبل الخوض في تفاصيل تحديث وتطوير مجموعة المصنفات من خلال إجراءات التعليم المعزز يجب التعرف على بنية نظام XCS، وذلك من خلال التعرف على المكونات العامة للنظام والمكونات الخاصة للمصنف في نظام XCS.

يتكون المصنف من ثلاثة أجزاء رئيسية:

1- جزء الشرط $c \in \{0, 1, \#\}^L$ والذي يحدد حالة الدخل أو الوسط التي يمكن للمصنف أن يُنفذ عندها.

2- جزء الإجراء $a \in \{a_1, a_2, \dots, a_n\}$ يحدد الإجراء المقترح من قبل المصنف في حال التنفيذ.

3- تخمين أو تقدير الربح P وهي قيمة المردود العائد على النظام في حال اختيار المصنف وتنفيذ الإجراء المقترح منه.

وكذلك كل مصنف لديه مجموعة من البارامترات [2,8]:

- 1- خطأ التنبؤ أو التقدير ϵ : يقدر الخطأ المرتكب في عملية التنبؤ بالربح.
- 2- الملاءمة f : تشير إلى ملاءمة المصنف (مؤشر يدل على الدقة في التنبؤ).
- 3- الخبرة للمصنف exp : عبارة عن عداد يشير إلى عدد المرات التي تواجد فيها المصنف منذ بداية وجود ضمن مجموعة الإجراء $[A]$.
- 4- الطابع الزمني $time\ stamp\ ts$: يدل على الزمن الذي تم تنفيذ الخوارزمية الجينية آخر مرة على المجموعة $[A]$ التي كانت تحوي على المصنف المعتبر.
- 5- حجم مجموعة الإجراء $action\ set\ size\ as\ [A]$: معدل حجم المجموعات $[A]$ التي انتمى إليها المصنف.
- 6- الكثافة العددية للمصنف num : ترمز إلى عدد المصنفات التي لها نفس التمثيل في كل الأجزاء، أو بكلام آخر المصنفات المتطابقة لا يُحتفظ بنسخة لكل منها وإنما يستخدم هذا المؤشر ليذل على عددها.

بالنتيجة المصنف مكون من مجموعة من الخواص X_{cl}

$$X \in \{c, a, P, \epsilon, f, exp, ts, as, num\}.$$

أما المكونات العامة لنظام XCS عبارة عن أربع مجموعات من المصنفات وهي:

1- المجموعة العامة للمصنفات [P]: وتحتوي كل المصنفات الموجودة في النظام في أي وقت t .

2- مجموعة التطابق [M]: مجموعة جزئية من [P] والتي تحوي كل المصنفات التي تطابق الحالة الراهنة للوسط $\sigma(t)$.

3- مجموعة الإجراءات [A] مجموعة جزئية من [M] تتضمن كل المصنفات التي تقترح الإجراءات المختار للتنفيذ.

4- مجموعة الإجراءات السابقة 1-[A] مجموعة الإجراءات للنظام في دورة التشغيل السابقة.

وأيضاً لدينا مجموعة من البارامترات العامة في نظام XCS مسؤولة عن عملية التعلم فيه [2,8]:

1-N: يحدد الحجم الأعظمي للمجموعة العامة [P]، أي يجب أن لا يتجاوز مجموع num لكل المصنفات هذا البارامتر (حيث يجب الأخذ بعين الاعتبار الكثافات العددية للمصنفات).

2- β : معدل التعليم للبارامترات P, ϵ, f .

3- α, ϵ_0, v : بارامترات تستخدم في تابع الملاءمة.

4- γ معامل الخصم discount factor: يستخدم في المسائل متعددة الخطوات multi-step لتحديث تقدير المصنفات للربح P .

5- θ_{GA} : العتبة الزمنية لتنفيذ الخوارزمية الجينية: حيث أن الخوارزمية الجينية تُنفذ على مجموعة عندما يكون معدل أزمنة آخر تنفيذ للخوارزمية على أعضاء هذه المجموعة أكبر من θ_{GA} .

6- χ : احتمال تطبيق معامل العبور crossover في الخوارزمية الجينية.

7- μ : تحدد احتمال حدوث معامل الطفرة Mutation في النسل الجديد.

8- θ_{del} : عتبة الحذف للمصنف: في حال كانت خبرة المصنف $\exp$ أكبر من قيمة θ_{del}

عندها سيتم الأخذ بعين الاعتبار ملائمة المصنف f في احتمال الحذف.

9- δ : بارامتر يحدد نسبة من مقدار متوسط الملاءمة في المجموعة العامة $[P]$ ، هذه

النسبة يجب أن تأخذ بعين الاعتبار في احتمال الحذف للمصنف.

10- θ_{sub} : يعالج هذا البارامتر إحدى الآليات من أجل اختزال وضغط التمثيل العام

للنظام (التمثيل بعدد أقل من المصنفات)، حيث توجد آلية تدعى Subsumption

(المكافأة ضمن)، الهدف منها تضمين مصنف في مصنف آخر.

11- $P_{\#}$: احتمال استخدام التعميم $\#$ في جزء الشرط C عند تنفيذ معامل التغطية

وذلك من أجل كل خاصية.

12- $P1, \epsilon1, f1$: القيم الأولية للمصنفات الجديدة.

13- P_{exp} : احتمال اختيار الإجراء بشكل عشوائي.

14- θ_{mna} : يحدد العدد الأصغر من الإجراءات الواجب توفره في $[M]$ وإلا فإن

معامل التغطية سوف يعمل.

15- $doGASubsumption$: بارامتر بولياني يحدد فيما إذا كان النسل الناتج من

الخوارزمية الجينية سيخضع للاختبار من أجل إمكانية المكافأة ضمن الآباء للمصنف.

16- $doActionSetSubsumption$: بارامتر بولياني يحدد فيما إذا كانت مجموعة

الإجراء سوف تخضع للاختبار من أجل البحث عن المصنفات التي يمكن مكافئتها

ضمن الأخرى.

3-2-2-2- اختيار الإجراء:

حاولت الدراسات على نظم XCS إيجاد موازنة بين آلية الاستكشاف والبحث عن مصنفات

جديدة لم تستخدم بعد وبين آلية استثمار المصنفات الجيدة ذات الدقة العالية [1]، هناك العديد

من الخوارزميات التي تدعم هذه الفكرة منها خوارزمية e-greedy، حيث باستخدام هذه الخوارزمية يوجد احتمال P_{exp} لاختيار الإجراء بشكل عشوائي أو يتم الاختيار بشكل حتمي وفق مصفوفة التنبؤ Prediction array التي تحتوي على قيم تدل على الملاءمة وتوقعات المردود للمصنفات وتكون هذه القيم مصنفة على أساس الإجراءات الممكنة (الموجودة في المجموعة $[M]$)، حيث سيتم اختيار الإجراء الذي يملك قيمة الملاءمة الوسطية الأعلى.

ملاحظة: مصفوفة التنبؤ تُشكل من خلال حساب قيمتين لكل إجراء في المجموعة $[M]$ - القيمة الأولى هي مجموع حاصل ضرب الملاءمة بقيمة التنبؤ بالربح لكل المصنفات التي تدعم كل إجراء في المجموعة $[M]$ ، والقيمة الثانية مجموع قيم الملاءمة لهذه المصنفات ذات الإجراء المشترك، ومن هاتين القيمتين ينتج لدينا معدل الملاءمة الموزونة بالنسبة للتنبؤ بالربح الناتج عن كل إجراء في $[M]$ [2].

$$P_k = \frac{\sum_j F_j p_j}{\sum_j F_j} \quad (3-5)$$

3-2-2-3- تطور المصنفات:

خوارزمية تطوير وتحديث المصنفات في نظام XCS أقرب ما تكون إلى خوارزمية Q-learning، في كل مرة يدخل فيها المصنف ضمن المجموعة $[A]$ يتم تحديث بارامترات الخبرة (exp) وخطأ التنبؤ (ϵ) والتنبؤ (P) وتخمين حجم مجموعة الإجراء (as) والملاءمة (f)، بنفس الترتيب المذكور، التحديثات أو التغيرات على المصنف يمكن أن تقسم إلى طورين، يتم تنفيذ الطور الأول حيث تحدث البارامترات ϵ و P و as إلى قيم جديدة مساوية لمتوسط القيم السابقة والحالية، أو يتم تنفيذ الطور الثاني عندما يكون المصنف قد نُفِّذَ أو لديه خبرة

بمقدار $(\frac{1}{\beta})$ وعندها يتم التحديث باستخدام معدل التعليم β ، المعادلات التالية توضح هذين الطورين [2]:

$$\text{exp} = \text{exp} + 1 \quad (3-6)$$

$$\epsilon = \begin{cases} \epsilon + \frac{|P - 'P| - \epsilon}{\text{exp}} & \text{if } (\text{exp} < \frac{1}{\beta}) \\ \epsilon + \beta * (|P - 'P| - \epsilon) & \text{otherwise} \end{cases} \quad (3-7)$$

$$'P = \begin{cases} 'P + \frac{(P - 'P)}{\text{exp}} & \text{if } (\text{exp} < \frac{1}{\beta}) \\ 'P + \beta * (|P - 'P|) & \text{otherwise} \end{cases} \quad (3-8)$$

$$\text{as} = \begin{cases} \text{as} + \frac{(\sum_{j \in [A]} \text{num}_j - \text{as})}{\text{exp}} & \text{if } (\text{exp} < \frac{1}{\beta}) \\ \text{as} + \beta * (\sum_{j \in [A]} \text{num}_j - \text{as}) & \text{otherwise} \end{cases} \quad (3-9)$$

يعد تعديل الملاءمة f للمصنفات أكثر تعقيداً و يطبق على كافة المصنفات في المجموعة $[A]$ بنفس الوقت، حيث أولاً يتم حساب الدقة κ للمصنفات، ومن أجل ذلك يتم مقارنة خطأ التنبؤ مع البارامتر ϵ_0 (حيث يعتبر أي قيمة للخطأ أقل من ϵ_0 مهمة ويعتبر المصنف دقيق ويكون $\kappa = 1$)، عدا ذلك قيمة κ تعرف من خلال البارامترات ϵ_0 ، α ، v


$$\kappa = \begin{cases} 1 & \text{if } (\epsilon < \epsilon_0) \\ \alpha * \left(\frac{\epsilon}{\epsilon_0}\right)^{-v} & \text{otherwise} \end{cases} \quad (3-10)$$

بعد ذلك يتم حساب الدقة النسبية κ' للمصنف بالنسبة للمجموعة $[A]$ من خلال العلاقة:

$$\kappa' = \frac{\kappa * \text{num}}{\sum_{j \in [A]} (\kappa_j * \text{num}_j)} \quad (3-11)$$

وأخيراً يتم حساب قيمة الملاءمة الجديدة من العلاقة التالية:

$$f = f + \beta * (\kappa' - f) \quad (3-12)$$



الشكل (3-2): المخطط العام لنظام XCS

3-2-2-4- إنشاء وحذف المصنفات:

إنشاء المصنفات الجديدة يعتمد على الخوارزمية الجينية ومعامل التغطية ولكن وعلى خلاف نظام ZCS المعتمد على القوة فإن الخوارزمية الجينية تطبق على المجموعة [A] بدلاً من المجموعة العامة للمصنفات [P]، وهذا يؤدي إلى المنافسة بين المصنفات التي تتطابق مع نفس الحالة، يتم اختيار الآباء من خلال خوارزمية عجلة روليت معتمدة على احتمالات متناسبة مع ملائمة المصنفات، ويتم وضع مصنفي النسل الناتج ضمن المجموعة العامة [P] بعد تطبيق معامل الطفرة Mutation ومعامل العبور Crossover عليهما ويكون (, num = 1

(exp = 0) لهما، أما البارامترات f ، ϵ ، P فتوضع مساوية لمتوسط هذه القيم في المصنفين الآباء.

كذلك يتم استدعاء معامل التغطية لإضافة مصنفات عندما لا يتوفر في المجموعة $[M]$ إجراءات كافية للاختيار منها، لذا يجب إضافة مصنفات تحدد الإجراءات المفقودة ويكون جزء الشرط لها موافق للحالة الراهنة، ويوجد احتمال $P_{\#}$ لكل خاصية في جزء الشرط أن تكون معممة $\#$.

في نظام XCS حجم المجموعة العامة $[P]$ محدود، لذلك عند إضافة أي مصنف يجب التحقق من إمكانية الإضافة المباشرة وإلا فإنه يجب حذف عدد من مصنفات مساوي لعدد المصنفات المراد إضافتها ليحل مكانها المصنفات الجديدة.

تعتمد آلية حذف المصنفات على نقطتين:

- الحفاظ بشكل تقريبي على حجم تمثيل متساوي لكل أجزاء الوسط أو بكلام آخر الحفاظ

على حجم متساوي لكل مجموعات الإجراءات $[A]$

- التخلص من المصنفات ذات الملاءمة المنخفضة

آلية الحذف المستخدمة هي آلية خوارزمية عجلة روليت معتمدة على قيمة مقياس يدعى اقتراح الحذف deletion vote، من خلال هذا المقياس يتم تقييم حذف المصنف.

يتم حساب هذا المقدار لكل المصنفات في المجموعة العامة $[P]$ وفق المعادلة التالية:

$$\text{Deletion vote} = \begin{cases} as * num \text{ if } exp < \theta_{del} \text{ or } \frac{f}{num} \geq \delta * \frac{\sum_{j \in [P]} f_j}{\sum_{j \in [P]} num_j} \\ \frac{as * num * \frac{\sum_{j \in [P]} f_j}{\sum_{j \in [P]} num_j}}{\frac{f}{num}} & otherwise \end{cases} \quad (3 - 13)$$

هناك أيضاً عمليتين إضافيتين للتحكم بحجم المجموعة العامة [P]:

عند إنشاء مصنف جديد من المحتمل أن يكون هذا المصنف موجود في المجموعة العامة من قبل، فبدلاً من الاحتفاظ بنسختين من نفس المصنف يتم الاحتفاظ بمصنف واحد ولكن نقوم بزيادة الكثافة العددية له num وهنا يظهر مفهوم المصنفات الفرعية أو المصغرة macro-classifier المستخدم في نظام XCS، ويكون الحجم الكلي للمجموعة العامة عبارة عن مجموع الكثافات العددية لكل المصنفات.

أيضاً يوجد آلية مكافأة المصنفات Subsumption والتي تتعامل مع المصنفات المعممة ضمن المجموعة العامة، حيث عند إنشاء مصنف جديد تقوم هذه الآلية بالتحقق فيما إذا كان يوجد مصنف آخر دقيق بشكل كافٍ يمكن مكافأة المصنف الجديد فيه (حيث سيكون المصنف الموجود مسبقاً أكثر تعميماً)، في حال وجود مثل هذا المصنف تتم زيادة الكثافة العددية له بدلاً من إضافة المصنف الجديد.

ملاحظة: تتطلب هذه الآلية الكثير من المعالجة وقد تؤثر سلباً على أداء النظام لذلك لا تستخدم دوماً.

3-3 - استخدام نظام XCS مع قيم دخل مستمرة:

تحدثنا عن نظم المصنفات المعتمدة على الدقة XCS وإمكانية تطبيقها في العديد من المجالات وضمان مستوى أعظمي دقيق من التعميم، ولكن من أهم الأمور التي تم التطرق لها في الأوراق [13, 14] هي استخدام هذه النظم XCS في معضلات التصنيف Classification التابعة لمدخلات لها قيم حقيقية أو مستمرة.

في معضلات التصنيف من المحتمل جداً الاعتماد على متغيرات مستمرة كدرجة الحرارة أو التركيز أو العمر في اتخاذ القرار، حيث انتماء متغير إلى مجال ما يعني أنه ضمن صنف معين انتماءه لمجال آخر يعني أنه يعود لصنف آخر وهكذا.

تم تطوير نظام XCSR للتعامل مع قيم دخل مستمرة، وهو عبارة عن امتداد لنظام XCS ولكن عدل للتعامل مع مثل هذه القيم للدخل [13].

3-3-1- مثال عن الأنظمة ذات المداخل المستمرة:

الناخب المنطقي ذو المداخل الحقيقية Real Multiplexer

في ورقة البحث [13] تم استخدام مسألة تصنيف لا خطي بقيم دخل حقيقية لاختبار النظام XCSR، وللتبسيط تم اعتبار الدخل هو شعاع من عدة مكونات $x = (x_0, x_1, \dots, x_n)$ وكل مكون x_i محدود بالمجال $0.0 \leq x_i \leq 1.0$ (ويمكن التعديل حسب قيم المجالات المطروحة في المسألة)، وتم اعتبار أنه لدينا فقط صنفين (0) و (1)، على سبيل المثال في نظام التشخيص المرضي (0) تعني عدم الإصابة بالمرض و (1) تعني الإصابة، وتكون قيم التصنيف الناتج حسب قيم متغيرات الدخل فيما إذا كانت تنتمي لمجال ما أو لا، مثلاً:

$$(0.31 \leq x_1 \leq 1.0) \text{ and } (0.12 \leq x_2 \leq 0.38) \rightarrow class1$$

في ضوء هذه الفرضيات، المعضلة المطروحة في [13] هي ملائمة معضلة الناخب المنطقي البولياني بستة مداخل (Boolean 6-multiplexer) للتعامل مع القيم الحقيقية.

في هذه المعضلة يكون الدخل عبارة عن سلسلة مكونة من ستة بتات وللخرج قيمة منطقية (0 أو 1)، إحدى الطرق المعالجة والحصول على الخرج هي اعتبار أول بتين يعنونان واحد من البتات الأربعة الأخرى، على سبيل المثال: على فرض لدينا السلسلة "011010"، أول بيتين

"01" يعنونان البت ذو العنوان 1 وقيمته "0"، بطريقة أخرى يمكن كتابة التابع المنطقي لوظيفة الناخب البوليني بست مداخل:

$$F_6 = b'_0 b'_1 b_2 + b'_0 b_1 b_3 + b_0 b'_1 b_4 + b_0 b_1 b_5$$

من أجل معضلة الناخب الحقيقي ذو ستة مداخل "RF6 Real – 6-multiplexer"، نفرض أنه لدينا شعاع دخل مكون من ستة مداخل $x = (x_0, x_1, \dots, x_5)$ حيث $0 \leq x_i < 1$ ولدينا العتبة θ_i حيث $0 \leq \theta_i < 1$ ، ويتم تفسير x_i على أنها "0" في حال $x_i \leq \theta_i$ أو "1" عدا ذلك، وقيمة التابع RF6 هي نفسها قيمة التابع F6 بعد أن يتم تطبيق عملية التفسير هذه على سلسلة الدخل.

من المفترض أن يقوم نظام XCSR بتعلم قيم الخرج للتابع RF6 وبالطبع ليس لديه أي معلومات مسبقة عن θ_i أو F6.

3-2-3- الاختلافات عن نظام XCS:

يوجد ثلاثة اختلافات رئيسية بين النظامين XCS وXCSR وهي في النقاط التالية:

- شكل الدخل.

- معامل الطفرة.

- معامل التغطية.

هذه الاختلافات ناتجة من اختلاف جزء الشرط فبدلاً من استخدام سلسلة مكونة من الثلاثية $\{0, 1, \#\}$ يتم استخدام تتابع من محددات المجالات Interval predicates ولها الشكل $int_i = (c_i + s_i)$ حيث أن s_i و c_i قيم حقيقية.

لتعريف معضلة الناخب الحقيقي بالمدخل الستة يُستخدم مصنفات ذات جزء شرط له ستة من محددات المجالات، ويكون شرط التطابق للدخل x هو: $c_i - s_i \leq x_i \leq c_i + s_i$ من أجل كل المدخل x_i ، ويكون المتغير c_i مركز المجال المحدد int_i و s_i امتداد المجال حول المركز c_i .

ملاحظة: ضمن إطار هذا التعريف يكون عدد القيم "alleles" هو ضعف عدد المكونات أو الخاصيات الموجودة في جزء الشرط.

معامل العبور crossover في نظام XCSR يشابه معامل العبور في نظام XCS حيث يمكن أن تكون نقطة العبور crossover point داخل المحدد للمجال (أي سيكون العبور أو التغيير في قيم المجالات أيضاً) وكذلك يمكن أن يكون العبور بين المحددات نفسها مثلاً: أول محددين من المصنف الأول والباقي من المصنف الثاني دون تغيير القيم.

أما معامل الطفرة Mutation فيختلف، من خلال إضافة مقدار معين للمجال $\pm amount$ حيث $rand(m)$ حيث $m = 0.1$ غالباً والتابع $rand$ يعطي قيمة حقيقية عشوائية $rand(m) = [o, m[$ ، أما الإشارة فيتم اختيارها بشكل احتمالي عشوائي.

وكما نعلم أن معامل التغطية يحدث عندما لا يوجد أي مصنف يتطابق مع الحالة الراهنة للوسط X ، في نظام XCSR سيكون المصنف الجديد له المكونات $(c_0, s_0, c_1, s_1, \dots, c_5, s_5)$ حيث $c_0 = x_i$ و $s_i = rand(S_0)$ حيث $S_0 = 0.5$ غالباً، ويتم إنشاء مصنف موافق لدخل الحالة من أجل كل إجراء ممكن كما هو الحال مع أنظمة XCS المعتمدة على الدقة، وفي حال أن المجموعة العامة قد بلغت الحد الأعظمي لعدد المصنفات المسموح عندها يجب حذف مصنفات أخرى لتحل محلها المصنفات الجديدة الناتجة من عملية التغطية.

ملاحظة: غالباً لن تكون عملية الحذف ضرورية حيث في البداية تكون المجموعة العامة [P] فارغة ونحتاج التغطية غالباً في البدايات عندما لا تتواجد المصنفات الكافية لتغطية كافة الحالات.

الفصل الرابع: نظم المصنفات الاستباقية

Anticipatory Learning Classifier

Systems ALCS

البنية والآليات المرافقة

4. نظم المصنفات الاستباقية القابلة للتعلم ALCS

4-1 - مقدمة:

على الرغم من أن نظم المصنفات الاستباقية ALCS تتشارك مع نظم المصنفات الأخرى في الخواص العامة إلا أنها تختلف عنها في إحدى أهم النقاط الأساسية، فبدلاً من استخدام مصنفات لها الشكل (شرط $\leftarrow$ إجراء) تستخدم مصنفات (شرط، إجراء $\leftarrow$ التأثير).


$$[Condition] , [Action] \rightarrow [Effect] \quad (4-1)$$

يمثل جزء التأثير effect في المصنف التأثير الناتج أو الحالة التالية المتوقعة من تنفيذ الإجراء المحدد في المصنف عند تفعيل هذا المصنف في أحد الحالات أو الأوضاع الموافقة للشرط الخاص به.

من وجهة نظر التعليم المعزز RL تُكوّن مجموعة مصنفات من هذا النوع ما يسمى بنموذج الانتقالات Model of transitions، وبناءً على ذلك يمكن اعتبار نظم ALCS لها بنية نظم التعليم المعزز المعتمدة على نموذج model-based RL حيث تكون بنية هذه النظم هي DYNA architecture، بالنتيجة نظم ALCS تجمع بين خاصيتين أساسيتين لأنظمة التعليم المعزز حيث أن لها بنية ديناميكية DYNA تقوم بتعلم نموذج للانتقالات وبالتالي يصبح لديها إمكانية للتخطيط أو التنبؤ وتزيد من سرعة التعلم، ولا ننسى خاصية التعميم موجودة أيضاً في نظم ALCS كما هو الحال مع كل نظم المصنفات القابلة للتعلم LCS، بالنتيجة تقوم هذه النظم ببناء نموذج مختزل ومضغوط أكثر من بنية DYNA الجدولية [1].

ملاحظة: يبين الشكل (4-1) بنية DYNA، وتستخدم مثل هذه البنى من أجل إجراء عمليات التعلم والتخطيط في نفس الوقت، حيث يكون لدينا نموذج للمعضلة ويتم من خلاله توليد الخبرات أو القرارات الآنية، وتستخدم المعلومات المؤكدة (الحقيقية) من أجل تعلم مثل هذه

النموذج وتطويره، بكلام آخر تستخدم الخبرة الحقيقية من أجل التعليم (تعلم النموذج) وتستخدم الخبرة الآنية (استخدام النموذج) من أجل التخطيط للإجراءات المستقبلية [10].




الشكل (4-1): المخطط العام لبنية DYNA

4-2- النظام ACS Anticipatory Classifier System

عبارة عن خوارزمية تعلم مبنية بالاعتماد على نظم المصنفات القابلة للتعلم LCS وتعتمد على آلية تدعى "التحكم السلوكي الاستباقي (التوقعي) Anticipatory Behavioral control"، يتم تمثيل المعرفة في نظام ACS من خلال مصنفات لها الشكل شرط - إجراء - توقع (C - A - E)، ومن خلال مقارنة الحالة R الناتجة من تنفيذ الإجراء A والحالة المتوقعة من تنفيذه E يقوم نظام ACS ببناء هذه المصنفات، ودوماً تتم البداية مع معرفة معمة جداً ومن خلال عملية التعلم يتم تحديد وتخصيص هذه المعرفة [5].

يتميز نظام ACS بمقدرته على التعلم الكامن latent learning وهو التعلم في حال غياب المردود أو الربح الوارد من الوسط، وكذلك يمكن استخدام المصنفات C-A-E من أجل عملية التخطيط للإجراءات المناسبة للوصول إلى الهدف.

4-2-1- التحكم السلوكي الاستباقي Anticipatory Behavioral Control:



الشكل (2-4): التعليم السلوكي الاستباقي

ويبين الشكل (2-4) آلية التعلم باستخدام التحكم السلوكي الاستباقي، حيث لدينا الثلاثية S - R - E.

S: تمثل الحالة المدركة أو المحسوسة.

R: تمثل الإجراء المتخذ.

E: الحالة التالية المتوقعة من تنفيذ الإجراء A.

ويتم وضع أربع فرضيات من أجل هذه الآلية:

1- يتم ربط كل إجراء بحالة متوقعة (مرغوبة بالنسبة للإجراء) E_{ant} .


2- يتم تعزيز الروابط بين الإجراءات والتوقعات الخاصة بها.

3- وثوقية العلاقة إجراء - تأثير تعتمد على الشرط أو الحالة S_{start} ، وعلى هذه الأساس يتم التمييز بين خصائص الحالات أو الأوضاع الممكنة للوسط.

4- التعزيز Reinforcement والتمايز Differentiation تعتمد على المقارنة بين التأثير المتوقع لتنفيذ إجراء E_{ant} والنتيجة الحقيقية لتنفيذ الإجراء E_{real} .

4-2-2- المكونات الرئيسية:

يقوم نظام ACS بالتعلم في بيئة متعددة الخطوة multi-step environment حيث عندما يتم تنفيذ إجراء معين سيؤدي إلى حالة جديدة للوسط يتم التعامل معها. يبين الشكل (3-4) التفاعل بين البيئة والعميل ACS حيث في اللحظة الزمنية t يدرك العميل حالة الوسط $\sigma(t)$ ويتلقى المردود من الوسط $p(t)$ وعلى أساس $\sigma(t)$ و $p(t)$ يقوم العميل باختيار إجراء $\alpha(t)$ ، تنفيذ هذا الإجراء يؤدي إلى حالة ومردود جديدين $p(t+1)$ و $\sigma(t+1)$ يجب أن يقوم العميل بالتعامل معهما.



الشكل (3-4): التفاعل بين الوسط والعميل ACS

يتألف نظام ACS من المكونات الرئيسية التالية:

1- واجهة الدخل: عبارة عن مجموعة الحساسات والكواشف التي تمثل حالة الوسط σ .

2- واجهة الخرج: مجموعة الأدوات المسؤولة عن تنفيذ الإجراء α .

3- قائمة المصنفات: مجموعة من القواعد ذات الشكل $C - A - E$.

4- قائمة الرسائل: تحتوي على الرسائل المتبادلة بين المكونات السابقة.

في حالة التمثيل الثنائي (0-1) للوسط، جزأي الشرط والنتيجة يأخذان القيم من الثلاثية $C, E \in \{0, 1, \#\}$ ، حيث أن الرمز # في الشرط يعني "غير مهم" أو بكلام آخر سيتم إهمال الحساس أو الكاشف المتعلق، أما في النتيجة يعني الرمز # "عدم التغيير Pass-through". أي أن نظام ACS يتوقع بأن الدخل الموافق سيبقى على حاله بعد اتخاذ الإجراء A المحدد في المصنف.

ويوجد في كل مصنف بارامترين الجودة q والتي تعبر عن دقة التوقع، وكذلك الربح المتوقع r يقوم بالتنبؤ بمقدار المردود المتوقع من الوسط.

4-2-3- الخوارزمية العامة:

يبين الشكل (4-4) الأفعال السلوكية الأساسية في نظام ACS

1- في اللحظة الزمنية t يقوم العميل بإدراك حالة الوسط $\sigma(t)$ وتوضع في قائمة الرسائل وتسمى S_t .

2- يتم مقارنة S_t مع الشرط لكل المصنفات في المجموعة العامة والمصنفات المطابقة تشكل مجموعة التوافق $[M]$.


3- يتم اختيار مصنف واحد من المجموعة $[M]$ إما باستخدام تقنية عجلة روليت أو بشكل عشوائي باحتمال P_x (احتمال الاستكشاف).

عند استخدام تقنية عجلة روليت احتمال اختيار مصنف ما هو:

$$f_{C_i} / \sum_{C \in [M]} f_C \quad (4-1)$$

حيث أن f_{C_i} هي ملائمة المصنف وتعطى بالعلاقة:

$$f_c(t) = q_c(t) \cdot r_c(t) \quad (4-2)$$



الشكل (4-4) الأفعال السلوكية في نظام ACS

4- بعد تفعيل أحد المصنفات وباعتبار الحالة الراهنة للوسط S_t والتوقع للمصنف E يتم

إضافة رسالة جديدة يكون فيها الحالة المتوقعة S_{t+1}^{ant} وتحسب بالشكل $S_{t+1}^{ant} = passthrough(S_t, E_j)$ ، وكذلك يتم تفعيل الإجراء المحدد في المصنف.

5- بعد تنفيذ الإجراء $\alpha(t)$ يتم التحسس لحالة الوسط الجديدة $\sigma(t+1)$ وتوضع في قائمة الرسائل S_{t+1} .

- 6- تتم مقارنة S_{t+1} و S_{t+1}^{ant} وعلى أساس نتيجة المقارنة يتم تعديل قائمة المصنفات وتفعيل إجراءات التعليم الاستباقي anticipation-learning (الفقرة 4.2.5).
- 7- يتم حذف S_t و S_{t+1}^{ant} ، وعلى أساس S_{t+1} يتم تنفيذ إجراء سلوكي آخر.

4-2-4- خوارزمية التعليم الأساسية:

يوجد جزئين أساسيين للتعليم في نظام ACS، التعليم الاستباقي وتعليم المردود.

4-2-4-1- التعليم الاستباقي Anticipation Learning:

الفكرة الأساسية في التعلم الاستباقي بسيطة حيث أنه في حال تم توقع S_{t+1} بشكل صحيح (S_{t+1} تطابق S_{t+1}^{ant}) سيتم زيادة جودة المصنف q ، وفي حال العكس سيتم توليد مصنف جديد يقوم بعملية التنبؤ بشكل صحيح، وفي حال أنه من غير الممكن إنشاء مثل هذا المصنف يتم إنقاص جودة المصنف المختار.

بشكل مشابه لخوارزمية bucket brigade [5,3] يتم استخدام أوزان المحاولة bid ratio b_q لتعديل قيم جودة المصنفات حيث $b_q \in [0,1]$ ، ويمكن التمييز بين أربعة حالات:

1- حالة عديمة الجدوى:

إذا كان الإجراء السلوكي المتخذ لا يقوم بتغيير أي شيء في الوسط، عندها فإن جودة المصنف سوف تصبح أصغر وفق العلاقة

$$q_c(t+1) = (1 - b_q) \cdot q_c(t) \quad (4-3)$$

2- حالة متوقعة:

إذا كان اتخاذ الإجراء قد غير في الوسط و S_{t+1} تطابق S_{t+1}^{ant} فعندها جودة المصنف سوف تصبح أكبر وفق العلاقة

$$q_c(t+1) = (1 - b_q) \cdot q_c(t) + b_q \quad (4-4)$$

3- حالة قابلة للتصحيح:

إذا كانت S_{t+1} لا تطابق S_{t+1}^{ant} وتنفيذ الإجراء أدى إلى تغيرات في الوسط، وكل المكونات أو الخصائص في جزأي الشرط C والتأثير E (للمصنف الفعال) التي لا يوجد عندها تطابق بين S_{t+1} و S_{t+1}^{ant} عبارة عن رموز "#"، فعندها يمكن الحصول على مصنف جديد

$$C_{new} = C_{new} - A_{new} - E_{new} \quad (4-5)$$

حيث يكون $A_{new} = A$ أما C_{new} و E_{new} يختلفان عن C و E عند المكونات غير المتطابقة، عندها تكون E_{new} مساوية لـ S_{t+1} و C_{new} مساوية لـ S_t ، وبالتالي تبقى C_{new} موافقة لـ S_t و E_{new} تقوم بتوقع S_{t+1} بشكل صحيح.

4- حالة غير قابلة للتصحيح:

في حال أن S_{t+1} لا تطابق S_{t+1}^{ant} ومن غير الممكن تصحيح المصنف كما مر معنا في الحالة السابقة، عندها يجب أن تصبح قيمة جودة المصنف أصغر كما في الحالة عديمة الجدوى، يمكن النظر إلى جودة المصنف $q_c(t)$ على أنها احتمال أن تتطابق S_{t+1} مع S_{t+1}^{ant} .

حتى الآن لدينا خوارزمية قادرة على إنشاء مصنفات جديدة ولكنها لا تستطيع حذف المصنفات، لذلك يتم تعريف العتبة $Q_i \in [0,1]$ في حال كانت جودة المصنف أقل من هذه العتبة يعتبر هذا المصنف غير ملائم (غالباً تكون قيمتها $Q_i = 0.1$).

وأيضاً لدينا عتبة أخرى $Q_r \in [0,1]$ وهي عتبة الموثوقية فعندما يكون $q_c \geq Q_r$ يمكن اعتبار المصنف موثوق أي أن احتمال التوقع بشكل صحيح من خلال هذا المصنف يكون مرتفع (غالباً تكون قيمتها $Q_r = 0.9$).

4-2-4-2- Reward learning: تعليم المردود

يستطيع نظام ACS التعلم من دون تلقي أي مردود من الوسط من خلال تقنية التعليم التوقعي أو الاستباقي، ولكن في حال كان النظام يتلقى مردود من الوسط يمكن التعامل مع نظام ACS كباقي نظم المصنفات القابلة للتعلم LCS من خلال استخدام أحد تقنيات التعليم المعزز RL حيث وفقاً لـ [5] تم استخدام آلية bucket brigade لتحديث قيم المردود المتوقع للمصنفات، وأيضاً يتم استخدام معدل المحاولة للمردود $b_r \in [0,1]$.

على اعتبار أن المصنف cl_t هو المصنف الفعال في اللحظة الزمنية t والمصنف cl_{t+1} هو الفعال في اللحظة الزمنية $t+1$ يكون تحديث توقع المردود كما يلي:

$$\text{if } p(t+1) \neq 0 \rightarrow r_{cl_t}(t+1) = (1 - b_r) \cdot r_{cl_t}(t) + b_r \cdot p(t+1) \quad (4-6)$$

$$\text{if } p(t+1) = 0 \rightarrow r_{cl_t}(t+1) = (1 - b_r) \cdot r_{cl_t}(t) + b_r \cdot r_{cl_{t+1}}(t) \quad (4-7)$$

4-2-4-5- تطبيق عملي:

1- في ورقة البحث [5] تم تطبيق نظام ACS على عميل موجود ضمن متاهة مكونة من خلايا، هذه الخلايا لها ثلاث حالات ممكنة إما فارغة يمكن للعميل التواجد فيها أو فيها عائق T لا يمكن التواجد فيها أو أن الخلية تكون هي خلية الهدف F المراد الوصول إليها مثل هذه الأوساط تسمى "Woods Environment" والشكل (4-5) يبين بعض الأمثلة منها.

2- في مثل هذه الحالات يكون الهدف هو تعلم الطريق الأقصر للوصول إلى الخلية المطلوبة (الهدف) ولكن في ورقة البحث [5] لدى العميل مهمة إضافية وهي تعلم نموذج داخلي للوسط، إجرائية التعليم في مثل هذه الأوساط مكونة من عدة تجارب أو محاولات كل محاولة تنتهي إما بالوصول إلى الهدف أو عند بلوغ عدد الخطوات المنفذة

الحد الأعظمي المسموح والمحدد بالبارامتر MaxStep (يستخدم لمنع حدوث حلقات غير منتهية)

T	T	T	T
T	2	F ₁	T
T	3	T	T
T	4	5	T
T	6	T	T
T	T	T	T

MazeF1

T	T	T	T	T
T	3	2	F ₁	T
T	4	T	T	T
T	5	6	T	T
T	7	T	T	T
T	T	T	T	T

MazeF2

T	T	T	T	T	T
T	4	3	2	F ₁	T
T	5	T	T	T	T
T	6	7	8	T	T
T	7	T	T	T	T
T	T	T	T	T	T

MazeF3

T	T	T	T	T	T	T
T	5	4	3	2	F ₁	T
T	6	T	T	T	T	T
T	7	8	9	10	T	T
T	11	T	T	T	T	T
T	T	T	T	T	T	T

MazeF4

الشكل (4-5): Woods Environment

3- نماذج الأوساط المبينة في الشكل (4-5) كلها أوساط حتمية deterministic أي أن $\sigma(t+1)$ تحدد فقط من خلال $\sigma(t)$ و $\alpha(t)$ ، ولكن من وجهة نظر العميل فإن MazeF4 ليست حتمية حيث أن الخلية 3 والخلية 9 لهما نفس الترميز وبالتالي لا يمكن للعميل التمييز بينهما وبالتالي فإن الإجراء التوجه نحو اليمين $\rightarrow$ east قد يؤدي إلى الخلية 2 أو الخلية 10، تدعى هذه الحالة بمشكلة الإدراك الزائف The perceptual aliasing problem.

4- في نهاية كل محاولة للعميل يتم حساب مقدار المعرفة المحققة "achieved knowledge"، ومن أجل ذلك يتم التحقق فيما إذا كان هناك مصنف موثوق من أجل كل انتقال (σ_1, a, σ_2) حيث $\sigma_1 \neq \sigma_2$.

5- في ورقة البحث [5] يقدر عدد الخطوات للوصول للهدف بالمتوسط لآخر 50 محاولة لذلك تأخذ النتائج من بعد أول 50 محاولة.

6- تقسم عملية التعليم إلى قسمين يتم في الأول الاستكشاف للمصنفات والاستثمار وفق آلية احتمالية كما ذكرنا من قبل، وفي الثاني يتم حصر الاستثمار للمصنفات الأفضل.

4-2-6- تحديد المكونات الثابتة (غير المتغيرة)

كما ذكرنا من قبل في حال كان لدينا توقع خاطئ وحالة قابلة للتصحيح يتم تغيير أو تحديد المكونات المعممة التي تغيرت نتيجة لاتخاذ الإجراء، ويتم انتاج مصنف جديد. وبالتالي حتى الآن نظام ACS غير قادر على معالجة الحالات التي لا يؤدي اتخاذ الإجراء إلى تغيير قيم المكونات غير المتطابقة.

لتكن لدينا S_1 الحالة الراهنة للوسط والمصنف $c = C - A - E$ هو المصنف الفعال، وعند تطبيق هذا المصنف لم يحقق التنبؤ بشكل صحيح (لم يؤدي إلى الحالة المتوقعة) وكانت الحالة غير قابلة للتصحيح، فعندها يتم الاحتفاظ بقيمة S_1 لدى المصنف كعلامة Mark. وفي حال كان لدينا S_2 حالة للوسط وتم تفعيل نفس المصنف C وأدى إلى تنبؤ صحيح (الحالة المتوقعة صحيحة)، فعندها يتم اختيار خاصية بشكل عشوائي من مجموعة الخاصيات التي تحقق التالي:

S_1 تختلف عن S_2 عند هذه الخاصية و أيضاً C و E للمصنف عبارة عن رموز "#" عند المكان الموافق للخاصية.

فإذا وجدت مثل هذه الخاصية ا يتم تغيير القيمة الموافقة في C و E إلى ما يقابلها في S_2 . يتم تحديد العدد الأعظمي لعمليات تخصيص المكونات غير المتغيرة من خلال البارامتر U_{max} ، وكذلك يمكن تحديد العدد الاعظمي لعمليات تحديد المكونات المتغيرة (الحالات القابلة للتصحيح) من خلال البارامتر C_{max} ولكن لم يتم استخدام هذا البارامتر في ورقة البحث [5].

مثال:

على فرض أنه لدينا عميل قائم على نظام ACS موجود في بيئة MazeF2 المبينة في الشكل (4-5)، وأحد مصنفات هذا العميل هو: $###f#tbb - \rightarrow - ###b#btt# .c =$

فإذا كانت الحالة الراهنة للوسط هي $\sigma = 5$ ($S = \text{btbtbttt}$) يمكن لهذا المصنف أن يكون فعال ويكون لدينا حالة غير قابلة للتصحيح فيوضع للمصنف علامة ($M = S$).
وبعدها يمكن للمصنف أن يكون فعال في $\sigma = 3$ ($S = \text{ttbtbttt}$) ويؤدي إلى الحالة المتوقعة بشكل صحيح، وعندها تتم مقارنة M مع S وتطبيق آلية تحديد المكونات الثابتة يكون لدينا مصنف جديد $\text{t\#f\#tbb\#} \rightarrow \text{t\#b\#btt\#}$ ، وسيكون هذا المصنف فعال وموثوق ويؤدي إلى الحالة المتوقعة لأنه أصبح يطبق في $\sigma = 3$ فقط.

4-2-7- الأوساط غير الحتمية:

تناقش هذه الإضافة لنظام ACS إمكانية النظام على التعامل مع نوع خاص من الحالات التي لا تخضع لخاصية ماركوف non-Markov stats، أو بكلام آخر نوع خاص من الأوساط أو البيئات غير الحتمية non-deterministic environment.

4-2-7-1- الإدراك الزائف للحالات:

كما ذكرنا الوسط في MazeF4 غير حتمي من وجهة نظر العميل حيث لا يمكن التمييز بين الحالتين (3) و (9)، تدعى مثل هذه الحالات بالحالات الزائفة aliasing state. على فرض أن S_t هي حالة زائفة ويكون لدينا تسلسل من الحالات والإجراءات $S_0, a(0)$ ، فيكون $S_t, a(t) \dots$.

$$P\{S_{t+1}/a(t), S_t, \dots \dots \dots a(0), S_0\} = 1 \text{ and}$$

$$P\{S_{t+1}/a(t), S_t\} \neq P\{S_{t+1}/a(t), S_t, \dots \dots \dots a(0), S_0\}$$

يوجد عدة أبحاث لمعالجة مثل هذه الحالات مع نظم XCS و ZCS وترتكز بشكل أساسي على إضافة ذاكرة للنظام، أما مع نظام ACS فيستخدم تقنية تدعى تجزئة الإجراء Action Chunking [11].

ولكن قبل الخوض في تفاصيل هذه التقنية نحتاج لمعيار من أجل كشف الحالات الزائفة حيث يمكن القول: إذا كانت لدينا الحالة S_2 والمصنف $c_2 = C_2 - A_2 - E_2$ هو المصنف الفعال وتم الوصول إلى الحالة المتوقعة بشكل صحيح والمصنف لديه علامة Mark وعند محاولة إجراء تخصيص للمكونات الثابتة (غير متحركة) وتفشل عندها يكون لدينا حالة زائفة في S_2 .

4-2-7-2- تجزئة الإجراءات:

على فرض أن المصنف $c_1 = C_1 - A_1 - E_1$ كان المصنف الفعال قبل c_2 (عند الحالة S_1) وقد أدى للوصول إلى الحالة المتوقعة الصحيحة ($S_2^{ant} = S_2$) ، المصنفين c_1 و c_2 يمكن أن يستخدم لإنشاء مصنف جديد $c_{new} = C_{new} - A_{new} - E_{new}$ من أجل تجنب الحالة الزائفة S_2 ويكون :

$$\begin{aligned} C_{new} &= passthrough(C_2, C_1) \\ E_{new} &= passthrough(E_2, E_1) \\ A_{new} &= A_1 \cdot A_2 \end{aligned}$$

عند ورود إجراءات معاً بهذا الشكل $A_1 \cdot A_2$ يعني أنه سيتم تنفيذ A_1 ثم A_2 .

ملاحظة: إن تعريف C_{new} بالشكل $C_{new} = passthrough(C_2, C_1)$ لا يضمن أن المصنف الجديد يوافق S_1 لذلك يمكن استخدام $C_{new} = C_1$ ، ولكن لم تستخدم هذه الطريقة في ورقة البحث [5].

يمكن أن يتكون الإجراءات من أكثر من جزأين لذلك نعرف بارامتر a_{max} يحدد العدد الأعظمي المسموح.

4-2-8- Action Planning : تخطيط الإجراءات

كما ذكرنا إن نظام ACS يقوم بتعلم نموذج داخلي للوسط، يُمثل هذا النموذج من خلال المصنفات الموثوقة، لذلك من الممكن أن يتم استخدام هذا النموذج من أجل القيام بعملية تخطيط استباقي للإجراءات المتتالية في سبيل الوصول إلى الهدف.

يتم استخدام جزء التوقع من المصنف الموثوق لحساب الحالة التالية المتوقعة S_{t+1}^{ant} ثم يتم فرض هذه الحالة أنها صحيحة S_{t+1} ويتم على أساسها انتقاء مصنف موثوق واعتبار جزء التوقع له حالة الوسط، ويتم تكرار العملية حتى الوصول إلى الحالة المطلوبة (الهدف) [11]. يمكن تنفيذ نفس العملية ولكن باتجاه معاكس (البدا من الحالة الهدف حتى الوصول إلى الحالة الراهنة).

إذاً يمكن إجراء التخطيط من خلال البحث بأحد الاتجاهين أو بالاتجاهين معاً من أجل ضمان التسلسل الأمثل من المصنفات (على الأقل من وجهة نظر العميل)، وهذه العملية تحدث من غير الاتصال مع الوسط، يستخدم من أجل عملية البحث مبدأ البحث بالعرض.

4-2-8-1 خوارزمية البحث الأمامي Forwards-directed breadth-first

:search

1- تحديد $c_i = C_i - A_i - E_i$ من أجل $i = 1 \dots t$ كل المصنفات الموثوقة التي

توافق S_N (الحالة الراهنة) جزء الشرط لها C_i .

2- حساب $S_1^{ant} \dots S_k^{ant}$ حيث $S_i^{ant} = \text{passthrough}(S_N, C_i^{ant})$.

3- في حال $F_S \in \{S_1^{ant} \dots S_k^{ant}\}$ (الهدف) تتوقف الخوارزمية أو يتم تكرار

الخطوتين 1 و 2 من أجل $S_1^{ant} \dots S_k^{ant}$ بدلاً من S_N .

4- إعادة الخطوات السابقة حتى إيجاد F_S أو بلوغ عدد العمليات الأعظمي المسموح به

والمحدد من خلال البارامتر $S_{\max}$.

4-2-8-2- خوارزمية البحث الخلفي Backwards-directed breadth-first

:search

1- تحديد $c_i = C_i - A_i - E_i$ من أجل $i = 1 \dots t$ كل المصنفات الموثوقة التي

توافق F_S (الحالة الهدف) جزء التوقع لها E_i .

2- حساب $S_1^{ant} \dots S_k^{ant}$ حيث $S_i^{ant} = passthrough(F_S, C_i)$.

3- في حال $S_N \in \{S_1^{ant} \dots S_k^{ant}\}$ (الحالة الراهنة) تتوقف الخوارزمية أو يتم

تكرار الخطوتين 1 و 2 من أجل $S_1^{ant} \dots S_k^{ant}$ بدلاً من F_S .

4- إعادة الخطوات السابقة حتى إيجاد S_N أو الوصول إلى S_{max} (عدد العمليات الأعظمي

المسموح به في عملية البحث).

أيضاً يمكن استخدام طريقة البحث الثنائي والتي تتضمن تنفيذ الخوارزميتين السابقتين في

نفس الوقت.

يجب الحذر في هذه الخوارزميات الثلاثة من الحلقات غير المنتهية، على سبيل المثال: لدينا

روبوت في أحد خلايا المتاهة S_1 وعند التحرك باتجاه اليسار يصبح في S_2 ، وإذا كان في S_2

وتحرك باتجاه الشرق يصبح في S_1 وهكذا، وكحل لهذه المشكلة اعتبار الحالات S_i^{ant} التي

لم يتم المرور بها أو الوجود فيها فقط.

4-2-9- التعليم الموجه بالأهداف Goal-Directed learning

في ورقة البحث [11] تم تقديم تجربة ذراع روبوتية مسؤولة عن نقل مجسم ما من مكان إلى

آخر.

ما يميز هذه التجربة أن احتمالات التواجد في الحالات المختلفة للوسط ليست متساوية، فمن

غير الممكن نقل المجسم إلى أي مكان ما لم تكن الذراع ممسكة بالمجسم أو الإمساك بالمجسم

وهو غير موجود في المكان المتواجدة فيه الذراع، وبالتالي سيؤدي محاولة تنفيذ مثل هذه الخطوات إلى إضعاف جودة المصنفات المسؤولة عن هذه الخطوات، يمكن تجاوز هذه المشكلة من خلال استخدام تقنية التعلم الموجه بالأهداف.

ملاحظة: طبيعة هذه المعضلة تفرض التعامل مع عدة مجموعات للمصنفات، كل مجموعة مسؤولة عن نوع من الإجراءات على سبيل المثال: تحريك الذراع بدون الإمساك بالمجسم، الإمساك بالمجسم، إفلات المجسم وتحريك الذراع مع الإمساك بالمجسم.

إذاً الفكرة الأساسية تقوم على تحديد حالات وسطية يمكن اعتبارها أهداف مرحلية من أجل الوصول إلى الهدف الرئيسي، وببساطة يجب توليد هذه الأهداف من خلال مولد الأهداف Goal-generator ويمكن اعتباره جزء من الوسط وليس من النظام ACS، في [11] تم اعتماد الآلية التالية للتنفيذ:

في طور تخطيط الإجراءات يقوم النظام بطلب الهدف المرحلي وبناءً عليه يقوم بمحاولة إيجاد الطريق الأقصر إلى هذا الهدف من خلال استخدام طريقة البحث ثنائي الاتجاه، في حال إيجاد ذلك يتم تنفيذ المصنفات المقترحة وعند نجاح التنفيذ يقوم بطلب الهدف المرحلي التالي. في حال أن التنفيذ لم ينجح أو بالأساس خوارزمية البحث لم تتجح في إيجاد مسار مناسب للهدف على الإطلاق، يخرج نظام ACS من طور التخطيط ويدخل في طور الاستكشاف العادي وبعدها كل 50 خطوة يدخل النظام في طور التخطيط.

الفصل الخامس: النظام ACS2

الهيكليّة والخوارزميات المرافقة

5. النظام ACS2:


نظام ACS2 مشتق من نظام ACS الذي سبق وتطرقنا إليه، ولكن بالإضافة الرئيسية لهذا النظام هي استخدام آلية تعميم معتمدة على الخوارزمية الجينية [9].

5-1 - التفاعل مع الوسط:

بشكل مشابه لعمل التعليم المعزز RL يدرك نظام ACS2 حالة الوسط $\sigma \in I =$ $\{l_1, l_2, \dots, l_m\}^L$ حيث m عدد خاصيات أو ميزات الوسط و $l_1, l_2, \dots, l_m$ القيم المختلفة الممكنة لهذه الخاصيات و L طول السلسلة التي تمثل الحالة المدركة من قبل العميل. **ملاحظة:** ليس من الضروري أن تكون هذه الخاصيات مرمزة بشكل ثنائي ولكن من المهم أن تكون قيم مقطعة discrete [9].

ويقوم النظام ACS2 باتخاذ إجراء في الوسط من مجموعة الإجراءات المتاحة $a \in A =$ $\{a_1, a_2, \dots, a_n\}$ حيث n العدد المتاح من الإجراءات، بعد تنفيذ الإجراء يقوم برنامج التعليم المعزز بتقييم الإجراء من خلال قيمة الربح أو المردود $P(t) \in R$.

الشكل (5-1) يوضح آلية التفاعل العامة وتمثيل المعرفة في نظام ACS2 ، كما نلاحظ أن جزء التعليم المعزز RL تم فصله بكيان منفصل عن الوسط حيث أن التعزيز يمكن أن يكون أما من خلال الوسط أو من معلم مستقل أو من نظام ACS2 نفسه، في الحالة الأخيرة يمكن القول عن النظام أنه عميل متكيف باحتياجات خاصة لتحقيق التعزيز الداخلي، وكذلك يمكن القول إن نظام ACS2 يمكنه تمثيل حوافز وأهداف معينة يكون لها تأثير على آلية التعزيز، على سبيل المثال دعم خصائص محددة للوسط التي ستكون مفضلة للنظام.



الشكل (5-1): المخطط الصندوقي للنظام ACS2

مردود عملية التعزيز والعملية الإدراكية هو من يفعل إجراءات التعليم في نظام ACS2 حيث يتم استخدام نموذج مشترك لتمثيل التعزيز والتنبؤات، ومن هذا النموذج يتم انتقاء الإجراءات المناسبة أو بكلام آخر يمكن استخدام هذا النموذج لتحسين السياسة السلوكية للنظام.

5-2- تمثيل المعرفة:

كما هو الحال مع نظم المصنفات الأخرى يتم تمثيل المعرفة في نظام ACS2 من خلال المجموعة العامة للمصنفات [P]، حيث كل مصنف يتمثل من خلال قاعدة لها الشكل: شرط - إجراء - تأثير أو نتيجة، يقوم المصنف بتوقع حالة الوسط الناتجة من تنفيذ إجراء معين في حالة ما محددة بشكل كامل، كل مصنف يتكون من المكونات التالية:

C-1 جزء الشرط $C \in I = \{l_1, l_2, \dots, l_m, \#\}^L$ يحدد مجموعة من الحالات

الممكن تطبيق المصنف فيها.

A-2 جزء الإجراء يقوم باقتراح إجراء ما للتنفيذ.

E-3 جزء التأثير $E \in I = \{l_1, l_2, \dots, l_m, \#\}^L$ يقوم بتوقع حالة الوسط التالية الناتجة من تنفيذ الإجراء المحدد.

M-4: علام $M = (m_1, m_2, \dots, m_L)$ حيث $m_i \subset \{l_1, l_2, \dots, l_m\}^L$ عبارة عن سجل يحتوي على الخصائص التي سبق وأن أخطأ فيها المصنف.

q-5: جودة المصنف وهو مقدار يقوم بقياس دقة التنبؤ.

r-6: توقع الربح الناتج من تنفيذ الإجراء A في حالة الشرط المحدد C.

ir-7: توقع الربح الفوري حيث يحدد قيمة التعزيز مباشرة بعد تنفيذ الإجراء A.

8- t_{ga} : الطابع الزمني الخاص بالخوارزمية الجينية ويحدد زمن آخر مرة كان المصنف جزء من مجموعة إجراء تم تطبيق الخوارزمية الجينية عليها

9- t_{alp} : طابع الزمني يحدد زمن آخر مرة خضع فيها المصنف لعملية التعليم الاستباقي.

ALP Anticipatory Learning Process.

10- aav: معدل التطبيق application average، يقوم بتقدير تواتر تنفيذ عملية ALP على المصنف.

11- exp: عداد الخبرة يحتوي على عدد مرات خضوع المصنف لعملية ALP.

12- num: الكثافة العددية للمصنف حيث يحدد عدد المصنفات المكافئة المضمنة في المصنف.

5-3- مجموعة بارامترات النظام:

يوجد في نظام ACS2 مجموعة من الثوابت مسؤولة عن عملية التعليم:

1- θ_i : عتبة عدم الدقة ($\theta_i \in [0,1]$) تحدد متى يمكن اعتبار المصنف غير كفؤ أو غير دقيق من خلال قيمة الجودة q له.

2- θ_r : عتبة الوثوقية ($\theta_r \in [0,1]$) يحدد متى يمكن اعتبار المصنف أنه موثوق بالاعتماد على قيمة الجودة q.

3- β : معدل التعليم ($\beta \in [0,1]$) يستخدم في إجراءات التعليم الاستباقي ALP والتعليم المعزز RL لتحديث قيم البارامترات aav, ir, r, q .

4- γ : معامل الخصم ($\gamma \in [0,1]$) يستخدم لإجراء خصم على الربح الأعظمي المتوقع في الأوضاع أو الحالات المتتالية.

5- ρ : قيمة الربح الفوري الذي يستقبله النظام عند الانتقال إلى حالة ما للوسط.

6- U_{max} : عتبة التخصيص specificity threshold ($U_{max} \in N$) تستخدم هذه العتبة لتحديد عدد الخاصيات الأعظمي في الشرط C المسموح أن يُتوقع أنها ستبقى كما هي في جزء النتيجة E.

7- ϵ : احتمال تفعيل الاستكشاف ($\epsilon \in [0,1]$) يحدد احتمال اختيار الإجراء بشكل عشوائي بشكل مشابه لآلية e-greedy.

8- θ_{ga} : عتبة تطبيق الخوارزمية الجينية ($\theta_{ga} \in N$) تحدد تواتر تطبيق الخوارزمية الجينية، حيث أن الخوارزمية الجينية تطبق على مجموعة الإجراء [A] إذا كان معدل أزمنا تطبيق هذه الخوارزمية على أعضاء المجموعة أكبر من هذه العتبة θ_{ga} .

9- μ : معدل حدوث الطفرة ($\mu \in [0,1]$) حيث يحدد احتمال حدوث تغيير على خاصية محددة في جزء الشرط لمصنفات النسل الناتج عند تطبيق الخوارزمية الجينية، حيث تصبح الخاصية معمة أي لها القيمة #.

10- λ : احتمال حدوث معامل العبور crossover ($\lambda \in [0,1]$).

11- θ_{as} : عتبة حجم مجموعة الإجراء ($\theta_{as} \in N$) تحدد العدد الأعظمي للمصنفات في مجموعة الإجراء عند تطبيق الخوارزمية الجينية عليها.

-12 θ_{exp} : عتبة الخبرة ($\theta_{exp} \in N$) تحدد متى يمكن اعتبار المصنف أنه ذو خبرة. حيث تتم مقارنة هذه العتبة مع البارمتر $\exp$.

5-4- الخوارزمية العامة لنظام ACS2:

سيتم توصيف الخوارزمية العامة بطريقة تنازلية، حيث يحدد أولاً إجراءات التنفيذ العامة ثم يتم تحديد الخطوات التفصيلية فيها.

5-4-1- التهيئة:

حتى يعمل نظام ACS2 بشكل صحيح يجب إعداد كافة المكونات اللازمة، كإعداد وضبط التعامل مع الوسط والبدء من حالة معينة، وكذلك إعداد برنامج التعليم المعزز RL وتهيئة النظام ACS2 من خلال ضبط القيم الأولية للبارامترات وإنشاء المجموعة العامة للمصنفات [P] التي سيبدأ النظام العمل من خلالها.

Start ACS2:

1. initialize environment env
2. initialize reinforcement program rp
3. initialize ACS2
4. RUN EXPERIMENT with population [P] and initial time t

الشكل (5-2): خوارزمية برنامج التهيئة

5-4-2- حلقة التنفيذ العامة:

كما ذكرنا أن نظم المصنفات القابلة للتعلم LCS تعتمد مبدأ التجربة والخطأ، لذلك حلقة التشغيل الرئيسية RUN EXPERIMENT ستكون مسؤولة عن إدارة التجارب المتلاحقة والتعليم التراكمي، وسوف تستمر حلقة التنفيذ العامة بالعمل حتى تحقق معيار معين للتوقف، وكل تجربة عبارة عن حلقة يتم فيها تنفيذ الإجراءات المتتالية حتى الوصول إلى الهدف المطلوب

أو الوصول إلى عدد الخطوات الأعظمي المسموح في التجربة الواحدة، وتتضمن التجربة الخطوات التالية:

- 1- التحسس للحالة الراهنة للوسط.
 - 2- تشكيل مجموعة التطابق.
 - 3- في حال أن دورة التنفيذ الحالية ليست في بداية التجربة يتم تنفيذ البرامج الفرعية المسؤول عن عملية التعليم الاستباقي ALP والتعليم المعزز RL والخوارزمية الجينية GA على مجموعة الإجراء السابقة $[A]_{-1}$.
 - 4- اختيار الإجراء وتشكيل مجموعة الإجراء $[A]$.
 - 5- تعديل قيم البارامترات.
 - 6- في حال الوصول إلى نهاية التجربة يتم تطبيق البرامج ALP, RL, GA على مجموعة التطابق $[A]$ وإلا فسيتم الانتقال إلى بداية الحلقة (الخطوة 1) مع اعتبار مجموعة الإجراء الحالية $[A]$ هي مجموع الإجراء السابقة $[A]_{-1}$.
- ملاحظة: عند نهاية تجربة ما يجب إفراغ مجموعة الإجراء $[A]_{-1}$ لتجنب الخطأ الناتج عند البدء بالتجربة مع اعتبار مجموعة إجراء تخص التجربة السابقة.
- ويبين المقطع التالي التوصيف الخوارزمي لحلقة التنفيذ العامة: σ

RUN EXPERIMENT ([P] , t):

1. While (termination criteria is not met)
2. $\sigma \leftarrow \text{env: perceive situation}$
3. Do
4. GENERATE MATCH SET [M] out of [P] using σ
5. if ($[A]_{-1}$ is not empty)
6. APPLY ALP in $[A]_{-1}$ considering σ_{-1} , σ , t and [P]

7. APLY REINFORCEMENT LEARNING in $[A]_{-1}$ using ρ and $\max_{cl \in [M] \wedge cl.E \neq \{\#\}^L} (cl.q * cl.r)$
8. APPLY GENETIC GENERALIZATION in $[A]_{-1}$ considering t
9. $act \leftarrow$ CHOOSE ACTION with an e-greedy policy in [M]
10. GENERATE ACTIO SET [A] out of [M] according to act
11. env : execute action act
12. $t \leftarrow t + 1$
13. rp : receive reward ρ
14. $\sigma_{-1} \leftarrow \sigma$
15. $\sigma \leftarrow env$: perceive situation
16. If (env : is and of one trial)
17. APPLY ALP in $[A]$ considering σ_{-1} , σ , t and [P]
18. APLY REINFORCEMENT LEARNING in $[A]$ using ρ
19. APPLY GENETIC GENERALIZATION in $[A]$ considering t
20. $[A]_{-1} \leftarrow [A]$
21. While (not env : is end of one trial)
22. env : reset position
23. $[A]_{-1} \leftarrow empty$

الشكل (3-5): خوارزمية حلقة التنفيذ العامة

3-4-5 - تشكيل مجموعة التطابق:

إجرائية بسيطة جداً تقوم بانتقاء المصنفات التي توافق الحالة الراهنة للوسط من خلال المقارنة مع جزء الشرط الخاص بالمصنف.

GENERAT MATCH SET ([P], σ)

1. Initialize empty set [M]
2. For each classifier cl in [P]
3. if (DOES MATCH classifier cl in situation σ)
4. add classifier cl to set [M]
5. return [M]

الشكل (4-5): خوارزمية تشكيل مجموعة التطابق

والتابع الفرعي DOES MATCH يقوم بالتحقق من التطابق، كما يوضح المقطع التالي:

DOES MATCH (cl, σ)

1. for each attribute x in $cl.C$
2. if ($x \neq \#$ and $x \neq$ the corresponding attribute in σ)
3. return false
4. return true

الشكل (5-5): خوارزمية اختبار التطابق مع حالة الوسط

4-4-5- اختيار الإجراء:

يتم اعتماد آلية e-greedy لاختيار الإجراء حيث يتم الاختيار إما بشكل عشوائي باحتمال ϵ أو سيتم اختيار المصنف الأكثر ملاءمة (الواعد أكثر) وتتم هذه العملية بين المصنفات في مجموعة التطابق [M].

ملاحظة: يجب الأخذ بعين الاعتبار المصنفات التي تتوقع صراحةً بعدم حصول أي تغيير في الوسط واستثنائها من عملية الاختيار.

يبين المقطع التالي التوصيف الخوارزمي لعملية اختيار الإجراء.

CHOOSE ACTION ([M]):

1. if (RandomNumber [0,1] < ϵ)
2. return a randomly chosen action possible in *env*
3. else
4. $bestCl \leftarrow$ first *cl* in [M] with $cl.E \neq \{\#^L\}$
5. for all classifiers $cl \in [M]$
6. if ($cl.E \neq \{\#^L\}$ and $cl.q * cl.r > bestCl.q * bestCl.r$)
7. $bestCl \leftarrow cl$
8. Return $cl.A$

الشكل (5-6) : خوارزمية اختيار الإجراء

5-4-5 - تشكيل مجموعة الإجراء [A]:

تتضمن هذه العملية انتقاء المصنفات من مجموعة التطابق التي تقترح الإجراء المختار.

GENERAT ACTION SET ([M] , *act*):

1. initialize empty set [A]
2. for each classifier in [M]
3. if ($cl.A = act$)
4. Add classifier *cl* to set [A]
5. return [A]

الشكل (5-7): خوارزمية تشكيل مجموعة الإجراء [A]

5-4-6- عملية التعليم الاستباقي Anticipatory Learning Process ALP:

إن تطبيق عملية التعليم الاستباقي بحاجة إلى دقة في التنفيذ، فبسبب إنشاء وحذف المصنفات خلال هذه العملية يجب التأكد من أن المصنفات الجديدة الناتجة أنها ستدخل في مجموعة الإجراء [A] ولكن لا تعتبر في عملية ALP الحالية، وكذلك حذف المصنفات من مجموعة الإجراء يجب ألا يؤثر على إجراءات التحديث للبارامترات والمصنفات.

الإجراءات المسؤولة عن تطبيق عملية ALP تظهر في المقطع التالي APPLY ALP حيث تأخذ هذه الإجراءات بعين الاعتبار التوقعات لكل المصنفات في مجموعة الإجراء [A]، فإما أن يكون التوقع صحيح أو خاطئ، وعلى هذا الأساس يتم تنفيذ إحدى الإجرائيتين EXPECTED CASE أو UNEXPECTED CASE.

في إجراءات UNEXPECTED CASE تتم معالجة الحالة التي أخطأ فيها المصنف بالتوقع حيث يتم إنقاص قيمة الجودة q للمصنف ثم التحقق إذا كانت قيمتها أقل من قيمة عتبة عدم الدقة θ_i فعندها يجب حذف المصنف (بغض النظر عن قيمة الكثافة العددية له num حيث كل المصنفات المكافئة ستكون غير دقيقة).

وعند إضافة مصنف جديد من الضروري التحقق فيما إذا كان يوجد مصنف مماثل أو مكافئ له، وفي حال أنه لا يوجد أي مصنف ضمن مجموعة الإجراء قام بالتنبؤ بشكل صحيح فعندها يجب إضافة مصنف جديد يحقق عملية التنبؤ اللازمة بشكل صحيح.

APPLAY ALP ($[A], \sigma_{-1}, act, \sigma, t, [P]$) :

1. wasExpectedCase $\leftarrow 0$
2. for each classifier cl in $[A]$
3. $cl.exp + +$
4. UPDATE APPLICATION AVERAGE of cl with respect to t
5. if (cl DOES ANTICIPATE CORRECTLY σ in σ_{-1})

```

6.      newCl ← EXPECTED CASE of cl in  $\sigma, \sigma_{-1}$ 
7.      wasExpectedCase ← 1
8.      else
9.      newCl ← UNEXPECTED CASE of cl in  $\sigma, \sigma_{-1}$ 
10.     if ( $cl.q < \theta_i$ )
11.         remove classifier cl from [P] and [A]
12.     if ( newCl is not empty)
13.         newCl.tga ← t
14.         ADD ALP CLASSIFIER newCl to [P] and [A]
15.     if ( wasExpectedCase =0 )
16.         newCl ← COVER TRIPLE  $\sigma_{-1}, act, \sigma$  with time t
17.         ADD ALP CLASSIFIER newCl to [P] and [A]

```

الشكل (5-8): الخوارزمية العامة الخاصة بعملية التعليم الاستباقي

وأيضاً هناك إجرائية لتعديل معدل التطبيق UPDATE APPLICATION AVERAGE تستخدم تقنية تدعى moyenne adaptive modiffee technique من أجل الوصول إلى قيمة دقيقة لمعدل التطبيق بشكل سريع.

```

UPDATE APPLICATION AVERAGE ( cl , t )
1.  if ( $cl.exp < 1/\beta$ )
2.      cl.aav ←  $cl.aav + (t - cl.t_{alp} - cl.aav) / cl.exp$ 
3.  else
4.      cl.aav ←  $cl.aav + \beta * (t - cl.t_{alp} - cl.aav)$ 
5.      cl.talp ← t

```

الشكل (5-9): خوارزمية تعديل معدل التطبيق

إجرائية DOES ANTICIPATE CORRECTLY تقوم بالتحقق من المصنف بأنه قام بالتنبؤ بشكل صحيح حيث يجب أن تأخذ بعين الاعتبار رموز "#" في جزء النتيجة والذي تعني أن الخاصية الموافقة بقيت كما هي، وكذلك الخاصيات المحددة في جزء التأثير والتي تعني أن الخاصية تغيرت إلى القيمة المحددة والمقطع الخوارزمي التالي يبين هذه الإجرائية:

DOES ANTICIPATE CORRECTLY (cl, σ_{-1}, σ):

1. for each position i
2. if ($cl.E[i] = \#$)
3. if ($\sigma_{-1}[i] \neq \sigma[i]$)
4. return false
5. else
6. if ($cl.E[i] \neq \sigma[i]$ or $\sigma_{-1}[i] = \sigma[i]$)
7. return false
8. return true

الشكل (5-10): خوارزمية اختبار التوقع الصحيح

كما ذكرنا يوجد إجرائيتين لمعالجة فيما إذا كانت الحالة المتوقعة في المصنف صحيحة أم لا، إجرائية EXPECTED CASE تعالج حالة التوقع الصحيح ويمكن أن تقسم إلى جزأين، في الأول يتم إضافة مصنف جديد أو في الثاني لا يتم ذلك.

حيث لا يتم إضافة أي مصنف في حال أن العلام mark الخاص بالمصنف المعتبر فارغ أو لا يوجد فروقات بينه وبين الحالة المعتبرة (الحالة الجديدة)، ويتم كذلك زيادة الجودة q للمصنف، بالمقابل في حال وجد اختلاف بين العلام والحالة المعتبرة سيتم إنشاء مصنف جديد، ولكن من المهم الأخذ بعين الاعتبار الحالات التي تتطلب تخصيص أو تحديد عدة خاصيات، حيث يجب التحقق من أن المصنف لم يبلغ عتبة التخصيص (أي أن عدد الخاصيات المحددة في

المصنف يجب أن لا يتجاوز العتبة U_{max} وفي حال أن المصنف قد بلغ هذه العتبة فعندها يجب إجراء تعميم لخاصيات أخرى محددة من قبل حتى يصبح من الممكن تحديد الخاصيات المطلوبة.

EXPECTED CASE (cl, σ):

1. $diff \leftarrow$ GET DIFFERENCES of $cl.M$ and σ
2. if ($diff = \{\#\}^L$)
3. $cl.q \leftarrow cl.q + \beta * (1 - cl.q)$
4. return empty
5. else
6. $spec \leftarrow$ number of non-# symbols in $cl.C$
7. $specNew \leftarrow$ number of non-# symbols in $diff$
8. $child \leftarrow$ copy classifier cl
9. if ($spec = U_{max}$)
10. remove randomly specific attribute in $child.C$
11. $spec --$
12. while ($spec + specNew > U_{max}$)
13. if ($spec > 0$ and random number[0,1] < 0.5)
14. remove randomly specific attribute in $child.C$
15. $spec --$
16. else
17. remove randomly specific attribute in $diff$
18. $specNew --$
19. else
20. while ($spec + specNew > U_{max}$)

```

21.          remove randomly specific attribute in diff
22.          specNew ← -
23.          specify child.C with diff
24.          if (child.q < 0.5)
25.              child.q = 0.5
26.          child.exp ← 1
27.          return child

```

الشكل (5-11): خوارزمية معالجة حالة التوقع الصحيح

في المقطع السابق يتم الحصول على الفروقات بين العلام والحالة المعتبرة من خلال المتحول *diff* الذي له نفس بنية الشرط للمصنف ويتم الحصول عليه من خلال الإجرائية GET DIFFERENCES المبينة في المقطع التالي:

```

GET DIFFERENCES (M ,  $\sigma$ ):
1.  diff ←  $\{\#\}^L$ 
2.  if ( M is not empty)
3.      type1 ← type2 ← 0
4.      for all position i in  $\sigma$ 
5.          if ( M[i] does not contain  $\sigma$ [i])
6.              type1 ++
7.          else if ( $|M[i]| > 1$ )
8.              type2 ++
9.      if (type1 > 0)
10.         type1 ← random number [0,1] * type1
11.         for all position i in  $\sigma$ 

```

```

12.          if (  $M[i]$  does not contain  $\sigma[i]$ )
13.              lf ( $type1 = 0$ )
14.                   $diff[i] \leftarrow \sigma[i]$ 
15.                   $type1 - -$ 
16.      else if ( $type2 > 0$ )
17.          for all position  $i$  in  $\sigma$ 
18.              if ( $|M[i]| > 1$ )
19.                   $diff[i] \leftarrow \sigma[i]$ 
20.  return  $diff$ 

```

الشكل (5-12): خوارزمية إيجاد الفروقات بين حالة وعلام المصنف

في إجرائية GET DIFFERENCES تم التمييز بين حالتين، الأولى تكون الفروقات واضحة حيث أحد مكونات العلام (والتي من المحتمل أن تكون محتوية أكثر من قيمة واحدة) تتضمن الخاصية المقابلة من الحالة المعتبرة σ ، وفي الثانية تكون الفروقات غير واضحة حيث المكونة من العلام تكون تحوي بالإضافة لقيمة الخاصية الموافقة من الحالة المعتبرة σ قيم أخرى، وبالتالي من أجل الحالة الأولى يتم اختيار أحد الفروقات الواضحة فقط وذلك بشكل عشوائي، أما من أجل الحالة الثانية فيتم اعتبار كل الفروقات غير الواضحة.

تعالج إجرائية Unexpected case حالة التوقع الخاطئ وتقوم بإنشاء مصنف جديد في حال أن الحالة قابلة للتصحيح، أو بكلام آخر تتخذ هذه الإجرائية معيار إنشاء مصنف جديد هو أنه يمكن تعديل جزء النتيجة للمصنف المعتبر فقط من خلال تحديد الخاصيات حتى يستطيع المصنف التنبؤ بشكل صحيح بالحالة σ من الحالة σ_{-1} وبالتالي عندما يتحقق هذا الأمر سيتم إنشاء مصنف جديد وتكون الخبرة لهذا المصنف مساوية 1.

UNEXPECTED CASE (cl, σ_{-1}, σ):
1. $cl.q \leftarrow cl.q - \beta * (cl.q)$
2. SET MARK $cl.M$ with σ_{-1}
3. for all position i in σ
4. if ($cl.E[i] \neq \#$)
5. if ($cl.E[i] \neq \sigma[i]$ or $\sigma_{-1}[i] = \sigma[i]$)
6. return empty
7. $child \leftarrow$ copy classifier cl
8. for all position i in σ
9. if ($cl.E[i] = \#$ and $\sigma_{-1}[i] \neq \sigma[i]$)
10. $child.C[i] \leftarrow \sigma_{-1}[i]$
11. $child.E[i] \leftarrow \sigma[i]$
12. if ($cl.q < 0.5$)
13. $cl.q = 0.5$
14. $child.exp \leftarrow 1$
15. return $child$

الشكل (5-13): خوارزمية معالجة حالة التوقع غير الصحيح

يجب على نظام ACS2 أن يكون قادر على معالجة كل الحالات أو الأوضاع الممكنة من كل التشكيلات الممكنة للثلاثية (شرط - إجراء - نتيجة)، ومن هذه الفكرة تدرج أهمية معامل التغطية covering، ففي حال مصادفة ثلاثية غير معالجة في مجموعة الإجراء سيتم استدعاء الإجرائية المسؤولة عن التغطية.

حيث يتم انتاج مصنف يحدد كل التغيرات الحاصلة من الانتقال من الحالة السابقة σ_{-1} إلى الحالة الراهنة σ ، ويكون الإجراء لهذا المصنف هو نفس الإجراء المنفذ act ، وتوضع الأزمنة

t_{alp} و t_{ga} للمصنف الناتج إلى قيمة عداد الزمن الحالة t ويتم وضع عداد الخبرة للمصنف $exp = 0$ ، ولذلك لا يتم مباشرة وضع قيم لمعدل التطبيق aav لهذا المصنف الجديد بل يتم تأخير ذلك حتى أول استخدام لهذا المصنف.

COVER TRIPLE ($act, \sigma_{-1}, \sigma, t$):

1. $child \leftarrow$ generate empty classifier with action act
2. for all position i in σ
3. if ($\sigma_{-1}[i] \neq \sigma[i]$)
4. $child.C[i] \leftarrow \sigma_{-1}[i]$
5. $child.E[i] \leftarrow \sigma[i]$
6. $child.exp \leftarrow child.r \leftarrow child.aav \leftarrow 0$
7. $child.t_{alp} \leftarrow child.t_{ga} \leftarrow t$
8. $child.q = 0.5$
9. $child.num \leftarrow 1$
10. return $child$

الشكل (5-14) : خوارزمية التغطية

كما رأينا أنه في عملية ALP يتم إنشاء مصنفات جديدة، وبالتالي يجب إضافة هذه المصنفات إلى المجموعة العامة للمصنفات [P] ومجموعة الإجراء [A] ولكن يجب التمييز بين عدة حالات، فيجب التحقق فيما إذا كان يوجد مصنف مكافئ للمصنف الجديد وفي حال عدم وجود مثل هذا المصنف يتم البحث عن مصنف مساوي للمصنف الجديد، وإلا سيتم عندها إضافة المصنف الجديد إلى المجموعة العامة [P] ومجموعة الإجراء [A]، وعلى كل حال عند وجود مصنف مكافئ أو مساوي يتم زيادة الخبرة لهذا المصنف بمقدار (1) وتجاهل المصنف الجديد.

ملاحظة: ليس من الضروري التحقق من أن المصنف له نفس الإجراء لأن كل المصنفات في مجموعة الإجراء [A] تملك نفس الإجراء.

ADD ALP CLASSIFIER ($cl, [A], [P]$)	
1.	$oldCl \leftarrow empty$
2.	for all classifiers c in $[A]$
3.	if (c IS SUBSUMER of cl)
4.	if ($oldCl$ is empty or $c.C$ is more general than $oldCl.C$)
5.	$oldCl \leftarrow c$
6.	if ($oldCl$ is empty)
7.	for all classifier c in $[A]$
8.	if (c is equal to cl in condition and effect part)
9.	$oldCl \leftarrow c$
10.	if ($oldCl$ is empty)
11.	insert cl in $[A]$ and $[P]$
12.	else
13.	$oldCl.q \leftarrow oldCl.q + \beta * (1 - oldCl.q)$
14.	discard classifier cl

الشكل (5-15): خوارزمية إضافة المصنفات الناتجة من إجرائية ALP

5-4-7- التعليم المعزز RL في نظام ACS2:

يتبع برنامج التعليم المعزز في نظام ACS2 فكرة خوارزمية Q-Learning، حيث يتم تحديث قيمة الربح المتوقع بالاعتماد على قيمة الربح الفورية وكذلك على قيمة الربح الأعظمي المتوقع في الخطوة التالية $maxP$ مضروبة بمعامل الخصم γ .

الفكرة الأساسية في نظام ACS2 أنه لا يقوم بالاحتفاظ بالنموذج للوسط بشكل صريح ولكن يتم تمثيل النموذج من خلال مجموعة من المصنفات التي قد تكون معممة بشكل كبير أو قليل، وفي ضوء عمل إجرائية التعليم المعزز يجب أن تكون هذه المصنفات مخصصة بشكل كافي لضمان عملها بشكل صحيح، يبين المقطع التالي إجرائية التعليم المعزز:

APPLY REINFORCEMENT LEARNING ($[A], \rho, \max P$)

1. for each classifier cl in $[A]$
2. $cl.r \leftarrow cl.r + \beta * (\rho + \gamma \max P - cl.r)$
3. $cl.ir \leftarrow cl.ir + \beta * (\rho - cl.ir)$

الشكل (5-16) : خوارزمية التعليم المعزز

5-4-8- التعميم باستخدام الخوارزمية الجينية:

تستخدم الخوارزمية الجينية في نظام ACS2 لإجراء تعميم في جزء الشرط للمصنفات. الإجرائية المسؤولة عن تطبيق الخوارزمية الجينية تبدأ من خلال التحقق من إمكانية تفعيل عمل هذه الخوارزمية في الخطوة الزمنية الحالية من عمل النظام، حيث يكون نظام ACS2 محتفظ بمجموع أو عدد خطوات التشغيل t على شكل عداد، وعند حدوث الخوارزمية الجينية على مجموعة إجراء ما $[A]$ يتم رسم المصنفات فيها بقيمة العداد t ($t_{ga} \leftarrow t$)، وعند تشكيل مجموعة إجراء يتم احتساب المتوسط لأزمة تطبيق الخوارزمية الجينية t_{ga} لكل المصنفات فيها وطرح هذا المتوسط من قيمة العداد الزمني لحالة للنظام t فإذا كانت القيمة الناتجة أكبر من قيمة عتبة التنفيذ للخوارزمية الجينية θ_{GA} فعندها يمكن تنفيذ الخوارزمية الجينية وإلا فلا يمكن ذلك [13].

في حال تفعيل الخوارزمية الجينية يتم انتقاء مصنفين من المصنفات الدقيقة والمخصصة بشكل كبير ويطبق عليها معامل الطفرة *mutation* ومعامل العبور *crossover*، وقبل إضافة المصنفات الناتجة يتم حذف المصنفات الزائدة.

APPLY GENETIC GENERALIZATION ([A], *t*)

1. if $(t - \sum_{cl \in [A]} cl.t_{ga} \cdot cl.num / \sum_{cl \in [A]} cl.num > \theta_{GA})$
2. for each classifier *cl* in [A]
3. $cl.t_{ga} \leftarrow \text{actual time } t$
4. $parent1 \leftarrow \text{SELECT OFFSPRING in [A]}$
5. $parent2 \leftarrow \text{SELECT OFFSPRING in [A]}$
6. $child1 \leftarrow \text{copy classifier } parent1$
7. $child2 \leftarrow \text{copy classifier } parent2$
8. $child1.num \leftarrow child2.num \leftarrow 1$
9. $child1.exp \leftarrow child2.exp \leftarrow 1$
10. APPLY GENERALIZING MUTATION on *child1*
11. APPLY GENERALIZING MUTATION on *child2*
12. if (RandomNumber[0,1[< $\aleph$)
13. APPLY CROSSOVER on *child1* and *child2*
14. $child1.r \leftarrow child2.r \leftarrow (parent1.r + parent2.r)/2$
15. $child1.q \leftarrow child2.q \leftarrow (parent1.q + parent2.q)/2$
16. $child1.q \leftarrow child1.q/2$
17. $child2.q \leftarrow child2.q/2$
18. DELETE CLASSIFIER in [A],[P] to allow the insertion of 2 children
19. for each *child*
20. if ($child.C \text{ equals } \{\#\}^L$)

- | | |
|-----|--|
| 21. | Next <i>child</i> |
| 22. | else |
| 23. | ADD GA CLASSIFIER <i>child</i> to [P] and[A] |

الشكل (5-17): الخوارزمية الجينية

بالنسبة لعملية انتقاء المصنفات الداخلة في الخوارزمية الجينية SELECT OFFSPRING تعتمد على آلية عجلة روليت، حيث يتم الاختيار من أجل عملية إعادة الانتاج reproduction من المجموعة [A] بشكل تناسبي مع قيمة جودة المصنفات مرفوعة إلى القوة 3.

SELECT OFFSPRING ([A]):

1. $qualitySum \leftarrow 0$
2. for each classifier cl in [A]
3. $qualitySum \leftarrow qualitySum + cl.q^3$
4. $choicePoint \leftarrow RandomNumber[0,1[* qualitySum$
5. $qualitySum \leftarrow 0$
6. for each classifier cl in [A]
7. $qualitySum \leftarrow qualitySum + cl.q^3$
8. if ($qualitySum > choicePoint$)
9. return cl

الشكل (5-18): خوارزمية انتقاء مصنفات النسل الجديد

معامل الطفرة في نظام ACS2 عبارة عن إجراءات تعميم لجزء الشرط للمصنفات الداخلة في الخوارزمية الجينية، حيث يمكن أن تصبح كل خاصية في جزء الشرط معممة (#) باحتمال

• μ

APPLY GENERALIZATION MUTATION (*cl*):

1. for all position i in $cl.C$
2. if ($cl.C[i] \neq \#$)
3. if ($RandomNumber[0,1[< \mu$)
4. $cl.C[i] \leftarrow \#$

الشكل (5-19): خوارزمية تطبيق معامل الطفرة

وكذلك يتم تطبيق معامل العبور Crossover على جزء الشرط للمصنفات الداخلة في الخوارزمية الجينية، ويمكن تطبيق معامل العبور فقط في حال أن المصنفين يتوقعان التغيير نفسه (أي أن جزأي النتيجة لهما متساويان)، المقطع التالي يبين الإجراءات المسؤولة عن عمل معامل العبور:

APPLY CROSSOVER (*cl1*, *cl2*)

1. if ($cl1.E \neq cl2.E$)
2. return
3. $x \leftarrow RandomNumber[0,1[(length\ of\ cl1.C + 1)$
4. do
5. $y \leftarrow RandomNumber[0,1[(length\ of\ cl1.C + 1)$
6. while ($x = y$)
7. if ($x > y$)
8. switch x and y
9. $i \leftarrow 0$
10. do
11. if ($x \leq i$ and $i < y$)

```

12.          switch  $cl1.C[i]$  and  $cl2.C[i]$ 
13.       $i++$ 
14.  while (  $i < y$  )

```

الشكل (5-20): خوارزمية تطبيق معامل العبور

إن إضافة المصنفات الناتجة من تطبيق الخوارزمية الجينية يُوجب التحقق من إمكانية إضافة هذه المصنفات، حيث من المحتمل أن يكون حجم مجموعة الإجراء قد بلغت الحد الأعظمي من حيث عدد المصنفات فيها، وفي هذه الحالة يجب حذف مصنفات أخرى بنفس العدد المراد إضافته، ومن أجل ذلك يجب إجراء عملية انتقاء للمصنفات المراد حذفها.

عملية الانتقاء هذه تتم من خلال آلية تدعى Tournament selection، تعتمد هذه الآلية على فكرة المنافسة بين المصنفات من خلال قيم الجودة للمصنفات، ويكون دخول المصنفات في المنافسة من خلال آلية احتمالية، حيث في إجراءات الحذف المبينة في الخوارزمية التالية تم اعتبار أن ثلث المصنفات في مجموعة الإجراء ستدخل في المنافسة من خلال المقارنة مع العتبة ($1/3$) وبعد ذلك يتم اعتبار قيم الجودة للمصنفات وفي حال أنها متساوية يتم اعتبار وجود علام للمصنف حيث ستكون المصنفات التي لا تملك علام لها أولوية البقاء على المصنفات الأخرى، ويجب الانتباه أن عملية المنافسة تتم على مستوى المصنفات الجزئية micro_classifiers ففي حال أن الكثافة العددية للمصنف المراد حذفه أكبر من الواحد يجب فقط إنقاص الكثافة العددية بمقدار واحد.

DELETE CLASSIFIERS ([A], [P], inSize)

```

1.  while (inSize +  $\sum_{cl \in [A]} cl.num > \theta_{as}$ )
2.      clDel  $\leftarrow$  empty
3.      for each micro_classifier cl in [A]

```

```

4.      if (RandomNumber[0,1[ < 1/3 )
5.          if (clDel is empty)
6.              clDel ← cl
7.      else
8.          if (cl.q – clDel.q < –0.1)
9.              clDel ← cl
10.         if (|cl.q – clDel.q| ≤ 0.1)
11.             if (cl.M is not empty and clDel.M is empty)
12.                 clDel ← cl
13.             else if (cl.M is not empty or clDel.M is empty)
14.                 if (cl.aav > clDel.aav)
15.                     clDel ← cl
16.         if (clDel is not empty)
17.             if (clDel.num > 1)
18.                 clDel.num – –
19.         else
20.             remove classifier cl from [P] and [A]

```

الشكل (5-21): خوارزمية حذف المصنفات

عملية إضافة المصنفات الناتجة من الخوارزمية الجينية مشابهة لعملية الإضافة في إجرائية ALP ولكن تختلف عنها في نقطتين، الأولى في حال أنه يوجد مصنف مكافئ أو مساوي يتم زيادة الكثافة العددية للمصنف بدلاً من زيادة الجودة وذلك لأن المصنفات الجديدة لم تستخدم بعد، والنقطة الثانية أنه يتم زيادة الكثافة العددية للمصنف في حال أنه لا يملك علام فقط.

ADD GA CLASSIFIER (<i>cl</i> , [A], [P]):	
1.	<i>oldCl</i> $\leftarrow$ empty
2.	for all classifiers <i>c</i> in [A]
3.	if (<i>c</i> IS SUBSUMER of <i>cl</i>)
4.	if (<i>oldCl</i> is empty or <i>c.C</i> is more general than <i>oldCl.C</i>)
5.	<i>oldCl</i> $\leftarrow$ <i>c</i>
6.	if (<i>oldCl</i> is empty)
7.	for all classifiers <i>c</i> in [A]
8.	if (<i>c</i> is equal to <i>cl</i> in condition and effect part)
9.	<i>oldCl</i> $\leftarrow$ <i>c</i>
10.	if (<i>oldCl</i> is empty)
11.	insert <i>cl</i> in [A] and [P]
12.	else
13.	if (<i>oldCl</i> is not marked)
14.	<i>oldCl.num</i> + +
15.	discard classifier <i>cl</i>

الشكل (5-22): خوارزمية إضافة المصنفات الناتجة من الخوارزمية الجينية

5-4-9- التكافؤ أو التصنيف الضمني Subsumption:

يقوم نظام ACS2 بالبحث عن المصنفات المتكافئة أو المصنفة ضمن بعضها عند تنفيذ الخوارزمية الجينية وكذلك عند عملية ALP، ولكن يشترط أن يكون المصنف موثوق وذو خبرة ولا يملك علام لكي نستطيع أن نضمن مصنفات أخرى فيه، وكذلك يجب أن يكون جزء الشرط له أكثر تعميماً وأن يكون جزء النتيجة له مساوي لجزء النتيجة للمصنف المراد إضافته، وليس

من الضروري التحقق من جزء الإجراء لأنه من المفترض أن المصنفين هما من مجموعة الإجراء نفسها.

IS SUBSUMER (cl_{sub}, cl_{tos})

1. if ($cl_{sub}.exp > \theta_{exp}$ and $cl_{sub}.q > \theta_r$ and $cl_{sub}.M$ is empty)
2. if (the number of # in $cl_{sub}.C \leq$ the number of # in $cl_{tos}.C$)
3. if ($cl_{sub}.E$ is equal to $cl_{tos}.E$)
4. return true
5. return false

الشكل (5-23): خوارزمية التحقق من تكافؤ المصنفات

في هذا الفصل تم تناول النظام ACS2 بكل تفاصيله من تمثيل المعرفة وتعريف البارامترات المختلفة والخوارزميات الفرعية المستخدمة، وسوف يتم في الفصل السابع إجراء مجموعة من التعديلات على هذه الخوارزميات من أجل استخدام نظام ACS2 في الأوساط ذات المداخل المستمرة.

الفصل السادس: أنظمة الزمن الميت

والتحكم من خلال النموذج التنبؤي

1.6. الأنظمة ذات أزمنة التأخير الميتة dead-time process

6-1 - مقدمة:

العديد من الأنظمة وعمليات التحكم تعاني من أزمنة ميتة في سلوكها الديناميكي، حيث أن المسبب الأساسي لهذا النوع من أزمنة التأخير هو ظاهرة انتقال الكتلة أو الطاقة أو المعلومات، أيضاً من الممكن أن تكون ناتجة عن أزمنة المعالجة أو تراكم الفوارق الزمنية عندما يكون لدينا عدة أنظمة تحكم بسيطة مرتبطة مع بعضها ضمن سلسلة.

الفكرة الأساسية في الأنظمة التي تعاني من مشكلة الزمن الميت هي أن أي إجراء متخذ بناءً على متغيرات دخل النظام لا يظهر تأثيره على سلوك النظام أو متغيرات التحكم إلا بعد فارق زمني هو ما نسميه الزمن الميت dead-time، وهذا هو أحد أهم الأسباب التي يجعل تصميم المتحكمات لهذا النوع من الأنظمة أكثر صعوبة.

على سبيل المثال: ليكن لدينا نظام تدفئة في بناء، المرجل يتواجد في قبو هذا البناء ويتصل مع الغرف الموزعة في البناء من خلال مجموعة من الأنابيب، زيادة فتحة صمام الغاز في المرجل ستؤدي إلى زيادة درجة حرارة الماء في المرجل ولكن سيكون علينا الانتظار لمدة زمنية معينة قبل وصول الماء الساخن إلى الغرف، أو بكلام آخر سيعاني هذا النظام من زمن ميت ناتج عن الزمن اللازم لانتقال الماء الساخن من غرفة المرجل وحتى باقي الغرف، يعتمد هذا الزمن على المسافات الفاصلة وقيمة تدفق الماء.

6-2 - صعوبات التحكم بأنظمة الزمن الميت:


من الصعب جداً التحكم بالعمليات التي تعاني من أزمنة تأخير ميتة واضحة من خلال المتحكمات التقليدية وذلك للأسباب الرئيسية التالية:

- 1- إجراءات التحكم الأساسية تحتاج إلى زمن ليظهر تأثيرها في متغيرات الخرج.
- 2- لا يظهر تأثير الضجيج قبل مدة زمنية طويلة.
- 3- إجراء التحكم المتخذ في لحظة زمنية ما يعالج الخطأ الناشئ قبل مدة زمنية.
- 4- بالأخذ بعين الاعتبار المجال الترددي سيسبب الزمن الميت فروقات في الصفحة إضافية قد تؤدي إلى عدم استقرار.

3-6 - مثال:

في العديد من الحالات يكون زمن التأخير الميت نتيجة لتراكم أزمنة التأخير للنظم البسيطة المكونة للنظم الأعقد، على سبيل المثال ليكن لدينا مجموعة من خزانات الغاز الأسطوانية كما يظهر في الشكل (1-6)، في هذا النظام تدفق الخرج من الخزان رقم (i) يغذي الخزان التالي (i+1) وبالتالي تتحقق المعادلة (1-6):

$$F_{(i+1)I} = F_{(i)O} \quad (6-1)$$



الشكل (1-6): مجموعة خزانات التعبئة الأسطوانية

عندما يكون مستوى المواد في الخزانات قريب إلى نقطة التشغيل يمكن توصيف السلوك الديناميكي للخزان (مستوى الغاز فيه) من خلال العلاقة الخطية:

$$A \frac{dH_i}{dt} = F_{iI} - F_{iO} \quad (6-2)$$

$$F_{iO} = KH_i \quad (6-3)$$

A: هي مساحة قاعدة الخزان

K: بارامتر يعتمد على مميزات الخزان

وبالتالي يمكن الحصول على تابع تحويل الخزان i

$$H_i(s) = \frac{1/K}{TS+1} F_{iI}(S) , T = A/K \quad (6-4)$$

من أجل الخزان رقم (1)

$$H_1(s) = \frac{1/K}{TS+1} F_{1I}(S) \quad (6-5)$$

من أجل الخزان رقم (2)

$$H_2(s) = \frac{1/K}{TS+1} F_{2I}(S) = \frac{1/K}{TS+1} F_{1O}(S) = \frac{1/K}{TS+1} KH_1(S)$$

$$H_2(s) = \frac{1}{TS+1} \frac{1/K}{TS+1} F_{1I}(S) = \frac{1/K}{(TS+1)^2} F_{1I}(S) \quad (6-6)$$

ويمكن التطبيق من أجل الخزان رقم n ليكون لدينا تابع التحويل P(S)

$$H_n(s) = P(S) F_{1I}(S) = \frac{K_e}{(TS+1)^n} F_{1I}(S) \quad (6-7)$$

$$\text{حيث: } K_e = 1/K$$

4-6 - التحكم من خلال النموذج التنبؤي Model Predictive control : MPC

يعد التحكم من خلال النموذج التنبؤي من أهم تقنيات التحكم التي لها تأثير كبير في مختلف المجالات، وربما يعود ذلك للميزات التالية:

1- إمكانية التعامل مع العديد من الحالات حيث يمكن استخدام طريقة التحكم هذه مع الأنظمة ذات المدخل الواحد والمخرج الواحد (Single-input-single-output) (SISO) وكذلك في الأنظمة متعددة المداخل ومتعددة المخرجات (Multi-input-multi-output MIMO)

2- وكذلك يمكن اعتماد اتخاذ الإجراءات الأمامية والخلفية في التحكم ذو النموذج التنبؤي بشكل مباشر، وبالتالي يمكن الاستفادة من هذه النقطة في التخطيط المسبق لعملية التحكم باتجاه الأهداف المرغوبة.

3- باستخدام النموذج التنبؤي للنظام يمكن إجراء عملية استباقية وتخطيطية للإجراءات التحكمية بهدف الحصول على الأداء الأمثل، أخذين بعين الاعتبار الشروط المفروضة على مداخل ومخارج النظام.

6-4-1- لمحة عامة عن التحكم من خلال النموذج التنبؤي MPC

عند الحديث عن التحكم من خلال النموذج التنبؤي لا يقصد تقنية تحكم معينة بحد ذاتها، وإنما مجال واسع من طرق التحكم التي تتشارك بميزة استخدام نموذج للنظام المدروس بهدف الحصول على إشارة تحكم مثالية، يتم من خلالها الحصول على تابع الهدف بشكل مثالي.

هناك عدة نقاط مشتركة بين تقنيات التحكم التنبؤي:

1- الاستخدام الصريح لنموذج يمثل النظام المدروس وبالتالي يمكن التنبؤ بخرج النظام المستقبلي استجابة للإشارات التحكمية.

2- الإيجاد المسبق لتسلسل الإجراءات التحكمية الأمثل الذي يقوم بتصغير تابع الهدف.

3- يمكن اعتماد استراتيجية تخطيط، وبالتالي في أي نقطة زمنية ضمن عملية التحكم يمكن اعتبار التسلسل المثالي للوصول إلى الهدف.

تختلف خوارزميات التحكم التنبؤي في النموذج المستخدم لتمثيل النظام وتمثيل الضجيج وتابع التكلفة المراد تقليلها.

يتميز التحكم باستخدام النموذج التنبؤي بمجموعة من الميزات عن باقي تقنيات التحكم:

1- تشكل طريقة تحكم سهلة وفعالة وخاصة بالنسبة للأشخاص ذو المعرفة التحليلية بنظم التحكم.

2- يمكن استخدام تقنيات التحكم المعتمدة على فكرة النموذج التنبؤي مع مختلف أنواع الأنظمة والعمليات البسيطة والمعقدة، والمستقرة وغير المستقرة.

3- يمكن التعامل بسهولة مع التطبيقات متعددة الأبعاد أو البارامترات Multi variable.

4-تستخدم هذه التقنية بشكل أساسي من أجل التغلب على أزمنة التأخير الميتة الموجودة في العديد من الأنظمة.


5-يمكن أن تستخدم هذه الطرق من أجل معالجة القيود المفروضة على دخل وخرج أنظمة التحكم، وذلك من خلال إدراج هذه القيود في العملية التصميمية.

6-سيكون من السهل جدا استخدام هذه التقنية في حال معرفة التغيرات المستقبلية بشكل مسبق.

7-تعد تقنية بسيطة مفتوحة على أي تغيرات أو توسعات مستقبلية تعتمد على مفاهيم أساسية معينة.

6-4-2- مفهوم التحكم المعتمد على النموذج التنبؤي MPC:

يمكن أخذ فكرة عن آلية المتحكمات التنبؤية من خلال الشكل (2-6):



الشكل (2-6): مخطط زمني يظهر آلية التحكم التنبؤي

1-في كل لحظة زمنية t يتم توقع خرج النظام $\hat{y}(t+k|t)$ بالاعتماد على قيم الدخل

والخرج السابقة باعتبار اللحظة الزمنية t ، وكذلك إشارات التحكم المستقبلية $u(t+k|t)$


$$k = 1, 2, \dots, N$$

2- إشارات التحكم المستقبلية يجب أن تحسب بحيث تكون أفضل ما يمكن ولتحقيق ذلك يجب اعتماد معيار لذلك، أو مسار مرجعي (reference trajectory $w(t + k|t)$ ، الذي من الممكن أن يكون الجهد المرجعي (القيم المرغوبة). وأيضاً يؤخذ بعين الاعتبار تكلفة عملية التحكم من خلال تابع الهدف في العديد من الحالات

3- من مميزات هذه الطريقة أنها تعتمد استراتيجية تصميمية وأن النموذج التنبؤي للنظام الموضوع مسبقاً يمكن تعديله أثناء عمل النظام، أي عند تفعيل إشارة التحكم $u(t|t)$ ، فإن إشارة التحكم التالية $u(t + 1|t)$ ستهمل أو ستدقق وذلك لأن إشارة خرج النظام $y(t + 1)$ ستصبح معروفة وسنعود إلى الخطوة رقم (1) لتحديد إشارة التحكم $u(t + 1|t + 1)$ بدلاً من إشارة التحكم الموجودة مسبقاً $u(t + 1|t)$ ، أو بكلام آخر أصبح لدينا معلومات جديدة عن سلوك النظام فمن المنطقي جداً الاستفادة منها في العديد من الأمور:

- إيجاد إشارات التحكم المناسبة التالية
- إجراء تقييم للنموذج التنبؤي للنظام وإجراء التصحيح المناسب عليه
- تقييم آلية انتقاء الإجراءات المستخدمة

الشكل (3-6) يظهر الآلية العامة لتطبيق طريقة النموذج التنبؤي:



الشكل (3-6): الآلية العامة لتطبيق طريقة النموذج التنبؤي

3-4-6- مكونات المتحكم المعتمد على النموذج التنبؤي MPC:

يمكن أن تضم خوارزميات التحكم التنبؤي العناصر التالية في بنيتها الأساسية:

1- النموذج التنبؤي

2- تابع الهدف

3- إجراءات الحصول على قانون التحكم

وليس من الضروري أن تشمل كل هذه المكونات الثلاثة وإنما هذا يعود إلى مبدأ الخوارزمية المعتمدة.

5-6- الخلاصة:

بالعودة إلى الفقرة (2-4-6) نجد انه لدينا ثلاثة شروط يجب ان تكون متوفرة في تقنيات التحكم التنبؤي، هذه الشروط الثلاثة محققة في عائلة نظم المصنفات الاستباقية ALCS وبالأخص النظام ACS والنظام ACS2.

حيث أنه خلال التجربة يتم بناء نموذج للوسط من خلال المصنفات الموثوقة وكذلك هناك آليات مرتبطة بالبحث عن الإجراءات المثالية وإمكانية التخطيط المسبق في أي لحظة. بالنتيجة لدينا نظام مصنفات يتميز بقدراته الاستباقية وبالتالي له القدرة على التنبؤ بالحالات التالية للنظام، فإذاً يمكن استخدامه من أجل أحد أهم تطبيقات التحكم وهو التحكم بالأنظمة ذات أزمنة التأخير الميتة.

وعلى هذا الأساس تم تطوير خوارزمية جديدة لأنظمة المصنفات الاستباقية معتمدة على الخوارزمية العامة للنظام ACS2 من أجل التعامل مع تطبيقات التحكم ذات أزمنة التأخير الميتة ضمن الأوساط ذات المداخل المستمرة او الحقيقية.

الفصل السابع: تصميم نظام مصنفات استباقي

بمداخل ذات قيم مستمرة

ALCS with continues-valued Inputs

7. تصميم نظام مصنفات استباقي بمدخل ذات قيم مستمرة

ALCS with continues-valued Inputs

7-1- مقدمة:

تم استخدام نظم المصنفات الاستباقية ALCS حتى الآن مع مسائل نموذجية ذات مدخل ثنائية (مجموعة تعريف قيم المدخل هي الثلاثية $\{0, 1, \#\}$ ، وأغلب هذه المسائل بعيدة عن تطبيقات العالم الحقيقي).

في هذا الفصل سنقوم بإجراء تعديل على أحد نظم المصنفات الاستباقية وهو ACS2 من أجل أن يستطيع التعامل مع مدخل ذات قيم مستمرة، وبهذا نكون قد اقتربنا أكثر باتجاه تطبيقات واقعية ضمن إطار نظم المصنفات الاستباقية ALCS، حيث أن اختلاف نوع المدخل المعتبر سيتطلب معالجة وتعديلات على العديد من النقاط في بنية النظام العامة وفي بنية المصنفات وآلية الخوارزمية الجينية.

7-2- بنية المصنفات:

7-2-1- التفاعل مع الوسط وجزء الشرط في المصنف:

يجب أن تسمح البنية الجديدة باستخدام نظم المصنفات الاستباقية ALCS ضمن بيئة ذات مدخل حقيقية، لذلك يجب إجراء تعديل على بنية المصنف بشكل أساسي وآلية التعميم في المصنفات.

كما هو الحال مع النظم الاستباقية كل مصنف له المكونات الأساسية (شرط - إجراء - نتيجة)، حيث أن الجزء الذي سيكون على احتكاك مباشر مع الوسط وبالتالي مع القيم المستمرة هو جزء الشرط المكون من عدد من المميزات، وكل مميزة ستعرف من خلال مجال تعريف

للقيم $[p_{min}, q_{max}]$ ، في حال انتماء الدخل عند هذه الميزة لهذا المجال ستعتبر محققة وبالتالي يمكن تفعيل المصنف (في حال تحقيق كل المميزات له في جزء الشرط).
ملاحظة: ليس من الضروري أن تتشارك جميع المميزات بالصفات ومجالات التعريف نفسها، أي قد يتم التعامل مع عدة أنواع من المتغيرات ذات معاني مختلفة ضمن جزء الشرط أو في بنية المصنف الأساسية.

لتعريف مجالات الانتماء سيتم اعتماد طريقة التمثيل (c , s) [13] حيث:

c: قيمة عددية تمثل مركز مجال التعريف

s: قيمة عددية تمثل مجال أو عرض مجال التعريف

وينتج من هذا التمثيل مجال التحقق $[p, q]$ الذي يعتبر أنه يحقق الميزة في حال أن القيمة الواردة من الوسط تنتمي إليه بالشكل التالي:

$$p = \max(p_{min}, c - s)$$

$$q = \min(q_{max}, c + s) \quad (7-1)$$

7-2-2- جزء الإجراء Action:

يحدد في هذا الجزء الإجراء المقترح للتنفيذ في المصنف، حيث سيتم تحديد واحد من الإجراءات الممكنة في التطبيق المعبر، وسيتم اختيار الإجراءات بناءً على طبيعة التطبيق كما سنرى لاحقاً.

7-2-3- جزء النتيجة Effect وآلية التعميم:

ظاهرياً يوافق التعامل مع هذا الجزء التعامل مع جزء الشرط ولكن يوجد فكرة أساسية يختلف اعتبارها في الجزأين وهي آلية التعميم #، حيث أنه في جزء الشرط لا وجود للرمز # وإنما يكون التعميم في ميزة معينة عندما تشمل كامل مجال تعريف لقيم الدخل المتعلقة بالميزة $[p_{min}, q_{max}]$ ، ويمكن القول عندها أن هذه الميزة معممة أو غير مهمة، أو يمكن الحفاظ

على استخدام الرمز # للدلالة على الانتماء إلى كامل المجال وهذا ما سيتم اعتماده في هذا البحث.

أما بالنسبة لجزء النتيجة فإن رمز التعميم # له معنى آخر وهو عدم التغيير في الميزة المحتوية عليه pass-through، أي أن المصنف يتوقع بأن الميزة سوف تبقى على حالها ولن تتغير، وفي حال حدوث غير ذلك سيؤدي إلى حالة توقع خاطئ وبالتالي إلى إنقاص جودة المصنف كما سنرى لاحقاً.

وبما أن من أهم خصائص نظم المصنفات الاستباقية هي القدرة على التنبؤ بالحالة التالية للوسط الناتجة عن تنفيذ الإجراء المحدد في المصنف المختار من خلال تحديد هذه الحالة في جزء النتيجة، فمن غير المنطقي إلغاء هذه الميزة في جزء النتيجة لذلك سنحافظ على استخدام الرمز # في جزء النتيجة للدلالة على أن الميزة ستبقى على حالها، وسيكون هناك هامش تغيير مقبول في حال أن المصنف يتوقع عدم التغيير من خلال الرمز #، هذا التغيير يحدد من خلال هامش معرف بواسطة البارامتر V_1 .

إذا سيكون لدينا خيارين لشكل الخاصيات في جزء النتيجة:

1- مجال محدد من خلال تحديد مركز وعرض المجال (s , c) كما هو الحال في جزء الشرط

2-# للتعبير أن الخاصية ستبقى على حالها ولن تتغير

وبالنسبة لآلية التعميم فهي كما يلي:

1- في جزء الشرط: تكون الميزة معمة في حال أن المجال المرتبط مع الميزة يشمل كامل القيم الممكنة لهذه الميزة ضمن إطار التطبيق المدروس (المجال الأعظمي الممكن)، وسيكون الرمز # في جزء الشرط يعني الانتماء إلى كامل المجال.

2- في جزء النتيجة: من خلال الرمز # أي أن المميّزة لن تتغير عند تنفيذ الإجراء المحدد في المصنف

7-2-4- العلام Mark:

يستخدم جزء العلام من أجل الاحتفاظ بحالات الوسط التي قام المصنف فيها بالتنبؤ بشكل خاطئ، من أجل استخدامها لاحقاً لكي يتم تخصيص المكونات أو المميزات المعممة التي أدت إلى التنبؤ الخاطئ بحالة الوسط التالية.

ولكن اختلاف طبيعة القيم سيؤدي إلى اختلاف طرق تعديل القيم وآلية تخصيص المميزات كما يلي:

ليكن لدينا S1 حالة الوسط التي أخطأ فيها المصنف وكان لدينا حالة غير قابلة للتصحيح، أي أن S1 أيضاً ستكون محفوظة في العلام للمصنف المعتبر، و S2 حالة الوسط التي أصاب فيها المصنف وقام بالتنبؤ بشكل صحيح.

فعندها سيتم اختيار أحد المميزات التي تحقق: S1 لا تقارب S2 عند هذه المميّزة أي S1 و S2 تحققان العلاقة التالية: $S1.Att - S2.Att > V_0$

وجزء النتيجة الموافق عند هذه المميّزة في المصنف هو معمم أي #، ولا داعي هنا للتحقق من جزء الشرط لأنه حكماً له درجة من التعميم ليحقق الحالتين S1 & S2، فعندها يتم تعديل المصنف عند المميّزة الموافقة في جزأي الشرط والنتيجة كما يلي:

$$Cl.C.Att.c_{new} = Cl.E.Att.c_{new} = S2.Att \quad (7-2)$$

$$Cl.C.Att.s_{new} = Cl.E.Att.s_{new} = rand (||S2.Att - S1.Att| - V_0|)$$

حيث:

Cl: المصنف المعتبر

Cond / effect: جزأي الشرط والنتيجة للمصنف


Att: المميّزة المختارة

S1.Att: القيمة الموافقة للمميّزة المختارة في حالة الوسط

S2.Att: القيمة الموافقة للمميّزة المختارة في حالة الوسط

V_0 : ثابت لضمان أن مجال القيم الجديد للمميّزة المعتبرة لن يضم قيمة الحالة الخاطئة S1,
($V_0=0.1$)

يظهر الشكل (1-7) آلية التعامل مع العلام في المصنف وتعديل المصنف وفقاً له.



الشكل (1-7) آلية تحديث المصنف وفق العلام

إذاً هنا قمنا بإضافة بارامتر جديد إلى مجموعة بارامترات النظام وهو V_0 الذي يضمن عدم تقاطع مجالات القيم الجديدة الناتجة عن تخصيص المكونات الثابتة

ملاحظة: في حال وجود عدة قيم لنفس الميزة في العلام، فعندها يتم اعتبار القيمة الأقرب للقيمة الموجودة في الميزة الموافقة في حالة الوسط المتوقعة بشكل صحيح S2.

يمكن القول أن العلاقات (2-7) تعبر عن آلية التخصيص المعتمدة من أجل عدم الوقوع في الحالات الخاطئة التي سبق وأن وقع فيها النظام.

وبالنسبة للبارامترات الأخرى ضمن المصنف سيتم الحفاظ عليها كما هي في نظام ACS2

(num / exp / aav / t_{ALP} / t_{ga} / ir / r / q) ، كما ورد معنا في الفقرة (5.2).

7-3- الخوارزمية العامة:

بالنسبة للخوارزمية العامة للنظام الجديد المقترح مطابقة للآلية العامة لنظام ACS2 ولكن يوجد بعض الاختلافات بالنقاط التالية:

7-3-1- تشكيل مجموعة التطابق [M]:

ستختلف آلية انتقاء المصنفات التي توافق الحالة الراهنة للوسط في ضوء التعامل مع القيم المستمرة، حيث ستم من خلال التحقق من انتماء قيم المميزات المقروءة من الوسط إلى المجالات المحددة في جزء الشرط للمصنف وفق كل مميزة.

7-3-2- اختيار الإجراء:

كما ذكرنا من قبل في نظام ACS2 سيكون اختيار الإجراء بطريقة احتمالية، فإما ان يكون بشكل عشوائي بهدف البحث واستكشاف المصنفات الجديدة او سيتم اختيار المصنف الأفضل في مجموعة التطابق، ولكن الاختلاف هنا انه في نظام ACS2 تم استثناء المصنفات التي تتوقع صراحة عدم حصول إي تغير في الوسط ولن تدخل في المنافسة مع باقي المصنفات.

اما في حالتنا وفي ضوء مقترح استخدام هذه الخوارزميات مع نظم التحكم بمدخل مستمرة والتي تعاني من أزمنة تأخير كبيرة سنقوم بإعادة صياغة هذه النقطة، وسيتم اعتبار المصنفات المذكورة بالمنافسة مع باقي المصنفات كما سنرى لاحقا في أحد الإجراءات الفرعية، حيث سيكون لدينا عملية تخطيط للإجراءات والأهداف وهي التي ستحدد فعالية اختيار مثل هذه المصنفات.

ملاحظة: طبيعة التطبيق او المسألة المدروسة هي التي تحدد مثل هذه النقاط، فمع النظام ACS2 [9] و ACS [5] تم استخدامها مع تطبيقات بسيطة لروبوتات ضمن متاهة، لذلك ظاهرياً اختيار المصنف قد يكون غير مجدي.

أما في حالتنا ستكون هذه المصنفات أساسية وذات أهمية من أجل ضمان سير العملية التحكمية بشكل صحيح وتجاوز عقبة أزمنة التأخير الميته.

7-3-3 - عملية التعليم الاستباقي ALP:

كما هو الحال مع نظام ACS2 يتم إجراء تقييم للمصنفات الموجودة في مجموعة الإجراء [A]، وعلى هذا أساس يتم إنشاء مصنفات جديدة أو حذف أخرى، وفق العديد من الحالات المبينة في الفقرات التالية:

1- حالة التوقع الصحيح (حالة متوقعة):

في حال أن المصنف قام بالتنبؤ بشكل صحيح يتم زيادة جودة المصنف q وهنا أيضا يجب التمييز بين ثلاث حالات ممكنة:

a. حالة متوقعة صحيحة وعلام المصنف فارغ: لا يتم إضافة أي مصنف جديد بل فقط يتم زيادة جودة المصنف q.

b. حالة متوقعة صحيحة ويوجد قيم في علام المصنف ولكن لا يوجد فروقات بين العلام والحالة المتوقعة الصحيحة يمكن تخصيصها، فعندها يتم أيضا زيادة جودة المصنف q ولا يتم إضافة أي مصنف جديد.

c. حالة متوقعة صحيحة ويوجد فروقات مع علام المصنف يمكن تخصيصها في المصنف: يتم هنا زيادة جودة المصنف ويتم أيضا إضافة مصنف جديد ناتج من تخصيص المميزات المختلفة بين الحالة المتوقعة الصحيحة وبين علام المصنف.

ملاحظة: من أجل اختبار الفروقات بين حالات الوسط وبين العلام وباعتبار التعامل مع القيم المستمرة فإن الاختبار باستخدام المساواة المباشرة بين القيم ستكون ذات احتمال صغير جدا وغير فعال، لذلك سيتم اعتماد اختبار الانتماء إلى مجالات متقاربة بين القيم، أو بكلام آخر عندما يكون الفرق بين القيمتين المعتبرتين أكبر من هامش معين فعندها يكون لدينا حالة فرق، يمكن تحديد هذا الهامش من خلال البارامتر V_1 .

2- حالة التوقع الخاطئ (حالة غير متوقعة):

وهي الحالة التي يخطئ فيها المصنف في توقع الحالة التالية للوسط الناتجة عن تنفيذ الإجراء المحدد في المصنف المعتبر ويمكن تمييز الحالتين التاليتين:

a. حالة قابلة للتصحيح: وهي حالة التوقع الخاطئ عند المميزات التي تحوي الرمز # في جزء النتيجة ضمن المصنف، وبالتالي يمكن توليد مصنف جديد ناتج عن تخصيص هذه المميزات، أي يجب تعريف مجال القيم للميزة في جزء النتيجة من خلال تحديد الثنائية (c , s) له بالطريقة التالية:

$$c = S_{env} \quad \& \quad s = \text{rand}(S_0) \quad (7-3)$$

S_{env} : قيمة الميزة الموافقة في حالة الوسط الجديدة

S_0 : البارامتر المعتمد من أجل تخصيص المميزات المعممة في جزء النتيجة (ذات التوقع عدم التغيير من خلال الرمز #) والتي أدت إلى التوقع الخاطئ، كقيمة افتراضية سيكون $(S_0 = 0.25)$.


b. حالة غير قابلة للتصحيح: وهي حالة التوقع الخاطئ غير القابلة للتصحيح وفي هذه الحالة من غير الممكن إنشاء مصنف جديد، وهنا يتم إضافة قيمة حالة الوسط إلى علام المصنف.

3-الحالات عديمة الجدوى:

كما ذكرنا من قبل هذه الحالات التي لا يؤدي تنفيذ الإجراء المحدد في المصنف المختار إلى أي تغيير في الوسط، حيث يتم إنقاص جودة المصنف كما هو الحال مع النظام ACS. أما ضمن إطار المداخل ذات القيم المستمرة ومقترح استخدام نظم المصنفات الاستباقية من أجل التحكم بأنظمة التحكم ذات أزمنة التأخير الميتة، يجب التمييز بين نوعين من هذه الحالات:

a. حالات هي فعلا عديمة الجدوى: حيث لا يؤدي اتخاذ الإجراء المقترح إلى أي تغيير فعلي في الوسط

مثال: ليكن لدينا النظام ذو الاستجابة في الشكل (2-7):



الشكل (7-2): مثال عن استجابة الأنظمة ذات أزمنة التأخير الميتة

في اللحظات الزمنية $t < 0.5$ مثلاً إعطاء الإشارة التحكمية قيمة الصفر غير منطقي فهنا لدينا قيمة خطأ كبيرة، لذلك المصنفات التي تقوم بإلغاء الإشارة التحكمية في أزمنة مبكرة قبل بدء إشارة خرج النظام بالصعود سوف تعاني من هذا النوع من الحالات، وبالتالي سيؤدي إلى إنقاص جودة هذه المصنفات q .

b. حالات عديمة الجدوى ظاهرياً: نفس المصنفات في المثال السابق ولكن عند أزمنة متأخرة $t \geq 0.5$ بعد ثبات إشارة الخرج، الظاهر أنه لدينا حالة غير مجدية، ولكن قد يكون هذا المصنف هو الأنسب على اعتبار أن إشارة الخرج في اللحظات الزمنية التالية سوف تبدأ بالصعود وتفعيل إشارة التحكم لا يؤدي إلى تغيرات مباشرة في الخرج. بالنتيجة يمكن القول إننا نتعامل مع أوساط غير حتمية أو أنها تحتوي على حالات لا تخضع لخاصية ماركوف non-Markov stats.

وللتعامل مع هذا النوع من الحالات تم اقتراح في نظام ACS [5] تكوين مصنفات جديدة ناتجة عن الجمع بين مصنفين متتاليين، وبالتالي الغاء التعامل مع حالة الوسط التي تؤدي إلى هذه

الحالات، ولكن قد تكون هذه الطريقة غير فعالة لأن استجابة النظم ذات أزمنة التأخير الميت تحتوي العديد من الحالات المتتالية التي لها هذه الصفة. لذلك يقترح هذا البحث إضافة مكون جديد وهو مراقب للنظام أو مخطط الإجراءات ويكون لديه المهام التالية:

- a. الكشف المسبق عن الحالات عديمة الجدوى.
- b. تعديل قيمة جودة المصنفات q في هذا النوع من الحالات.
- c. تجزئة مراحل عمل النظام على عدة مراحل، يتم في كل منها تقييم اختيار المصنفات أو الإجراءات الأنسب على أساس اعتبار الحالات غير الحتمية، أو بكلام آخر التخطيط المرحلي للأهداف من خلال تجزئ التجربة لعدة مراحل في كل مرحلة يكون هناك هدف يجب على النظام تحقيقه كما مر معنا في الفقرة (4-2-9). ويتم تحقيق ذلك من خلال خوارزمية فرعية تعتمد على فكرة تخطيط الإجراءات وفكرة التعليم الموجه.

4-الحالات غير الموجودة:

في حال ان كل المصنفات ضمن مجموعة الإجراء $[A]$ قامت بتوقع خاطئ، فهذا يعني أنه لدينا ثلاثية جديدة (شرط - إجراء - نتيجة) غير معالجة في النظام، وبالتالي يجب استدعاء إجرائية مسؤولة عن توليد مصنف جديد يعالج هذه الحالة، وهي إجرائية التغطية covering، حيث تكون مدخلات هذه الإجرائية:

σ_{-1} : الحالة السابقة للوسط.

act: الإجراء المنفذ.

σ : الحالة الناتجة عن تنفيذ الإجراء act عند اعتبار σ_{-1} هي حالة الوسط الفعالة

وستعتمد إجرائية التغطية نفس طريقة النظام XCSR [14,13] كما يلي:

$$\begin{aligned}
cl.cond.Att_i.c &= (\sigma_{-1}).Att_i \\
cl.cond.Att_i.s &= rand(S_0) \\
cl.effect.Att_i.c &= \sigma.Att_i \\
cl.effect.Att_i.s &= rand(S_0) \quad (7-4)
\end{aligned}$$

حيث $S_0 = 0.5$ [13].

ملاحظة: يجب الانتباه إلى نقطة أساسية، وهي أنه في حال أن أحد المميزات لم تتغير في الحالتين σ و σ_{-1} فعندها يجب أن تكون معمة في جزء النتيجة.

$$\sigma.Att_i = (\sigma_{-1}).Att_i$$

ولكن كما هو الحال في الاختبار مع جزء العلام يجب أن نعتمد طريقة الفرق بين القيمتين، أي عدم التحقق من المساواة المباشرة، أو بكلام آخر في حال أن الفرق بين القيمتين أكبر من هامش معين V_1 فعندها يعتبر تغيير في الميزة. أي:

$$\begin{aligned}
\text{If } |\sigma.Att_i - (\sigma_{-1}).Att_i| < V_1 \quad \text{then} \\
cl.cond.Att_i.c &= (\sigma_{-1}).Att_i \\
cl.cond.Att_i.s &= V_1 + rand(S_0 - V_1) \\
cl.effect.Att_i &= \# \quad (7-5)
\end{aligned}$$

حيث يجب ضمان أن المصنف الجديد يحقق الثلاثية $(\sigma, act, \sigma_{-1})$ وفق معيار الفرق بدل المساواة.

7-3-4- إضافة المصنفات الناتجة عن إجرائية ALP:

كما رأينا هناك العديد من الحالات التي يتم فيها إنشاء مصنفات جديدة، وبالتالي يجب أن تضاف إلى المجموعة العامة للمصنفات [P] ومجموعة الإجراء [A]، ولكن هنا يجب التحقق من أن هذه المصنفات غير موجودة من قبل أو ألا يوجد مصنفات مكافئة لها، ففي هذه الحالات لا داعي لإضافة المصنف بل يكفي زيادة جودة المصنف المكافئ.

من أجل التعامل مع إجرائية إضافة المصنفات الجديدة يجب إعادة تعريف المعايير التالية لتلائم التعامل مع القيم المستمرة.

7-3-4-1 - التكافؤ أو التصنيف الضمني Subsumption :

حتى نستطيع مكافأة مصنف جديد cl_{new} ضمن مصنف آخر cl_{sub} يجب أن تتحقق الشروط التالية:

$$cl_{sub}.exp > \theta_{exp}-1$$

$$cl_{sub}.q > \theta_r-2$$

3- لا يوجد علام للمصنف cl_{sub}

4- أن يكون جزء الشرط للمصنف cl_{sub} يحتوي جزء الشرط للمصنف الجديد cl_{new} في كل قيم المميزات أي:

$$cl_{new}.cond.Att_i \subset cl_{sub}.cond.Att_i$$

5- أن يكون جزء النتيجة للمصنف الجديد يكافئ جزء النتيجة للمصنف cl_{sub} ، أي ان يتحقق أحد النقاط التالية:

- $cl_{new}.effect.Att_i \subset cl_{sub}.effect.Att_i$ if $cl_{new}.effect.Att_i \neq \#$ & $cl_{sub}.effect.Att_i \neq \#$
- $cl_{new}.cond.Att_i \subset cl_{sub}.effect.Att_i$ if $cl_{new}.effect.Att_i = \#$ & $cl_{sub}.effect.Att_i \neq \#$
- $cl_{new}.effect.Att_i \subset cl_{sub}.cond.Att_i$ if $cl_{new}.effect.Att_i \neq \#$ & $cl_{sub}.effect.Att_i = \#$
- $cl_{new}.cond.Att_i \subset cl_{sub}.cond.Att_i$ if $cl_{new}.effect.Att_i = \#$ & $cl_{sub}.effect.Att_i = \#$

ملاحظة: في حال وجود مصنف يحقق النقاط (4 و 5) مع المصنف الجديد، ولكن هذا المصنف ليس من المصنفات ذات الخبرة أي لا يحقق النقاط (1 و 2) فمن غير الصحيح أن نكافئ المصنف الجديد معه، لأن مجالات القيم المعالجة في جزأي الشرط والنتيجة للمصنف الجديد ستكون أكثر تخصيص وبالتالي لا يجوز إدراجها ضمن مجالات أكبر (أكثر تعميم) غير موثوقة.

7-3-2- مساواة مصنفين في جزأي الشرط والنتيجة:

حتى يكون مصنف مساوي لمصنف آخر يجب أن يتطابق جزأي الشرط للمصنفين مع بعض وكذلك جزأي النتيجة لهما.

7-3-5- التعليم المعزز RL في النظام الجديد:

سيتم استخدام الآليات نفسها المتبعة مع خوارزمية النظام ACS2 المتعلقة بفكرة التعليم المعزز.

7-3-6- الخوارزمية الجينية:

بشكل مشابه للنظام ACS2 سيتم هنا تنفيذ الخوارزمية الجينية ولكن الاختلاف كما هو الحال مع XCSR [13 , 14] في آليات معامل الطفرة ومعامل العبور وكذلك وكما رأينا مسبقا مع إجراءات التغطية.

7-3-6-1- معامل الطفرة Mutation:

من خلال معامل الطفرة سيتم اتباع آلية احتمالية لإجراء تعويم على مجالات المميزات في جزء الشرط، فعند اختيار أحد المميزات سيتم تعديل مجال قيمها في جزء الشرط ليصبح ذو تعميم أكبر، أي مجال قيم أكبر وسيتم ذلك من خلال إضافة قيمة عشوائية لعرض مجال التعريف للخاصية s ، أي:

$$cl.cond.Att_{i.s} = cl.cond.Att_{i.s} + rand(m) \quad (7-6)$$

حيث أن $m = 0.1$ (نسبة معامل الطفرة).

7-3-6-2 - معامل العبور Crossover:

سيختلف تطبيق معامل العبور هنا في حالة القيم المستمرة عن النظام ACS2 الأساسي، حيث لن نشترط ان يكون كلا المصنفين يتوقعان نفس التغيير في الوسط وستكون المبادلة بشكل احتمالي لكلا جزأي الشرط والنتيجة بشكل متوافق على مستوى كامل المميزات.

ملاحظة: بعد تطبيق معامل الطفرة ومعامل العبور سينتج لدينا مصنفين جديدين، وهنا يجب إضافة هذين المصنفين إلى مجموعة الإجراءات الحالية [A] المجموعة العامة، وستتم عملية الإضافة كما كان الحال مع إضافة المصنفات الناتجة عن إجرائية ALP حيث يجب التأكد من عدم وجود مصنفات مساوية أو مكافئة، ولكن الاختلاف في حالة الخوارزمية الجينية والمصنفات الناتجة منها هو انه يجب التأكد من إمكانية ذلك، أي أن مجموعة الإجراءات أو المجموعة العامة للمصنفات لم تبلغ الحد الأعظمي المسموح فيه من حيث تعداد المصنفات، وفي هذه الحالة يجب حذف مصنفات أخرى ليحل محلها المصنفات الجديدة، ويتم هنا اتباع طريقة الحذف المتبعة في خوارزمية النظام ACS2.

7-4 - المراقب ومخطط الإجراءات:

بالاعتماد على مبدأ التعليم الموجه بالأهداف الوارد في الفقرة (4-2-9)، نجد أنه من الممكن أن تقبل نظم المصنفات الاستباقية مكون إضافي يكون مسؤول عن تخطيط أهداف مرحلية يجب بلوغها تبعاً حتى الوصول إلى الهدف النهائي.

وبالإضافة للمهام التي ذكرناها سابقاً في هذا الفصل في الفقرة (7-3-3)، وفي ضوء فكرة أنظمة التحكم ذات أزمدة التأخير الميت سيكون على المراقب توقع الزمن الميت الذي يعاني منه النظام، ويجب أن يقوم باعتباره في آليات اختيار الإجراءات، حيث سيقوم المراقب بالاستفادة من نموذج النظام واستجابته في الحلقة المفتوحة لتحديد المراحل المختلفة لعمل النظام.

7-5- الخلاصة:

إذاً تم في هذا الفصل العمل على مجموعة من التعديلات في بنية خوارزمية النظام ACS2 لكي يوافق التعامل مع الأوساط ذات المداخل المستمرة مع اعتبار مسائل الزمن الميت وما يناسبها من آليات توافق طبيعة هذه المسائل، ويمكن تلخيص النقاط التي تم العمل عليها بما يلي:

- 1- بنية المصنف: من خلال استخدام طريقة تحديد مجالات الانتماء بطريقة (مركز، عرض مجال) في كلا الجزأين الشرط والنتيجة
- 2- آلية التعميم "#": بالنسبة لجزء الشرط تمثل الانتماء لكل المجال، أما بالنسبة لجزء النتيجة تمثل توقع عدم التغيير إلا ضمن هامش محدد من خلال البارامتر V_1 .
- 3- آلية تحديد المكونات الثابتة والتعامل مع علام المصنف، واعتبار مبدأ التقارب بين الحالات من خلال البارامتر V_0 بدلاً من المساواة المباشرة
- 4- تشكيل مجموعة التطابق: حيث يتم التحقق من انتماء المميزات إلى المجالات المحدد في جزء الشرط ضمن المصنف
- 5- التعامل مع الحالات القابلة للتصحيح من خلال تحديد مجال انتماء الميزة المعممة
- 6- الاعتبار الجديد للحالات عديمة الجدوى والأوساط التي لا تخضع لخاصية ماركوف والتعامل معها من خلال المراقب للنظام ومخطط الإجراءات.
- 7- إجرائية التغطية للحالات غير الموجودة
- 8- التكافؤ والتصنيف الضمني للمصنفات
- 9- الخوارزمية الجينية متضمنة آليات الطفرة ومعامل العبور


الفصل الثامن: التطبيق العملي والنتائج

نتائج البحث والتوصيات والآفاق المستقبلية

8. التطبيق العملي والنتائج:

8-1- الجملة المستخدمة في التطبيق:

تم استخدام الخوارزمية المقترحة للتحكم بتدفق غاز ناتج من جملة مؤلفة من ثلاثة مراحل، كل مرحلة عبارة خزان للغاز، ويتم تغذية الجملة من مصدر للغاز بعيد يتم التحكم فيه من خلال صمام تماثلي، الشكل (8-1) يظهر الجملة العملية:



الشكل (8-1): المخطط العام للجملة العملية

تعاني هذه الجملة من زمن تأخير ميت ناتج من عدة عوامل وهي:

- الزمن اللازم لوصول الغاز من المصدر للخزان الأول.
- الأزمنة اللازمة والمتراكمة في كل مرحلة من مراحل الخزانات الثلاثة.

بالعودة إلى الفقرة (6-3) يمكن وضع تابع التحويل لكل خزان بالشكل التالي:


$$H(s) = \frac{1/K}{TS+1} F_I(S) \rightarrow G(S) = \frac{1/K}{TS+1}$$

على فرض $T = K = 1$ ، يصبح لدينا:

$$G(S) = \frac{1}{1+S}$$


وسنقدر التأخير الزمني للجملة بالمقدار e^{-5S} (وهو يمثل كافة أزمنة التأخير الميتة في الجملة الناتجة عن الزمن اللازم لوصول الغاز إلى الخزان الأول، وأيضاً أزمنة التأخير في مراحل الخزانات).

ويمثل الشكل (2-8) المخطط الصندوقي للجملة



الشكل (2-8): المخطط الصندوقي للجملة


ويكون تابع التحويل للجملة بشكل كامل: $G(S) = e^{-5s} \frac{1}{(S+1)^3}$



الشكل (3-8): المخطط الصندوقي المختصر للجملة

8-2- الربط بين نظام المصنفات والتطبيق:

إذاً أصبح لدينا متحكم مبني على نظام المصنفات ACS2 سيتم استخدامها للتحكم بجملة خزانات الغاز المذكورة في الفقرة السابقة، من خلال قيادة الصمام المسؤول عن تغذية هذه الجملة بالغاز.



الشكل (4-8): المخطط العام للجملة مع نظام المصنفات

إذا بارامتر التحكم هو مقدار فتح الصمام وهو يمثل جزء الإجراء في المصنف.

أما بالنسبة لمداخل المتحكم (نظام المصنفات) والتي تمثل القراءات من الجملة إلى المتحكم وفي نفس الوقت هي المميزات المعتبرة في جزء النتيجة وجزء الشرط، فقد تم اعتبار القراءات التالية:

- 1- بارامتر التحكم (فتحة الصمام) في اللحظة الزمنية الراهنة $F_{in}(t)$ والتي تمثل الإشارة التصحيحية الناتجة من المتحكم
- 2- بارامتر التحكم (فتحة الصمام) بعد التأخير الناتج عن الزمن الميت $F_{in}(t-5)$
- 3- تدفق الغاز الناتج من الخزان الأول في اللحظة الزمنية الراهنة $F_1(t)$

4- تدفق الغاز الناتج من الخزان الثاني في اللحظة الزمنية الراهنة $F_2(t)$

5- تدفق الغاز الناتج من الخزان الثالث في اللحظة الزمنية الراهنة $F_3(t)$ ويمثل بارامتر

التحكم المطلوب (خرج الجملة) F_{out}

يمثل الشكل (4-8) المخطط الصندوقي العام للجملة والمتحكم ويظهر آلية التفاعل بينهما.

8-3 - الأدوات المستخدمة:

تم استخدام بيئة الماتلاب (MATLAB) من أجل بناء نموذج للجملة العملية المقترحة وكذلك أداة المحاكاة المرفقة من أجل إجراء التجارب المختلفة، وتم استخدام لغة البرمجة الخاصة بهذه البيئة في بناء الخوارزمية الجديدة بكل أجزائها ومكوناتها.

8-4 - البناء الخوارزمي:

وفق التوصيف الوارد في الفصل السابع من هذا البحث، والذي تحدث عن التعديلات والنقاط الواجب اعتبارها من أجل بناء خوارزمية جديدة لنظم المصنفات الاستباقية قادرة على التعامل مع الأوساط ذات المداخل المستمرة، وكذلك بالاعتماد على الخوارزمية ACS2 [9] ، تم وضع الأسس العامة والتفصيلية لهذه الخوارزمية من خلال بناء مجموعة مع العمليات والوظائف الفرعية الضرورية والأساسية لتحقيق الآلية العامة لنظم المصنفات الاستباقية، ومنها:

- حلقة التنفيذ العامة.
- التحقق من التطابق وتشكيل مجموعة التطابق.
- انتقاء الإجراء الأفضل وتشكيل مجموعة الإجراء.
- عملية التعليم الاستباقية ALP والعمليات الفرعية ضمنها كالتحقق من الحالات الصحيحة وكشف الحالات القابلة للتصحيح والحالات غير القابلة للتصحيح.
- عملية التغطية Covering المستخدمة لتأمين مصنفات تطابق حالة الوسط في حال عدم وجودها ضمن المجموعة العامة.


- التعامل مع المصنفات وإضافتها أو حذفها.
 - إجراء التعميم باستخدام الخوارزمية الجينية وتنفيذ آليات الطفرة Mutation والعبور Crossover.
 - التحقق من مكافأة ومساواة المصنفات.
- ويحتوي الملحق (A) من هذا البحث على المخططات الصندوقية للخوارزمية لكافة العمليات والوظائف المستخدمة والموجودة ضمن الخوارزمية الجديدة المقترحة.

8-5- البناء البرمجي:

تم استخدام منهجية البرمجة كائنية التوجه (Object-Oriented Programming OOP) لتحقيق البنية البرمجية المطلوبة للخوارزمية الجديدة من خلال بناء مجموعة من الصفوف Classes، تؤمن هذه الصفوف التعامل والتفاعل مع مختلف المكونات لنظم المصنفات الاستباقية، وكذلك مع جملة التطبيق العملي، والشكل (8-5) هو مخطط الصفوف Class diagram يظهر الصفوف المستخدمة والتي تم بناؤها، وفيما يلي سرد سريع للصفوف ووظائفها:

- **Classifier**: يمثل المصنف بكل مكوناته وكذلك البارامترات المحدد للمصنف.
- **ClassifierList**: يتم من خلال هذا الصف بناء مجموعة من المصنفات، تستخدم لتمثيل المجموعات المختلفة الممكن بناؤها خلال عمل الخوارزمية كمجموعة التتابع أو مجموعة الإجراءات او المجموعة العامة.
- **Condition**: يمثل جزء الشرط ضمن المصنف.
- **Effect**: يمثل جزء النتيجة ضمن المصنف.
- **Mark**: يمثل جزء العلام ضمن المصنف.
- **Att**: من خلال هذا الصف يتم تشكيل الخاصيات المختلفة ضمن أجزاء الشرط والنتيجة.

-
- **Population:** يمثل هذا الصف نظام المصنفات الاستباقية بشكل عام، ويحتوي على المجموعات المختلفة للمصنفات ويحتوي على بارامترات النظام.
 - **Perception:** يستخدم لتحديد التعامل مع الوسط المحيط أو بكلام آخر يمثل مداخل النظام.
 - **Trial:** يمثل الغرض من هذا الصف دورة التشغيل الواحدة للنظام.
 - **Syst:** يمثل هذا الصف الجملة المطلوب التحكم بها، وهو يحتوي على تابع تحويل الجملة.




الشكل (5-8): مخطط الصفوف للخوارزمية

8-6- التطبيق العملي:

قمنا في هذا البحث بإجراء عدة تجارب تهدف إلى بيان وإثبات فعالية عدة نقاط ومكونات في الخوارزمية الجديدة والتعامل مع نوع المسائل المطروحة الجديدة (المسائل ذات المداخل المستمرة) وكذلك إثبات الفعالية في معالجة مشكلة أزمنة التأخير الميتة في جمل التحكم، وتم تنفيذ التجارب التالية:


1- تجربة (1): عمل الخوارزمية بدون تفعيل مراقب ومخطط الإجراءات وباعتبار إجراءات متقطعة لها القيم (0.25/0.5/0.75/1/1.25/1.5).



الشكل (8-6): استجابة خرج جملة التحكم في التجربة (1) بعد 500 دورة تدريب

بعد عدد من دورات التدريب والتشغيل لمجموعة المصنفات العامة (500 دورة) حصلنا على استجابة بدايتها جيدة ولكن تعاني من اهتزاز كبير يؤدي إلى عدم استقرار في خرج الجملة، وهذا سببه وجود إجراءات منفذة في أزمنة متقدمة من الاستجابة غير مناسبة أبداً وضارة لسلوك استجابة الخرج، على سبيل المثال: اختيار إجراء (0.25) بعد صعود الاستجابة وبلوغ مجال القيم المرغوبة (1).

يبين الشكل (6-8) استجابة الجملة في الحالة المذكورة، وعند زيادة عدد دورات التدريب نحصل على تحسن في الاستجابة والأداء، الشكل (7-8) يظهر نفس الحالة ولكن بعد زيادة عدد دورات التدريب (1000 دورة)، حيث نلاحظ (اهتزاز أقل / خطأ تحكم أقل).




الشكل (7-8): استجابة خرج جملة التحكم في التجربة (1) بعد 1000 دورة تدريب

2- تجربة (2): عمل الخوارزمية بدون تفعيل مراقب ومخطط الإجراءات وباعتبار إجراءات متقطعة لها القيم (1.5/1).

بناءً على طبيعة المسألة المطروحة وهي الأنظمة ذات أزمنة التأخير الميت يمكن استخدام قيمتين فقط للإجراءات (1.5/1)، حيث قيمة (1) تمثل الثبات عند القيمة المرغوبة أو أمر الدخل والقيمة (1.5) تهدف إلى تحقيق استجابة أسرع للنظام عندما نضع على الدخل قيم أكبر من القيم المطلوبة، أو يمكن القول إنه عند وجود قيم موجبة كبيرة لخطأ التحكم يجب تفعيل أوامر أو قيم تكون أكبر ما يمكن للصعود بالاستجابة إلى القيمة المرغوبة.

يبين الشكل (8-8) استجابة الجملة في هذه الحالة وذلك بعد عدد دورات تدريبية لمجموعة المصنفات 500 دورة




الشكل (8-8): استجابة خرج جملة التحكم في التجربة (2) بعد 500 دورة تدريب

نلاحظ تحسن في الاستجابة من حيث شكل الاهتزاز ولكن أصبح لدينا قيمة أكبر للخطأ وكذلك تأخير زمني أكبر.

3- تجربة (3): عمل الخوارزمية مع تفعيل مخطط الإجراءات وبدون استخدام نموذج النظام.


عند اختيار أي إجراء في أي دورة زمنية يقوم مخطط الإجراءات بالتحقق من جدوى تنفيذ الإجراء وفق المرحلة التي يتواجد بها النظام، حيث يقوم بتقسيم استجابة الجملة إلى قسمين، الأول هو قبل بداية صعود الاستجابة (أي أثناء الزمن الميت) والثاني بعد بداية الاستجابة بالصعود، أو بكلام آخر يقوم بتحديد العتبة الزمنية التي تبدأ عندها الجملة بالاستجابة.

يبين الشكل (8-9) استجابة الجملة في التجربة رقم (3) ويظهر لنا واضحاً فائدة كبيرة من آلية تخطيط الإجراءات، حيث أصبح لدينا خطأ تحكم صفر وزمن تأخير أصغر ما يمكن، ولكن ظهرت لدينا مشكلة جديدة وهي التجاوز الذي تعاني منه الاستجابة بعد الصعود.



الشكل (8-9): استجابة خرج جملة التحكم في التجربة (3) بعد 500 دورة تدريب

4- تجربة (4): عمل الخوارزمية مع تفعيل مخطط الإجراءات ومع استخدام نموذج للجملة.



الشكل (8-10): استجابة خرج جملة التحكم في التجربة (4) بعد 500 دورة تدريب


يقوم مخطط الإجراءات بالاستخدام المسبق لنموذج للجملة من أجل تحديد العتبة الزمنية المذكورة في التجربة (3)، وعلى أساس التحديد المسبق لها يصبح من الممكن المعرفة المسبقة عن فعالية ونتيجة تنفيذ كل إجراء في أي لحظة زمنية.

يظهر الشكل (8-10) استجابة خرج الجملة في هذه الحالة ونلاحظ أداء جيد، خطأ وزمن تأخير أصغر ما يمكن وكذلك لا وجود لمشكلة التجاوز.

8-6- المقارنة مع المتحكم التناسبي التفاضلي التكاملي PID:

تم استخدام بيئة الماتلاب للحصول على متحكم PID مناسب للجملة المستخدمة، حيث تم استخدام التابع pidtune للحصول على متحكم PID وكانت النتيجة هي:


$$K_p = 0.375 , K_i = 0.0367 , K_d = 0$$



الشكل (8-10): استجابة خرج جملة التحكم باستخدام متحكم PID

وبإجراء عملية ضبط أو معايرة إضافية لمتحكم PID تم الحصول على الاستجابة التالية:

$$K_p = 0.41 , K_i = 0.099 , K_d = 0.38$$



الشكل (8-11): استجابة خرج الجملة باستخدام متحكم PID بعد المعايرة الإضافي

بالمقارنة بين استجابة خرج الجملة باستخدام متحكم PID وخرج الجملة باستخدام المتحكم المبني على الخوارزمية المقترحة الأشكال (8-10) و (8-11)، نجد أن المتحكم المبني على خوارزمية نظم المصنفات الاستباقية يتميز عن متحكم PID بالنقاط التالية:

- 1- استجابة أسرع وزمن تأخير أصغر.
- 2- لا وجود لمشكلة التجاوز.
- 3- زمن صعود وزمن استقرار أقل.

8-7- نتائج البحث:

- عرض هذا البحث إحدى تقنيات تعلم الآلة Machine Learning وهي نظم المصنفات القابلة للتعلم LCS وعائلاتها الثلاثة، وتناول بالتفصيل نظام ACS2 المنتمي للعائلة الاستباقية وبالاعتماد عليه تم تطوير نظام مصنفات استباقي قادر على التعامل مع الأوساط المستمرة، وتم استخدام النظام الاستباقي الجديد كمتحكم تنبؤي للتعامل مع التطبيقات ذات أزمدة التأخير الميتة.
- إن نظم المصنفات الاستباقية ALCS صالحة للتطبيق ضمن البيئات المستمرة، لذلك فهي قادرة على التعامل مع مسائل العالم الحقيقي والمعقدة، وكذلك تمتلك الخصائص المطلوبة لتعتبر تقنية للتحكم المبني على النموذج التنبؤي MPC.
- اثبت المتحكم المبني على نظام المصنفات الاستباقي أداء جيد في التحكم بالنظم ذات أزمدة التأخير الميتة، وتم مقارنته مع المتحكم التناسبي التكاملي التفاضلي PID، وأظهر أداء أفضل من حيث سرعة الاستجابة وأزمدة التأخير الأقل.

8-8- الآفاق المستقبلية:

- استخدام نظم المصنفات في مجالات تطبيقية جديدة وخاصة في مجال التحكم والأوساط ذات المداخل المستمرة.
- تطوير آليات وتقنيات للتخطيط وقيادة العمليات مما يعطي مرونة أكثر بالتعامل مع معضلات جديدة ومختلفة.
- التحديث على الخوارزمية المقترحة لتكون قابلة للعمل أثناء التشغيل المستمر والتعامل مع أثر الضجيج.
- استخدام نظم المصنفات الاستباقية ALCS في مسائل التصنيف Classification أو Clustering ذات المداخل والقيم المستمرة.
- تطبيق خوارزميات البحث الخلفي والبحث الأمامي لتصميم استراتيجيات تحكم مسبقاً.

-
- دراسة إمكانية دمج أنظمة المصنفات LCS مع تقنيات الذكاء الصناعي الأخرى مثل الشبكات العصبونية والأنظمة المناعية بهدف تحسين أداء الأنظمة.

المراجع

المراجع:

- [1] S. Wilson. Learning Classifier Systems: survey, 2005.
- [2] D. Wyatt. Applying the XCS Learning Classifier System to Continuous-Valued Data-mining Problems, 2004.
- [3] MIT press. Introduction to Machine Learning, 2010.
- [4] M. Butz, D. Goldberg. generalized state values in an anticipatory learning classifier system, 2002.
- [5] Learning Classifier Systems From Foundations to Applications book – W.Stolzmann. An Introduction to Anticipatory Classifier Systems, 2001.
- [6] P.L. Lanzi. Learning classifier systems from a reinforcement learning perspective, 2002.
- [7] L.Bull. Learning Classifier Systems A Brief Introduction, 2002.
- [8] W.Wilson, M.Butz. An Algorithmic Description Of XCS, 2001.
- [9] W.Stolzmann , M.Butz. An Algorithmic Description of ACS2, 2002.
- [10] YUAN-PAO HSU & WEI-CHENG JIANG. A Fast Learning Agent Based on the Dyna Architecture. 2013.


-
- [11] Learning Classifier Systems From Foundations to Applications book – W.Stolzmann , M.Butz. Latent Learning and Action Planning in Robots with Anticipatory Classifier Systems, 2001.
- [12] J.Bacardit, E.o–Mansilla, and M. Butz. Learning Classifier Systems Looking Back and Glimpsing Ahead, 2008.
- [13] Stewart W. Wilson. Get real! XCS with continuous–valued inputs, 1999.
- [14] C.Stone, and L.Bull, For real! XCS with continuous–valued inputs,2003.
- [15] M.Butz, An implementation of anticipatory learning classifier systems in C++,2002.
- [16] T.Mulliam, Pattern Recognition using Artificial Immune System, 2009.
- [17] C.Stone, L.Bull, Comparing Learning Classifier Systems for Continuous–Valued Online Environments, 2003.
- [18] J.E. Normey–Rico, E.F. Camacho, Control of Dead–time Processes, 2007.
- [19] S.Abo Fakher, Developing a method to process the effects of time delay in fuzzy control systems, 2016.
- [20] Ryan J. Urbanowicz and Jason H.Moore, Learning Classifier Systems: A Complete Introduction, Review, and Roadmap, 2009.
-

-
- [21] M.R.Karlsen, S.Moschoyiannis, Evolution of control with learning classifier systems, 2018.
- [22] D.V.Vargas, H.Takano, Self organizing classifiers and niched fitness, 2013.
- [23] P.Gerard, J-A.Meyer, O.Sigaud , Combining Latent Learning with Dynamic Programming in the Modular Anticipatory Classifier System, 2003.
- [24] K.Tamee, L.Bull,O.Pinngern, Towards Clustering with XCS, 2007.
- [25] T.Kovacs, L.Bull, Toward a Better Understanding of Rule Initialization and Deletion, 2007.


ملحق (A): المخططات الصندوقية


A. المخططات الصندوقية للخوارزمية:

1- حلقة التشغيل العامة:




-2 حلقة التنفيذ العامة:







3- التطابق:




4- تشكيل مجموعة التطابق:




5- اختيار الإجراء:




-6 تشكيل مجموعة الاجراء:




-7 تحديث معدل التطبيق:




-8 عملية التعليم الاستباقي ALP:




9- اختبار التوقع الصحيح:




10- معالجة الحالة المتوقعة:



12- معالجة الحالة غير المتوقعة:




13- التغطية:







15- التعميم باستخدام الخوارزمية الجينية:




16- اختيار مصنفات النسل الجديد:




17- التعميم باستخدام معامل الطفرة




18- تطبيق معامل العبور




19- حذف المصنفات



20- إضافة المصنف الناتج من الخوارزمية الجينية



21- التحقق من مكافأة المصنفات:



Abstract

The aim of this research is study Learning Classifier Systems LCS, which is one of Artificial Intelligence AI techniques, this research introduces overview about Learning Classifier Systems and their types, also about several related techniques like Genetic Algorithm GA and Reinforcement Learning RL, then it focuses on ACS2 algorithm which belongs to Anticipatory Learning Classifier Systems ALCS family, also this research deals with XCSR algorithm, which is accuracy based classifier system XCS and previously used in continuous environments.

By using both algorithms ACS2 and XCSR and doing some modifications, a new algorithm is obtained capable to deal with continuous-input problems and applications, and then a comparison between anticipatory learning classifier systems and Model-Predictive Control MPC technique is made to approve that anticipatory classifier systems is able to solve one of biggest problems in control systems, which is control with dead-time process.

The performance of new algorithm is tested in practical application and compared with Proportional Integral Derivative PID controller performance in same application, and from testing process we find the new algorithm is active and more precise in control field.

Syrian Republic

Damascus University

Mechanical & Electrical Engineering Faculty

Computer & Automation Engineering Department



Improve Anticipatory Learning Classifier Systems

A Dissertation Submitted for the Master Degree in Control and
Automation Engineering

By

Eng. Ahmad Alkassas

Supervised by

Dr. Akram Mazkor

2019