

الجمهورية العربية السورية  
المعهد العالي للعلوم التطبيقية والتكنولوجيا  
قسم المعلوماتية - المعطيات الكبيرة

## مراقبة بارامترات الطيران لطائرة خفيفة

أعدت هذه الأطروحة لنيل درجة الماجستير في هندسة المعلومات من  
المعهد العالي للعلوم التطبيقية والتكنولوجيا


م. إيمان عبيد

بإشراف

د. أيهم الشبل

د. ياسر رحال

Syrian Arab Republic  
Higher Institute of Applied Sciences and Technology  
Informatics Department – Big Data



# Monitoring Light Aircraft Parameters

Study prepared for a master's degree in Informatics Engineering from  
Higher Institute of Applied Sciences and Technology

**Eng. Iman Ayman Obeid**

**Supervisors**

**Dr. Yasser Rahhal**

**Dr. Aiham Al-Shebel**

**Damascus, 2020- 2021**

# المعهد العالي للعلوم التطبيقية والتكنولوجيا

## Higher Institute for Applied Sciences and Technology

المعهد العالي للعلوم التطبيقية والتكنولوجيا مؤسسة حكومية للتعليم العالي أحدثت بموجب المرسوم التشريعي رقم /24/ لعام 1983، وذلك بهدف إعداد كوادر علمية متميزة من مهندسين وباحثين للإسهام الفاعل في عملية التطوير العلمي والتنمية في الجمهورية العربية السورية.

يمنح المعهد العالي درجة الإجازة في الهندسة في الاتصالات والمعلوماتية والنظم الإلكترونية والميكاترونيكس وعلوم وهندسة المواد وهندسة الطيران. يقبل المعهد العالي لدراسة هذه الاختصاصات شريحة منتقاة من المتفوقين في الشهادة الثانوية من الفرع العلمي. يتيح المعهد العالي أيضاً برامج ماجستير أكاديمي في نظم الاتصالات وفي التحكم والروبوتيك وفي نظم المعطيات الكبيرة ونظم المعلومات ودعم القرار وفي علوم وهندسة المواد وعلوم وهندسة البصريات. وأخيراً، يمنح المعهد العالي درجة الدكتوراه في الاتصالات والمعلوماتية ونظم التحكم والفيزياء التطبيقية. تُحدث في المعهد العالي اختصاصات جديدة بحسب متطلبات سوق العمل وتوجهات البحث والتطوير المحلية والعالمية.

إلى جانب النشاط التعليمي، يمارس المعهد العالي عبر جهود أطره وفعالياته العلمية المختلفة نشاطاً حثيثاً في البحث والتطوير، إذ ينفذ مشاريع ودراسات واستشارات متنوعة لصالح الجهات العامة والخاصة في القطر، كما يتعاون مع جهات خارج القطر في بعض المشاريع البحثية والتطويرية. يسعى المعهد أيضاً، عبر دورات تدريبية نظرية وعملية متاحة للقطاعات العام والخاص وللأفراد، إلى إفادة أوسع فئة من المهتمين من إمكانيات أطره العلمية ومختبراته. واستكمالاً لدوره الرائد في مجال التعليم ونشر العلم، ينشر المعهد العالي كتباً علمية عالية المستوى من نتاج أطره، منها ما هو تدريسي يوافق المناهج في المعهد العالي ويفيد شريحة واسعة من الطلاب الجامعيين عموماً، ومنها ما هو علمي ثقافي. يتيح المعهد العالي بعضاً من منشوراته على موقعه على الشبكة، كما يتيح إمكانية الاطلاع على رسائل الماجستير والدكتوراه المنفذة في المعهد العالي وعلى بعض منشورات طلابه وأطره من المقالات العلمية.

المعهد العالي للعلوم التطبيقية والتكنولوجيا، الجمهورية العربية السورية، دمشق، ص.ب 31983

Higher Institute for Applied Sciences and Technology – HIAST

P. O. Box 31983, Damascus, Syrian Arab Republic

هاتف 00963115123819 - فاكس 00963115140761

بريد إلكتروني [contact@hiast.edu.sy](mailto:contact@hiast.edu.sy)

موقع إلكتروني [www.hiast.edu.sy](http://www.hiast.edu.sy)

## كلمة شكر وتقدير

أقدم بالشكر الكبير إلى المشرفين الفاضلين د. ياسر مرحال ود. أيهم الشبل على توجيهاتهما ونصائحهما، وما

قدماه لي من دعم وعلم وصبر لإنجاز هذا العمل.

كما أتوجه بالشكر لكافة أعضاء الكادر الأكاديمي والفني وكافة مدرسي مقررات ماجستير نظم

المعطيات الكبيرة على جهودهم المبذولة خلال فترة الدراسة.

والحمد لله وليّ التوفيق

# الإهداء

إلى أمي وأبي، ولا يكافئ تعبكما معي شيء

إلى جدتي العزيزة، وجددي الكريمة وخالتي علياء اللحنان والدعوات الخالصة

إلى عمي محمد حسام لكل ما نرعت طيباً وأثمر في شخصي

إلى إخوتي وأخواتي وعائلتي للتشجيع الذي قدمتم

للحب المرصع بالانهاية ❁

## ملخص

يعرض هذا التقرير نموذجاً لمراقبة البارامترات المتغيرة مع الزمن واكتشاف حدوث خلل فيها في طائرة خفيفة، بالإضافة لاكتشاف تأثير تلك البارامترات على بعضها للمساعدة في تحديد أسباب الخلل مستقبلاً، وهو هدف العديد من الباحثين في الآونة الأخيرة. قمنا في هذا البحث بتصميم نموذج أولي لمراقبة بارامترات الطيران لطائرة خفيفة باستخدام عدة نماذج تعلم هي LSTM, NARXNET, VARM وكان أفضلها أداءً شبكة التعلم العميق LSTM Long Short Term Memory بالإضافة إلى استنتاج العلاقات السببية بين تلك البارامترات من خلال تطبيق عامل التنظيم LASSO: Least Absolute Shrinkage and Selection Operator.

قمنا أولاً بالتعرف على نموذج الحركة الطولية لطائرة خفيفة بنمطها قصيرة وطويلة الدور واختيار البارامترات التي اعتمدت في البحث، ويهدف التخلص من البيانات الزائدة الناتجة عن توحيد عدد العينات للبارامترات قمنا بفصل بارامترات الحركة قصيرة الدور عن الطويلة وبذلك استطعنا التخلص من الحجم الزائد الناتج من توحيد تردد أخذ العينات للبارامترات تقريباً 10 مرات بالحركة طويلة الدور. تم بعدها تدريب شبكتي تعلم عميق لكشف حدوث شذوذات بأي من بارامترات الخرج عن طريق حساب الخطأ بين قيم الخرج المتوقعة والفعلية وأعطت نتيجة التنبؤ خطأ نسبياً لا يتجاوز 3% لمدة 3 ثواني من قيمة البارامترات وهي مدة مناسبة للإنداز بحيث يتمكن الطيار من اتخاذ إجراءات تلافي الخلل وتم التدريب على التفرع لاختصار زمن التدريب.

استخدمنا منهجية LASSO لكشف الترابطات السببية خلال الزمن بين البارامترات على مصفوفة أوزان الخرج في شبكة التعلم بهدف إيجاد بارامترات الدخل التي تؤثر على بارامترات الخرج، وبالتالي نتج لدينا مجموعة من الروابط تمكنا من خلالها رسم بيان موجه لترابطات البارامترات بين بعضها، بهدف دراسة سلوك البارامترات في الحالة الطبيعية للنظام وفي حالات الأعطال المختلفة.

تمت تجربة النموذج على ثلاث مجموعات من البيانات، الأولى مجموعة سجلناها من نموذج للحركة الطولية لطائرة خفيفة ضمن بيئة ماتلاب، والثانية لمجموعة بيانات طيران سجلناها من برنامج مقلد الطيران X-Plane، والثالثة مجموعة بيانات MKAD الصناعية وهي مجموعة بيانات اختبار مجانية وتتكون من إشارات خطوة ونبضات بعضها مع ضجيج.

**الكلمات المفتاحية:** المعطيات الكبيرة، شبكات التعلم العميق، السببية، بيان موجه

## Abstract

This report presents a model for parameters monitoring, and detecting anomalies in multivariate time series data. Then discovering the temporal cause-effect relationship among data, to help determine the causes of defects dynamically, which is a major goal of many researchers recently. In this research, we managed to monitor the flight parameters of a light aircraft using different training models: NARXNET, VARM, and LSTM Deep Neural Network which showed the best results. In addition to that we were able to build a causality network by applying “Least Absolute Shrinkage and Selection Operator” methodology.

First the longitudinal motion of a light aircraft model was identified with both short and long Periods. Then the parameters to be adopted in the research were selected. In order to improve the performance, we separated the short period from the long period parameters, thus eliminating the excess volume resulting from the up-sampling rate consolidation, 10 times less in Long Period. Two deep learning networks were then trained, each by one type of the separated parameters, that is to detect the predicted output anomalies. Prediction errors shown a within exceed 3% relatively, for a period of 3 seconds of the parameter’s values, which is an appropriate period for warning the pilot in order for him to take a suitable action to avoid malfunctions. The training process was done in parallel to reduce training time.

As for the causal inference over time between the parameters, we used the LASSO methodology on the network’s output weights finding the smallest number of parameters that have effect on the output parameters, producing as a result a set of connection through which we were able build a causal directed graph, in order to study the behavior of Parameters in the normal state of the system and other cases of various malfunctions.

The model was tested on three data sets, the first is a set generated from a Simulink MATLAB Longitudinal Motion model for a Light Aircraft, the second is a data set generated from the X-Plane flight simulator, and the third is the popular free synthetic MKAD that consists of a collection of noisy step and pulse signals.

***Keywords:*** *Big data, Deep Neural Network, Causality, Inferring Network, Directed Graph.*

## فهرس المحتويات

I	ملخص	.....
II	ABSTRACT	.....
III	فهرس المحتويات	.....
VI	قائمة الأشكال	.....
VII	قائمة الجداول	.....
VIII	الاختصارات والمصطلحات	.....
1	مقدمة	.....
2	إشكالية البحث	.....
3	هدف البحث	.....
3	إسهامات البحث	.....
5	<u>الفصل الأول - الدراسة النظرية والأدبيات ذات الصلة</u>	.....
5	1-1- تمهيد	.....
6	2-1- نموذج الحركة الطولية لطائرة خفيفة	.....
9	1-2-1- الحركة الطولية قصيرة الدور	.....
12	2-2-1- النموذج العام للحركة الطولية	.....
14	3-1- تحصيل بارامترات الطيران..	.....
14	4-1- المعطيات الكبيرة في تحليل معطيات الطيران	.....
16	5-1- السلاسل الزمنية	.....
16	1-5-1- مكونات السلسلة الزمنية	.....
18	2-5-1- العوامل المؤثرة في السلسلة الزمنية لبارامترات الطيران	.....
18	3-5-1- قياس التشابه بين سلسلتين زمنيتين	.....
19	6-1- الشبكات العصبونية..	.....
21	1-6-1- الشبكات العصبونية العودية RNN	.....
25	2-6-1- قياس أخطاء التنبؤ	.....
26	7-1- الكشف عن ارتباطات السببية بين البارامترات	.....
27	1-7-1- كشف العلاقات السببية باستخدام شعاع الانحدار الذاتي VAR	.....
28	2-7-1- كشف العلاقات السببية لسلاسل زمنية متعددة البارامترات باستخدام MVAR	.....
28	3-7-1- استنتاج السببية من مصفوفة أوزان الشبكة العصبونية العودية	.....

30	4-7-1 عامل التنظيم LASSO و عامل التنظيم RIDGE .....
31	5-7-1 تمثيل بيان العلاقات السببية اعتماداً على مصفوفة أوزان الشبكة المعدلة .....
32	<u>الفصل الثاني- الدراسة المرجعية</u> .....
32	1-2- تمهيد .....
32	2-2- كشف مواطن الخلل في معطيات محرك الطائرة .....
33	3-2- نمذجة سلاسل الطيران، مقارنة بين VAR و LSTM .....
36	4-2- الطرائق الحديثة في كشف الشذوذات في تطبيقات مجال الطيران .....
38	5-2- تحليل السببية في السلاسل الزمنية غير الخطية باستخدام الشبكات العصبونية .....
40	6-2- منصة المعطيات الكبيرة للطيران المدني .....
41	<u>الفصل الثالث - النموذج المقترح لنظام مراقبة بارامترات طائرة خفيفة</u> .....
41	1-3- تمهيد .....
41	2-3- طبيعة السلسلة الزمنية للمسألة المطروحة .....
42	3-3- النموذج المقترح لمسألة البحث .....
42	1-3-3- المعالجة الأولية لبارامترات الدخل .....
48	2-3-3- التنبؤ لعدة خطوات زمنية .....
50	3-3-3- بيان العلاقات السببية بين البارامترات .....
50	<u>الفصل الرابع - اختبار النموذج ونتائج البحث</u> .....
52	1-4- تمهيد .....
53	2-4- إعدادات العمل ضمن بيئة ماتلاب .....
53	1-2-4- تدفق المعطيات من نموذج الحركة الطولية في ماتلاب .....
55	2-2-4- استقبال المعطيات من برنامج X-PLANE 10 .....
55	3-2-4- تخفيف الحمل .....
56	3-4- نتائج العمل .....
56	1-3-4- نتائج التدريب والاختبار على مجموعة MKAD .....
60	2-3-4- نتائج مجموعة ماتلاب .....
69	3-3-4- مجموعة بيانات X-PLANE .....
72	4-3-4- استنتاج علاقات السببية من مصفوفة أوزان شبكة التعلم .....
75	4-4- التوصيات .....
75	5-4- الآفاق المستقبلية .....

76.....	6-4- الخاتمة.....
ERROR! BOOKMARK NOT DEFINED.....	المراجع.....
80.....	ملحق بارامترات الطائرة.....

## قائمة الأشكال

- 6..... الشكل 1- أجزاء الطائرة الرئيسية ودفات التحكم والقلابات
- 8..... الشكل 2 – منحني استجابة زاوية الغوص لانحراف مفاجئ مقداره 1 درجة لدفة العمق
- 9..... الشكل 3- البارامترات الأساسية للحركة حول مركز الثقل
- 12..... الشكل 4- المخطط العام لنموذج الحركة الطولية لطائرة خفيفة
- 13..... الشكل 5 - كتلة حساب القوى والعزوم الأيروديناميكية
- 13..... الشكل 6 - كتلة معادلات حركة الطائرة
- 17..... الشكل 7 – مكونات السلسلة الزمنية [6]
- 19..... الشكل 8- محاذاة سلسلتين زمنيتين ثم قياس المسافة بينهما
- 20..... الشكل 9 – مكونات الشبكة العصبونية
- 20..... الشكل 10 – بعض توابع التفعيل المشهورة
- 22..... الشكل 11- شبكة عصبونية عودية بعد بسطها 3 خطوات من الزمن. مصدر الصورة [10]
- 22..... الشكل 12- بنية الشبكة العودية كاملة الارتباط [11]
- 23..... الشكل 13- مشكلة الانحدار المتناقص عند تطبيق تابع تفعيل Sigmoid عدة مرات
- 24..... الشكل 14- بنية تفصيلية لشبكة LSTM تظهر تفاعل طبقاتها مع بعضهم البعض
- 25..... الشكل 15 – بنية شبكة NARXNET. في اليمين شبكة ذات حلقة مغلقة، واليسار تمثل شبكة ذات حلقة مفتوحة
- 33..... الشكل 16- جزء من اختبارات خوارزمية DBSCAN في الكشف عن الشذوذات بين مجموعة من الرحلات
- 34..... الشكل 17- نمو الخطأ مع الزمن في كل من النماذج
- 35..... الشكل 18- قياس RMSE لكل خطوة مستقبلية في كل من النماذج الثلاث
- 35..... الشكل 19- جزء من الاختبارات لكل من نمودي LSTM, VAR
- 37..... الشكل 20- الطرق العامة الكلاسيكية في الكشف عن الشذوذات
- 38..... الشكل 21 – طرق كشف الشذوذات المستخدمة في تطبيقات الطيران المختلفة
- 39..... الشكل 22- مخطط توضيحي لبنية شبكة MLP للكشف عن السببية من خلال أوزان الطبقة المخفية الأولى لكل دخل
- 39..... الشكل 23 – جزء من اختبارات خوارزمية كشف اللاسببية بين البارامترات من أجل عوامل تنظيم  $\lambda$  مختلفة
- 40..... الشكل 24 – منصة نظام متكامل لتقديم خدمات في مجال الطيران ضمن بيئة معطيات كبيرة
- 42..... الشكل 25 - تمثيل لحركة البيانات في نموذج مقلد طيران يمثل خرجه دخلاً للنموذج المقترح
- 44..... الشكل 26- تأثير أمر التحكم بالمحرك على 14 بارامتر خرج من أصل 26 باستخدام LASSO
- 45..... الشكل 27 - المخطط الصندوقي للنموذج المقترح
- 47..... الشكل 28- إلغاء أثر الضجيج في مجموعة بيانات MKAD
- 48..... الشكل 29- التنبؤ بقيم الارتفاع بدون إلغاء أثر الاتجاه العام
- 53..... الشكل 30-النموذج المقترح في ماتلاب للكشف عن الشذوذات أثناء حركة المعطيات
- 58..... الشكل 31- نتائج التنبؤ على بعض بارامترات مجموعة MKAD
- 59..... الشكل 32- اختبار كشف شذوذ من النمط الأول في مجموعة MKAD
- 59..... الشكل 33- بيانات من مجموعة MKAD لملفين لحالة سليمة 201، 202
- 60..... الشكل 34- بيانات السببية من مجموعة MKAD لملفين من العطل III 238، 325
- 61..... الشكل 35- بارامتر معدل الغوص Q قبل وبعد إلغاء عدم الاستقرار
- 61..... الشكل 36- نتيجة التنبؤ لمدة 20 خطوة زمنية للأمام باستخدام نموذج VARM
- 62..... الشكل 37- نتائج تنبؤ 20 ثانية للأمام لمجموعة تدريب نمطية باستخدام شبكة LSTM
- 63..... الشكل 38 - نتائج تنبؤ 20 ثانية للأمام لمجموعة تدريب حقيقية باستخدام شبكة LSTM
- 64..... الشكل 39 – التنبؤ باستخدام NARXNET لبيانات نمطية

- الشكل 40- منحني خطأ التنبؤ لكل من LSTM, NARXNET, VARM لزاوية الغوص.....64
- الشكل 41 – نتائج تدريب شبكتي LSTM على التفرع للحركة الطولية بدورها السريعة والبطيئة.....65
- الشكل 42 - تنبؤ ثانية لأحد بارامترات الحركة السريعة الشكل43 – تنبؤ لأحد بارامترات الحركة البطيئة.....66
- الشكل 44 - كشف الشذوذ في بيانات مع عطل منطقة ميتة باستخدام LSTM.....67
- الشكل 45- الكشف عن شذوذات تعبر عن أعطال في القناة الطولية لعصا القيادة.....68
- الشكل 46- نتائج التنبؤ لزاويتي الغوص والدوران للحركة قصيرة الدور في مجموعة X-Plane.....70
- الشكل 47- نتائج التنبؤ للسرعة ودوران المحرك للحركة طويلة الدور في مجموعة X-Plane.....70
- الشكل 48 - مقارنة استجابة المقلد X-Plane مع النموذج في MATLAB على بعض البارامترات.....72
- الشكل 49- بيان العلاقات السببية للحركة الطولية بدون أعطال من مجموعتي اختبار مختلفتين 1،2.....73
- الشكل 50- بيان العلاقات السببية للحركة الطولية يمثل تغير في عزم العطالة الطولي من المجموعتين 1،3.....74
- الشكل 51- بيان العلاقات السببية للحركة الطولية يمثل عطل منطقة ميتة بالقناة الطولية من المجموعتين 8، 10.....74

## قائمة الجداول

- الجدول 1 – يظهر رمز ودلالة كل من بارامترات الحركة الطولية في الطائرة الخفيفة.....7
- الجدول 2- عيارات شبكة LSTM لكل من مجموعتي البيانات النمطية وبيانات المقلد الحقيقية.....62
- الجدول 3- مقارنة بين تقنيات LSTM, NARXNET, VRAM بمقياس RMSE.....64
- الجدول 4- أخطاء التنبؤ لبعض بارامترات الحركة قصيرة الدور وطويلة الدور لشبكة LSTM.....71

## الاختصارات والمصطلحات

الاختصار	باللغة الإنكليزية	باللغة العربية
	Cinematic	علم الحركة
CVR	Cockpit Voice Recorder	المسجل الصوتي في قمرة القيادة
DTW	Dynamic Time Warping	تحويل الزمن الديناميكي
DBSCAN	Density-based spatial clustering of applications with noise	العنقدة المعتمدة على الكثافة مع الضجيج
EFIS	Electronic Flight Instrument System	نظام العدادات الإلكتروني
	Feature Selection	انتقاء السمات
FDR	Flight Data Recorder	مسجل معطيات الرحلة
GF	Gaussian filter	مرشح غوسي
IAAS	Infrastructure as a service	البنية التحتية كخدمة
ICAO	International Civil Aviation Organization	منظمة الطيران المدني الدولي
	Inverse covariance	مقلوب مصفوفة التغاير
L1	Lasso Regularization Parameter L1	عامل التنظيم لاسو
L2	Ridge Regularization Parameter L2	عامل التنظيم ريدج
	Long Period Mode	الحركة الذاتية طويلة الدور
LSTM	Long Short-Term Memory	شبكة الذاكرة طويلة وقصيرة الأمد
MAD	Mean Absolute Deviation	متوسط الانحرافات المطلق
MAPE	Mean Absolute Percentage Error	متوسط الأخطاء النسبية المطلقة
MLP	Multi-Layer Perceptron	مستقبلات متعددة الطبقات
MSE	MSE Mean Squared Error	متوسط مربعات الأخطاء
MVAR	Multi-Variate Auto-Regressive	أشعة الانحدار الذاتي متعددة البارامترات
Mvnpdf	Multivariate normal probability density function	الكثافة الاحتمالية لعدة بارامترات
NARXNET	Nonlinear autoregressive exogenous net.	شبكة الانحدار الذاتي غير الخطية
PAAS	Platform as a service	النظام الأساسي كخدمة
	Precision matrix	مصفوفة الدقة
RMSE	Root Mean Squared Error	جذر متوسط مربعات الأخطاء

RNN	Recurrent Neural Network	الشبكات العصبونية العودية
SAAS	Software as a service	البرمجيات كخدمة
SE	Sum of Errors	مجموع الأخطاء
	Short Period Mode	الحركة الذاتية قصيرة الدور
	Stationary Time Series	سلسلة زمنية مستقر
UDP	User Datagram Protocol	بروتوكول بيانات المستخدم
VAR	Vector Auto-Regressive	شعاع الانحدار الذاتي

## مقدمة

نتعامل في أنظمة تحليل البيانات بمعظم التطبيقات مع سلاسل زمنية متعددة البارامترات غير متجانسة من حيث النمط والتردد وغيرها من العوامل التي تجعل مسألة تحليلها تحدياً صعباً. ولتحليل البيانات عدة أهداف أهمها تنبؤ كيفية تغير تلك السلاسل مع الزمن كما في تطبيقات العملات والأرصاء الجوية، واكتشاف الأحداث في تطبيقات الاتصالات ووسائل التواصل الاجتماعي، أو كشف حدوث خلل ما (شذوذ) قد يكون مؤشراً لحدوث عطل ما كما في مسألة تحليل بارامترات الطيران موضوع البحث، وتحفظ عادة بيانات الرحلات الطيران رقمياً في مسجل بيانات الطيران (FDR Flight Data Recorder)، وتشكل سلاسل زمنية متعددة المتغيرات (Multivariable Time Series) وفق ترددات مختلفة وأنماط متعددة. تحوي تسجيلات FDR معلومات عن حالة الطائرة وأنظمتها وظروف الرحلة منذ لحظة تشغيل المحرك وحتى الهبوط وإطفاء المحرك، كبارامترات الرحلة (السرعة، الارتفاع...) وبارامترات عمل المحرك (عدد دورات المحرك في الدقيقة، ضغط وحرارة الزيت...) وأوامر التحكم والقيادة (انحراف عصا القيادة، انحراف البدالات...). لمعظم هذه البارامترات حدوداً عليا ودنيا يتم تنبيه الطيار عنها في حال تجاوزها، ولكن في بعض الحالات تكون هذه البارامترات ضمن حدودها المقبولة ولكن ارتباطها مع باقي البارامترات يشير إلى خلل قد يكون مؤشراً لعطل ما في المستقبل يساهم الكشف المبكر عن هذا النوع من الخلل رفع سوية أمان الطائرة. ويتضمن الملحق في نهاية التقرير دلالات البارامترات التي خضعت للدراسة في مجموعة X-Plane.

اقتصرت الفائدة من تسجيلات الطائرة قديماً على التحقيق في أسباب الحوادث، ثم عمليات الصيانة، وبظهور مفهوم المعطيات الكبيرة وتقنياتها المتطورة المستخدمة في تحليل المعطيات أصبح من الممكن استثمار هذه المعطيات ومراقبة حالة الطائرة باستمرار أثناء الرحلة بالزمن شبه الحقيقي والكشف عن حدوث خلل ما في أحد أنظمة الطائرة مما يرفع مستوى أمان الطيران، كما يساعد في تحسين أداء عمليات الصيانة، وتوقع العمر الفني للطائرة. وتحتاج البيانات المتولدة من حساسات الطائرة إلى سرعة عالية في المعالجة ناتجة عن التغير السريع لقيم بعض البارامترات التي تحتاج مع الزمن حجوم تخزين عالية لتحليلها لاحقاً.

يعرض الفصل الأول من هذا التقرير الدراسة النظرية وأدبيات البحث، أما الفصل الثاني فيحوي الدراسة المرجعية والأعمال الشبيهة لمسألة البحث من خلال تعريف مختصر بتلك الأعمال والنتائج التي تم التوصل إليها. أما الفصل الثالث فيتضمن صياغة فرضيات مسألة البحث وبناء نموذج الحل وتفصيل مراحلها والأدوات المستخدمة في كل مرحلة. أما في الفصل الرابع نقدم عرضاً مفصلاً لأهم النتائج وتأويلها ومن ثم بعض التطورات والتحسينات المستقبلية على النموذج والخاتمة.

## إشكالية البحث

تتركز الإشكالية المطروحة في هذا البحث حول فكرتين أساسيتين أولاهما تتعلق بإمكانية تخفيض حجم البيانات الكبير في السلسلة الزمنية متعددة البارامترات المتولدة من نموذج مقلد طائرة خفيفة، بالإضافة إلى إمكانية التنبؤ لعدة خطوات زمنية دون تصحيح اعتماداً قيم التنبؤ وذلك بتدريب نموذج تعلم تلقائي جيد. وتكمن **الفكرة الثانية** في إمكانية استنتاج ترابطات البارامترات بين بعضها عبر الزمن بغرض دراسة سلوكها في الحالة الطبيعية أو حالات الأعطال المختلفة والاستفادة منها مستقبلاً في التنبؤ بحدوث عطل بشكل مبكر.

أما من ناحية التطبيق، فيمكن مراقبة بارامترات الطائرة بعدة طرائق منها:

- الاعتماد على القواعد والقيود الخاصة بالطائرة والمبينة في وثائق استثمارها مثل حدود السرعة والارتفاع وإجراءات الإقلاع والهبوط أو الحد الأعلى المسموح لحرارة المحرك وغيرها، تتميز هذه الطريقة ببساطتها وسهولة تطبيقها ولكن لا يمكن من خلال هذه الطريقة سوى تحديد حالات التجاوزات المعروفة مسبقاً كما أن احتمال الحصول على نتائج خاطئة أعلى بسبب عدم وجود قواعد تغطي كافة الحالات. خاصة أنها لا تهتم باعتماد البارامترات على بعضها في المجال الزمني، مثلاً حدود ارتفاع درجة حرارة المحرك المقبولة أثناء الطيران الأفقي المستقيم تختلف عنها أثناء التسلق. من ناحية ثانية فإنه لا يمكن باعتماد هذه الطريقة توقع الأعطال فهي تستخدم لتنبية الطيار على التجاوزات بعد حصول تجاوز للقيم العظمى المسموحة فقط.

- الاعتماد على الطرق الإحصائية من خلال استعلامات محددة تقوم بالاستقصاء عنها، مثلاً عدد المرات التي تجاوز فيها الطيار سرعة معينة ضمن ارتفاع معين، وهذه الطريقة أيضاً تعتمد على البارامترات المسجلة خلال كامل الرحلة ولا يمكن الاستفادة منها بشكل مباشر في توقع الأعطال كما أنها تحتاج عادةً لخبير لتفسير النتائج.

يبدو من الطريقتين السابقتين قصورهما عن استثمار المعطيات إلا بعد انتهاء رحلة الطيران، فكلاهما لا تستطيعان الكشف إلا عن حالات محددة معروفة مسبقاً لدى محلي المعطيات ولا تساعدان في توقع الأعطال وتفتقران إلى إمكانية تعلم حالات جديدة. لذا تركزت الجهود نحو استخدام تقنيات المعطيات الكبيرة وتعلم الآلة مثل التنقيب في المعطيات وتحليل السلاسل الزمنية وغيرها والتي تمكن من معالجة تدفق المعطيات بالسرعة المناسبة والكشف عن الأعطال خاصة الغير معروفة سابقاً.

## هدف البحث

نسعى من خلال هذا البحث إلى تصميم نموذج أولي "لنظام مراقبة الحالة الفنية لطائرة خفيفة"<sup>1</sup> حيث نقوم بتحصيل وتحليل وتخزين بارامترات الطيران بهدف كشف حدوث خلل ما غير بديهي للطيار في سلوك أحد أنظمة الطائرة حيث تكون بارامترات الطيران ضمن حدودها المسموحة ولكن بمراقبة مجموعة البارامترات Combination مع بعضها خلال الزمن نكشف عن وجود خلل ما، ويتم ذلك اعتماداً على قياس الخطأ في التنبؤ عن القيم الحقيقية للبارامترات فإذا كان الخطأ كبيراً نقوم بالتنبيه حول الخطأ، ومن ثم استنتاج العلاقات السببية بين البارامترات عبر الزمن بهدف تعلم سلوك البارامترات خلال الحالة الطبيعية للنظام وتمييزه عن الحالات التي تحوي أعطالاً خاصة أثناء الأعطال غير المعروفة وتحديد أسبابها.

## إسهامات البحث

1- قمنا في هذا البحث بالتعرف على نموذجين للطيران أحدهما محلي التصميم للحركة الطولية لطائرة خفيفة ضمن بيئة برنامج MATLAB-Simulink، والآخر هو نموذج لطائرة خفيفة في برنامج مقلد الطيران الأرضي X-Plane 10. الهدف من ذلك توليد مجموعة معطيات من هذين النموذجين وزرع بعض الأعطال واختبار إحدى طرائق التنبؤ والكشف عن الشذوذات الناتجة عن الأعطال. إن برنامج X-Plane 10 موثوق بدرجة كبيرة ولكن يصعب زرع الأعطال ضمنه أحياناً، لذلك اعتمدنا على نموذج ماتلاب بعد دراسة التشابه بين استجابتي النموذجين لبارامترات الحركة الطولية لزراعة الأعطال ومن ثم الاختبار على نموذج X-PLANE.

2- عادة، يتم تحصيل البارامترات من الطائرة بترددات مختلفة ويقوم محللو البيانات بتوحيد تردد أخذ العينات إلى أعلى تردد لها لحؤول دون خسارة المعلومات من البارامترات ذات التردد السريع ولكن هذا يسبب زيادة غير مفيدة في حجم البيانات التي تحتاج إلى المعالجة. استطعنا من خلال البحث تخفيض الحجم الناتج في مجموعة البيانات المولدة ضمن نموذج ماتلاب، من خلال تحصيل البيانات بترددين مختلفين بحسب تردد الحركة الطولية السريعة والبطيئة، أدى ذلك لإمكانية تخفيض حجم البيانات 10 مرات في السلسلة الزمنية متعددة البارامترات التي تمثل الحركة الذاتية بطيئة الدور بالنسبة لحجم السلسلة الزمنية الممثلة للحركة الذاتية سريعة الدور وبدقة جيدة.

1- الطائرة الخفيفة هي طائرة تتسع لشخصين على الأكثر أحدهما الطيار وزنها لا يتجاوز 600 كغ، كطائرات الهواة وطائرات التدريب.

3- تم في هذا البحث استنتاج العلاقات السببية بين البارامترات المقاسة خلال وحدتي زمن متتاليتين وبناء بيان موجه لها وذلك بتطبيق عامل التنظيم LASSO على مصفوفة أوزان الدخل للشبكات العصبونية المدروسة بين بارامترات الدخل والخرج بغية دراسة سلوك وتأثيرها على بعضها خلال الزمن في كل من الحالة الطبيعية للنظام والحالات التي يتم فيها الكشف عن شذوذات تعبر عن أعطال مختلفة.

# الفصل الأول

## الدراسة النظرية والأدبيات ذات الصلة

### 1-1- تمهيد

يحتوي هذا الفصل دراسةً نظريةً بالإضافة إلى تعريف بأدبيات مسألة البحث وشرح بعض المفاهيم الأساسية الخاصة بالناحية الفيزيائية والفنية المعلوماتية.


يعتمد نظام مراقبة الحالة الفنية لطائرة خفيفة الذي تم بناؤه من خلال هذا المشروع في كشف العطل (أو الخلل) على مراقبة البارامترات الأساسية لحالة الطائرة وتوقع قيم هذه البارامترات خلال اللحظات القادمة ومن ثم مقارنة القيم الحقيقية المقاسة خلال اللحظات التالية مع القيم المتوقعة وكشف انحرافات القيم المتوقعة عن مجالاتها المقبولة. ويتم حل مسألة التوقع بمراقبة بارامترات الطائرة المقاسة على المتن واستخدام إحدى منهجيات التنبؤ. كما تمت خلال المشروع الاستعاضة أثناء عملية التدريب عن الطائرة الحقيقية بنموذج حاسبي لحركة طائرة خفيفة تمت برمجته باستخدام بيئة (MATLAB-Simulink) وذلك لكونه يمكن تحصيل البارامترات من خلاله بأكثر من تردد أخذ عينات بالإضافة إلى إمكانية زراعة أعطال ضمنه.

ويمكن توصيف حركة الطائرة من خلال 6 معادلات تفاضلية عادية<sup>2</sup> لا خطية متغيرة المعاملات، بالإضافة لمجموعة أخرى من المعادلات التي توصف الترابطات السينيماتيكية<sup>3</sup> بين بارامترات الحركة وعمل الأنظمة الجزئية في الطائرة كالمحرك والقلابات شكل (1). ويتم توصيف الحالة الكاملة للطائرة بعدد كبير جداً من البارامترات المتغيرة المتعلقة بمواصفاتها الأيروديناميكية ومنظوماتها الجزئية. لذلك ولتبسيط المسألة وكنسخة أولية من منظومة مراقبة البارامترات تم الاكتفاء بمراقبة الحركة الطولية للطائرة أي حركتها في المستوي الشاقولي المار من مركز ثقلها (دون ميل أو انزلاق جانبي) وذلك لكون مسألة الحركة الطولية (بثلاث درجات حرية) تتشابه فيزيائياً بقية الحركات ويمكن مستقبلاً تعميم المنظومة لتشمل درجات الحرية الست، بالإضافة إلى أن الطائرة تقضي معظم فترة الطيران في المستوي الشاقولي.

<sup>2</sup> - المعادلات التفاضلية العادية هي التي يكون فيها متغير وحيد هو الزمن هنا.

<sup>3</sup> - علاقات تعبر عن ارتباطات البارامترات الحركية للطائرة فيما بينها مثل العلاقة (1) صفحة 8.

نعرض في هذا الفصل النموذج الرياضي للحركة الطولية لطائرة خفيفة والبارامترات التي يتم تحصيلها من خلال وحدات التحصيل في الطائرة مثل بارامترات دفات التحكم<sup>4</sup> كما هو موضح في الشكل (1). ثم نعرض نموذجاً محلي التصميم للحركة الطولية لطائرة خفيفة في بيئة ماتلاب لتوليد مجموعة البيانات المستخدمة في البحث.



الشكل 1- أجزاء الطائرة الرئيسية ودفات التحكم والقلابات

## 2-1- نموذج الحركة الطولية لطائرة خفيفة

يمكن وبعد اعتماد بعض الفرضيات التبسيطية كتابة جملة المعادلات التي تصف الحركة الطولية للطائرة وهي كما ذكرنا جملة معادلات تفاضلية عادية، لا خطية ذات معاملات متغيرة، وذلك يمكننا من معرفة استجابة متغيرات الحركة لأوامر الدخل عبر الزمن [1].

4 - هي دفات العمق والجنيحات والاتجاه.

$$(1) \dots \begin{cases} m \dot{V} = T \cos(\alpha) - D - mg \sin(\gamma) \\ m V \dot{\gamma} = T \sin(\alpha) + L - mg \cos(\gamma) \\ \dot{\alpha} = q - \dot{\gamma} \\ \dot{q} = M_y / I_y \end{cases}$$

ويبين الجدول (1) رموز ودلالات كل من بارامترات الحركة الطولية:

الجدول 1 - يظهر رمز ودلالة كل من بارامترات الحركة الطولية في الطائرة الخفيفة

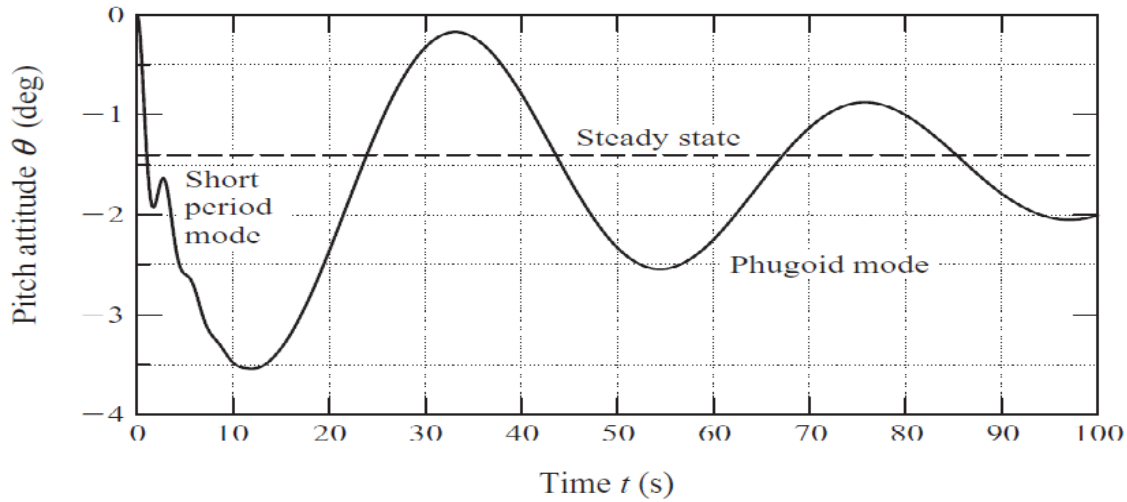
واحدة القياس	الرمز	الدلالة
[kg]	$m$	كتلة الطائرة
[m/s]	$V$	سرعة الطيران
[N]	$T$	قوة الدفع أو قوة جر المروحة
[N]	$D$	قوة الكبح
[m/s <sup>2</sup> ]	$g$	تسارع الجاذبية الأرضية
[rad]	$\gamma$	زاوية ميل المسار بين شعاع السرعة والمستوي الأفقي.
[N]	$L$	قوة الرفع
[rad]	$\alpha$	زاوية الهجوم بين محور الطائرة وشعاع السرعة.
[rad/s]	$q$	معدل الغوص (السرعة الزاوية حول المحور Y)
[m.N]	$M_y$	مجموع العزوم حول المحور العرضي OY
[kg.m <sup>2</sup> ]	$I_y$	عزم عطالة الطائرة حول المحور العرضي OY
[rad]	$\theta$	زاوية الغوص بين محور الطائرة الطولي $ox_1$ والمستوي الأفقي.
[rad]	$\delta$	زاوية انحراف دفعة العمق.

يمكننا ذلك أن ندرس حركة الطائرة أثناء المناورة في المستوى الشاقولي (أي دون ميل أو انزلاق جانبي) كمجموع حركتين [2]:

**1 – الحركة الذاتية طويلة الدور:** حركة مركز ثقل الطائرة في المستوى الشاقولي تحت تأثير قوى الرفع والكبح الأيروديناميكية وقوة دفع المحرك ويكون عادة معدل تغيرات البارامترات الموصفة لها (مثل شدة واتجاه شعاع السرعة وقيمة ارتفاع الطيران) صغيراً بالمقارنة مع معدل تغيير بارامترات الحركة حول مركز الثقل.

**2 – الحركة الذاتية قصيرة الدور:** حركة الطائرة كجسم صلب حول مركز الثقل (حركة دورانية) كاستجابة مباشرة لانحراف دفة العمق حيث تتغير البارامترات الموصفة لها (مثل زاوية الغوص، زاوية الهجوم...) بشكل أسرع نسبياً من بارامترات حركة مركز الثقل.

ويبين الشكل (2) منحنى استجابة زاوية الغوص لانحراف مفاجئ مقداره 1 درجة لدفة العمق تباين ترددات ومطالات كل من نمطي الحركة الذاتية طويلة وقصيرة الدور [1].




الشكل 2 – منحنى استجابة زاوية الغوص لانحراف مفاجئ مقداره 1 درجة لدفة العمق

ويمكن توضيح نمطي الحركة رياضياً بتحويل معادلات الحركة إلى الشكل الخطي بفرض ثبات المعاملات ودراسة الحركة كحركة اضطرابية صغيرة حول وضع التوازن، ثم وبإلغاء إشارات الدخل يمكن كتابة معادلات الحركة بالشكل المتجانس. وأخيراً بحل المعادلة المميزة نلاحظ تبايناً بين الجزئين العقديين من الجذور واللذين يعبران عن تردد كل من هاتين الحركتين.

### 1-2-1- الحركة الطولية قصيرة الدور

وسندرس فيما يلي حركة الطائرة الدورانية حول مركز الثقل والبارامترات المؤثرة عليها وتدعوها الحركة الطولية قصيرة الدور. يبين الشكل (3) كل من زاويا الهجوم، والمسار، والغوص، والعزم  $M_y$  المذكورة في الجدول (1) واتجاهاتها الموجبة.



الشكل 3- البارامترات الأساسية للحركة حول مركز الثقل

نلاحظ أن:

$$\theta = \alpha + \gamma \quad \dots (2)$$

بالإضافة للزاويا المذكورة فإن حركة الطائرة حول مركز الثقل توصف بالسرعة الزاوية لدورانها حول المحور العرضي أو ما يدعى معدل الغوص:

$$q = \frac{d\theta}{dt} \quad \dots (3)$$

يحسب العزم الأيروديناميكي بدلالة بارامترات الطيران كما يلي:

$$M(t) = C_m \frac{\rho V^2}{2} . S . c \quad \dots (4)$$

حيث:

$\rho$  [kg/m<sup>3</sup>] - هي كثافة الهواء (الكتلة الحجمية) على ارتفاع الطيران.

$V$  [m/s] - سرعة الطيران.

$S$  [m<sup>2</sup>] - المساحة المرجعية (مساحة سطح الجناح).

$c$  [m] - الطول المرجعي (وتر الجناح).

$C_m$  [1] - معامل العزم الأيروديناميكي للطائرة.

يحسب معامل العزم الأيروديناميكي بالعلاقة:

$$C_m = C_{m0} + C_{m\alpha} \cdot \alpha + C_{mq} \cdot q + C_{m\dot{\alpha}} \cdot \dot{\alpha} + C_{m\delta} \cdot \delta \dots (5)$$

حيث:

$C_{m0}$  - معامل العزم الصفري (ويساوي معامل العزم عند طيران مستديم على زاوية هجوم صفرية دون

حرف الدفة أي عند:

$$(\alpha = 0 , q = 0 , \dot{\alpha} = 0 , \delta = 0)$$

$$C_{m\alpha} = \frac{dC_m}{d\alpha} \left[ \frac{1}{rad} \right] \text{ مشتق معامل العزم الطولي لزاوية الهجوم.}$$

$$C_{mq} = \frac{dC_m}{dq} \left[ \frac{1}{rad/s} \right] \text{ مشتق معامل العزم الطولي لمعدل الغوص.}$$

$$C_{m\dot{\alpha}} = \frac{dC_m}{d\dot{\alpha}} \left[ \frac{1}{rad/s} \right] \text{ مشتق معامل العزم الطولي لمعدل تغير زاوية الهجوم.}$$

$$C_{\delta} = \frac{dC_m}{d\delta} \left[ \frac{1}{rad} \right] \text{ مشتق معامل العزم الطولي لانحراف دفة العمق.}$$

معادلة الحركة حول مركز الثقل:

$$M_y(t) = \varepsilon(t) \cdot I \quad (6)$$

حيث:

$M_y(t)$  [m . N] العزم الأيروديناميكي المطبق.

$\varepsilon(t)$  [rad/s<sup>2</sup>] - التسارع الزاوي للطائرة.

$I$  [Kg . m<sup>2</sup>] - عزم عطالة الطائرة حول محورها العرضي.

$$\varepsilon(t) = \frac{dq}{dt} = \frac{d^2\theta}{dt^2} \dots (7)$$

خلال الحركة قصيرة الدور تتغير بعض البارامترات ببطء لذلك فإننا نفرضها ثابتة أي:

$$V = const , \rho = const , \gamma = const$$

من (2) و (3) وبما أن  $\gamma = Const$  نجد:

$$q = \frac{d\theta}{dt} = \frac{d(\gamma + \alpha)}{dt} = \frac{d\alpha}{dt} = \dot{\alpha} \dots (8)$$

بتعويض عبارة العزم (4) في معادلة الحركة (6) مع أخذ قيم المعامل  $C_m$  من (5) وقيمة  $q$  من

(8) نجد:

$$\left( C_{m0} + C_{m\alpha} \cdot \alpha + (C_{mq} + C_{m\dot{\alpha}}) \frac{d\alpha}{dt} + C_{m\delta} \cdot \delta \right) \frac{\rho V^2}{2} S \cdot c = \frac{d^2\alpha}{dt^2} \cdot I \dots (9)$$

يمكن كتابة هذه المعادلة على الشكل النموذجي:

$$m \frac{d^2\alpha}{dt^2} + c \frac{d\alpha}{dt} + k\alpha = F(t) \dots (10)$$

حيث:

$$m = \frac{2I}{\rho V^2 S \cdot c} , \quad c = -(C_{mq} + C_{m\dot{\alpha}}) , \quad k = -C_{m\alpha} , \quad F(t) = C_{m0} + C_{m\delta} \cdot \delta$$

في حال التوازن أو الطيران المستديم (والذي يتم عادةً نمذجة ردة فعل الطائرة على اضطراب صغير

حواله) يكون  $M_y(t) = 0$  وبالتالي  $C_m = 0$

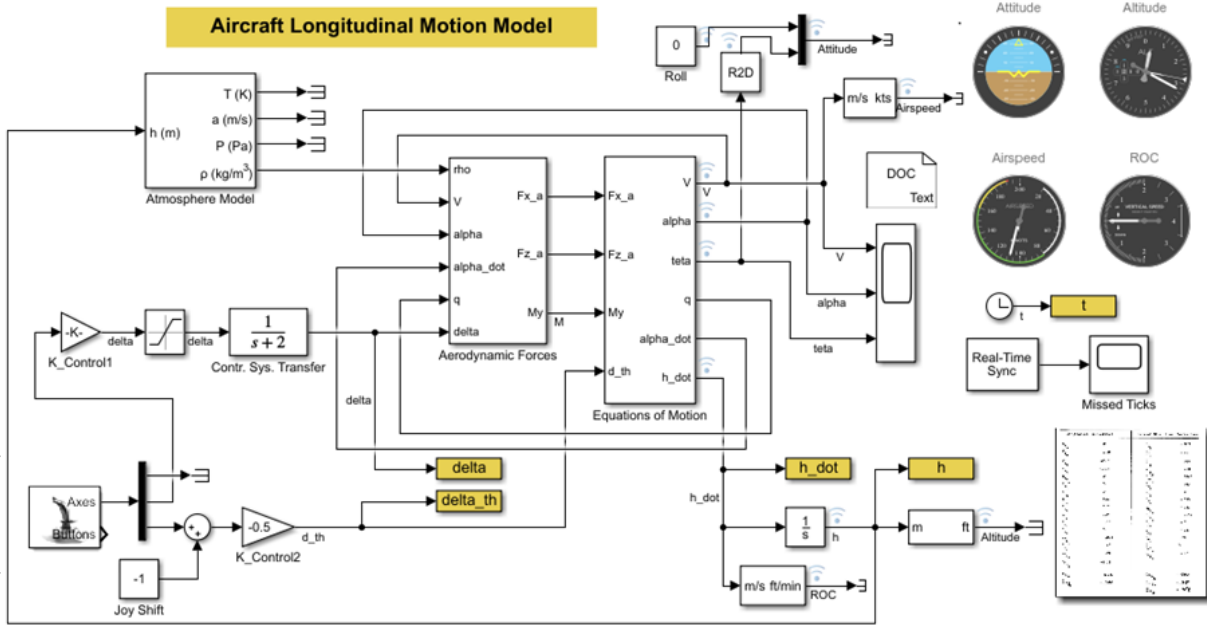
كما أن السرعة الزاوية معدومة وبالتالي  $\dot{\alpha} = 0$  من (5) نجد ان انحراف الدفة الذي يحقق التوازن

عند زاوية الهجوم  $\alpha$  :

$$\delta_t = \frac{-(C_{m0} + C_{m\alpha} \cdot \alpha)}{C_{m\delta}}$$

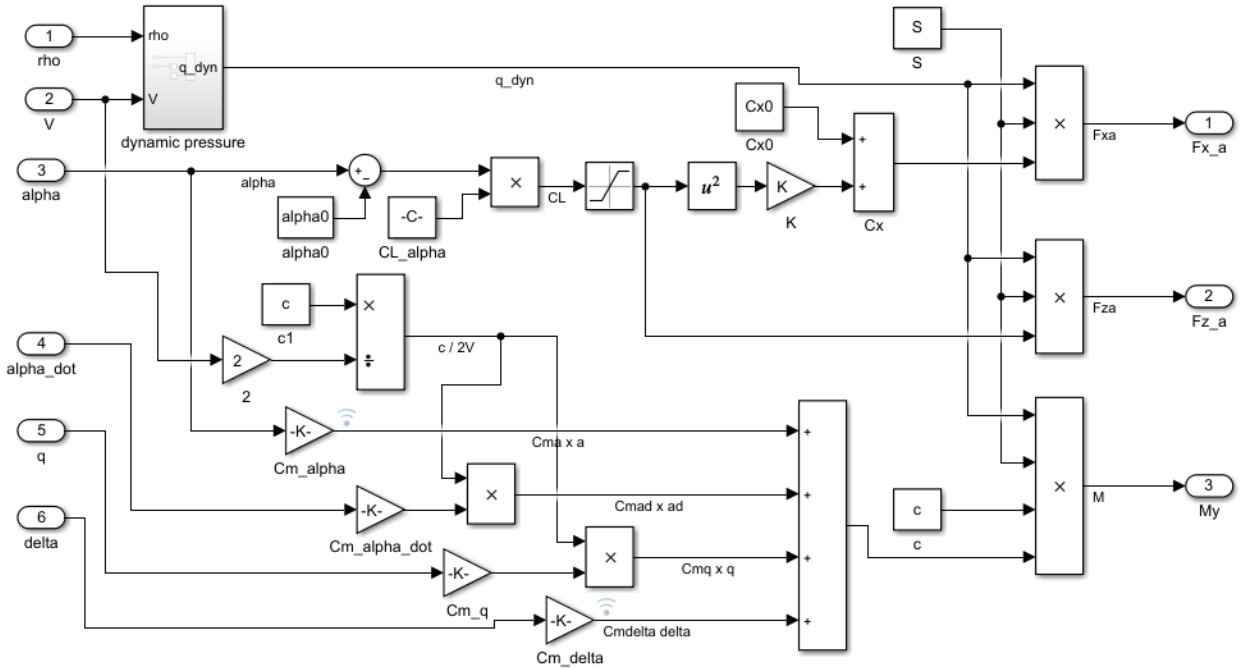
## 2-2-1- النموذج العام للحركة الطولية

تمت الاستفادة من جملة المعادلات المبسطة المعروضة في الفقرة السابقة في بناء نموذج للحركة الطولية ضمن برنامج ماتلاب لتنفيذ بعض الاختبارات الأولية وتحسس قيم البارامترات المتوقعة في النموذج الأعم الذي تم اعتماده لتمثيل حركة الطائرة وتبين كل من الأشكال التالية المكونات الأساسية لهذا النموذج. في الشكل (4) نوضح النموذج العام للحركة الطولية وفيه يمكننا توليد إشارة الدخل التي تمثل أوامر الطيار لعصا القيادة على القناة الطولية Elevator ومقود التحكم بالمحرك Throttle، باستخدام إما عصا القيادة Joystick أو كإشارات نمطية<sup>5</sup> Sine, Step، بالإضافة إلى وجود كتلتين أساسيتين نقوم في الكتلة الأولى بحساب القوى والعزوم الأيروديناميكية التي تمثلها المعادلة (3) والموضحة بالشكل (5)، حيث الدخل هو أوامر الطيار بالإضافة لتغذية راجعة من الخرج الناتج عن الكتلة الثانية التي تمثل حلاً لمعادلات الحركة (10) التي قمنا بشرح دلالات بارامتراتهما في الجدول (1) والموضحة بالشكل (6).

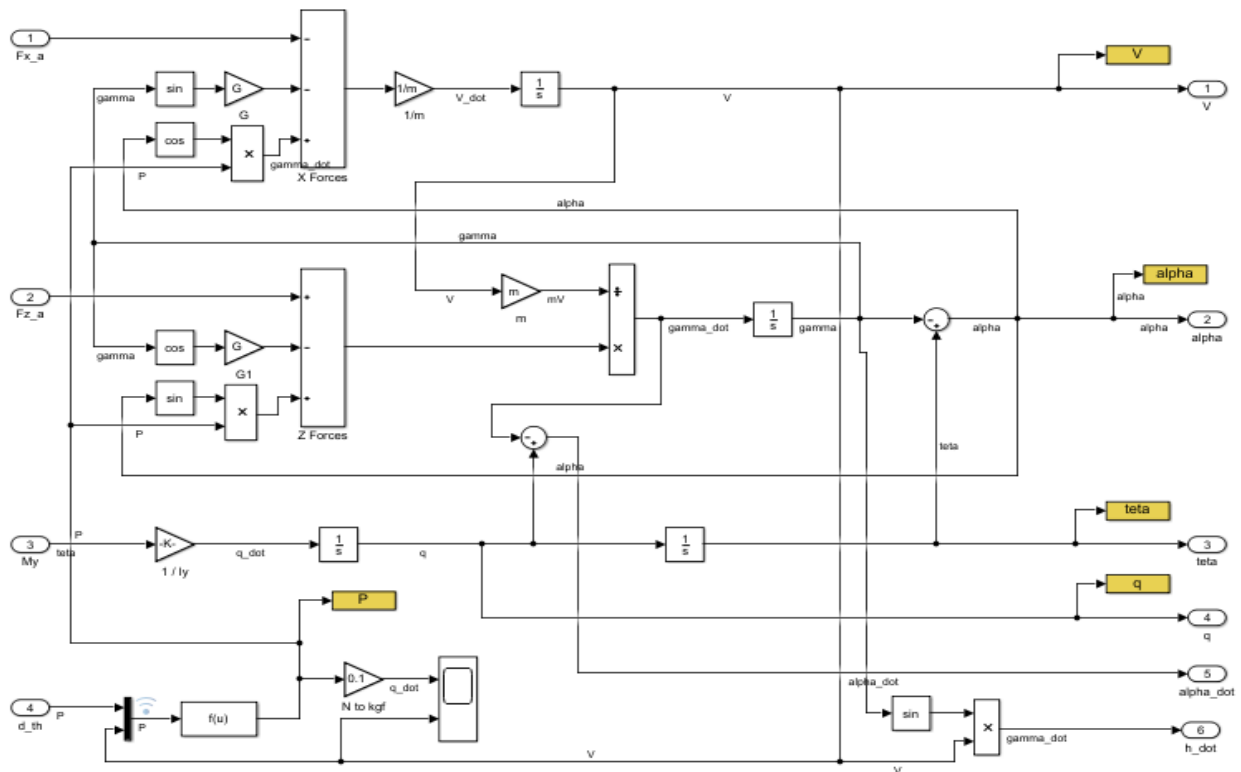


الشكل 4- المخطط العام لنموذج الحركة الطولية لطائرة خفيفة

<sup>5</sup> - يقصد بها هنا إشارات لها نمط متكرر مثل إشارة جيبية أو خطوة أو نبضة.



الشكل 5 - كتلة حساب القوى والعزوم الأيروديناميكية



الشكل 6 - كتلة معادلات حركة الطائرة

### 1-3- تحصيل بارامترات الطيران

تم تبني فكرة تسجيل معطيات رحلات الطيران للمساعدة في التحقيق في الحوادث في أربعينيات القرن الماضي وكان أول جهاز يقوم بتسجيل 5 أنواع فقط من معطيات الطائرة (التوجه، السرعة الهوائية، الارتفاع، التسارع الشاقولي، والزمن) خلال الرحلة الطيرانية لمدة تصل إلى الساعة. ثم في الستينيات من القرن الماضي وضعت قواعد استخدام الصندوق الأسود في الطائرة وأصبح من غير الممكن لأي طائرة أن تقلع دون التأكد من جاهزية صندوقها الأسود الذي يتكون من جهازين منفصلين، لضمان استقلالية ووثوقية المعلومات المحفوظة، هما المسجل الصوتي لقمرة القيادة CVR، ومسجل بيانات الرحلة FDR.

تقوم أجهزة الطائرة الإلكترونية بإرسال كل القراءات والقياسات التي تحدث طوال الرحلة وتظهرها على العدادات في قمرة القيادة وبنفس الوقت تقوم بتخزينها ضمن FDR وتحدد منظمة الطيران المدني الدولية ICAO ماهية البارامترات التي يتم حفظها بترددات مختلفة، مثل الارتفاع والسرعة والضغط إضافة لبيانات المحرك وأنظمة الطائرة المختلفة والأوامر التي يقوم بها الطيار ورد فعل الطائرة على تلك الأوامر بهدف تقييم حالتها الفنية أثناء الرحلة، مثلاً تخفيض سرعة دوران المحرك يؤدي إلى تباطؤ في سرعة الطائرة وبالتالي ينخفض الارتفاع بسبب تناقص قوة الرفع المتولدة على الأجنحة.

تتيح أنظمة العدادات الإلكترونية EFIS الحديثة تخزين البارامترات ضمنها أو إرسالها إلى مركز تحليل المعطيات على الأرض بترددات مناسبة (من 1 إلى 16 مرة في الثانية في بعض أنظمة EFIS) لتتم معالجتها في الزمن قرب الحقيقي. ويتم إرسالها على شكل رسالة نصية غالباً تتضمن لحظة القياس، وإشارة القيمة المقاسة (موجبة أو سالبة)، والقيمة المقاسة لكل بارامتر، ووحدة القياس.

إن عدم توافر تسجيلات رحلات طيران خفيف على الإنترنت وندرة أعطال الطيران بشكل عام جعل من الضروري بالنسبة لنا اعتماد نموذج مقلد أرضي للتدريب واختبار وجود شذوذ في تسجيلات الطيران، ولتسهيل العمل يمكن الاعتماد على مقلد طيران للحصول على البارامترات، وقد تم خلال المشروع التعرف على نموذج الحركة الطولية للطائرة ضمن برنامج Simulink MATLAB.

### 1-4- المعطيات الكبيرة في تحليل معطيات الطيران

لسنوات خلت، اقتصر تحليل البارامترات الطيرانية على الأرض في حالة سكون المعطيات لتعذر وجود تقنيات تساعد على تحصيل المعطيات التي تولدها الطائرة ومعالجتها وتخزينها بالسرعة المطلوبة. أما في

السنوات الأخيرة فقد حازت تقنيات المعطيات الكبيرة على اهتمام العاملين في مجال تحليل بارامترات الطيران، باعتبار أن الأدوات التي تقدمها في التحليل نموذجية في تجاوز العديد من المشاكل كذاكرة التخزين نظراً لتزايد أعداد الحساسات وتعقيد أنظمة الطيران المختلفة والحجم الكبير الذي تنتجه، بالإضافة لإمكانية المعالجة السريعة في الزمن قرب الحقيقي. [3]. ومن الخصائص التي يُعنى بها مفهوم المعطيات الكبيرة والتي تهتمنا في مراقبة بارامترات الطيران نذكر:

**الحجم Volume:** تولد الطائرات معطيات بشكل مستمر عن طريق الحساسات الموجودة على متنها وأنظمتها الحديثة، يضاف إليها المعطيات من المطارات ومن المحطات الأرضية والأرصاد الجوية. وعلى الرغم من قدرة التكنولوجيا الحديثة على إرسال ومعالجة بيانات الطيران في الزمن الحقيقي إلا أن الكلفة العالية لنقل البيانات تحول دون ذلك ويكتفى عادة بالمعالجة بالزمن قرب الحقيقي أو بإرسال جزء مناسب من البيانات فقط كبارامترات حالة المحرك وبارامترات الأساسية من موضع وارتفاع ووجهة [4]. ومثال على الحجم الكبير لبيانات الطيران فإن طائرة كطائرة Boing 737 تولد ما يقارب 20 تيرابايت بالساعة من البيانات لمحرك واحد فقط [5]. ونهتم في البحث بالمعطيات الرقمية التي نحصلها من الحساسات على متن طائرة خفيفة حيث يقل عدد البارامترات المسجلة خلال الرحلة.

**السرعة Velocity:** يقصد بها السرعة اللازمة لتحصيل وتحليل ومعالجة وتخزين المعطيات بالمقارنة مع سرعة نمو المعطيات عبر الزمن. تقدم العديد من أنظمة العدادات الإلكترونية أكثر من 100 بارامتر نحتاج لتحديد ما يهمنا من تلك البارامترات ومعالجتها بالزمن قرب الحقيقي.

**القيمة Value:** وهي مقدار الاستفادة من البيانات، فأحياناً لا تحمل البيانات قيم صحيحة نتيجة للضجيج أو انقطاع الإرسال، وهذا يضعف التحليلات، لذلك من المهم التأكد من صحة البيانات حتى تتمكن من الاستفادة منها بشكل دقيق، كالقيام بتنظيف البيانات قبل المعالجة لاستبدال أماكن الانقطاع أو التخلص من الضجيج.

**التغير Variability:** تعبر عن تغير البيانات وتباينها المستمر. إن الحصول على معنى لتلك التغيرات في البيانات مهم جداً ويفيد في الكشف عن حدوث خلل ما في أحد الأنظمة الجزئية للطائرة، وكمثال ذلك ارتفاع درجة حرارة المحرك أثناء التسلق ضمن مجال درجات حرارة معينة يعتبر مقبولاً في حين يعتبر ارتفاع درجة حرارة المحرك بنفس المجال أثناء طيران مستقيم قد ينبئ بحدوث خلل ما في المحرك.

**التطايير Volatility:** هو مقدار الزمن المفيد للبيانات أي أن الاحتفاظ بالبيانات بعد مدة زمنية معينة يصبح بلا فائدة، مثلاً في حال تأخر معالجة البيانات وعدم إطلاق تحذير في الوقت المناسب للطيار قد يحصل حادث وحينها تفقد المعالجة من قيمتها وهدفها في رفع سوية أمان الطائرة رغم الحصول على نتيجة صحيحة. وقدمت حديثاً الكثير من الأبحاث أنظمة دعم قرار لتوفير العديد من الخدمات كالإنذار المبكر وتوفير الوقود ووضع خطة صيانة الطائرة وتنظيم عمل الخطوط الجوية، وذلك من خلال تحليل المعطيات الناتجة عن مختلف أنظمة الطائرة والمطار والملاحة وتخزينها.

## 5-1- السلاسل الزمنية

تعرف السلسلة الزمنية بأنها مجموعة من المعطيات حول ظاهرة ما تؤخذ خلال فترات متتالية قد تكون متساوية الطول وقد لا تكون كذلك، وقد تكون مستمرة أو متقطعة. وما يميز السلسلة الزمنية عن غيرها من المعطيات أن لترتيب تحصيل المعطيات خلال الزمن أهمية كبيرة، وعادة ما يتم دراسة السلسلة الزمنية بمعزل عن العوامل الأخرى التي تؤثر بها أو ترتبط بها بعلاقة إحصائية أي المتغيرات المستقلة، ما عدا الزمن [6].

وتهدف دراسة السلسلة الزمنية إلى وصف تطور أو تحديد سلوك ظاهرة ما خلال فترة زمنية ومن ثم شرح وتفسير التغيرات التي تطرأ على الظاهرة المدروسة أو أحد العوامل المحيطة بها للوصول إلى القدرة على تنبؤ قيم المعطيات في المستقبل والتحكم بسلوك الظاهرة قيد الدراسة.

### 1-5-1- مكونات السلسلة الزمنية

تتأثر التغيرات التي تطرأ على السلسلة الزمنية بأربع عوامل وقد تتأثر السلسلة ببعض هذه العوامل مجتمعة أو ببعضها. وتشكل العوامل الثلاث الأولى المؤثرات الرئيسية في السلسلة الزمنية ويمكن اكتشاف أنماطها والتنبؤ بها، ويجب إلغاء أثرها عند دراسة السلسلة الزمنية، بينما يكون العامل الأخير غير أساسي وغير نمطي ولا يمكن التنبؤ به [6]. وهذه العوامل موضحة في الشكل (7) وهي:

**العوامل الموسمية Seasonality:** هي التغيرات التي تُحدث نمطاً دورياً منتظماً في السلسلة، قد تكون أسبوعية أو شهرية أو سنوية، مثل مواسم الزراعة خلال فصول العام، أو مواسم التنزيلات في الأسواق صيفاً وشتاءً.

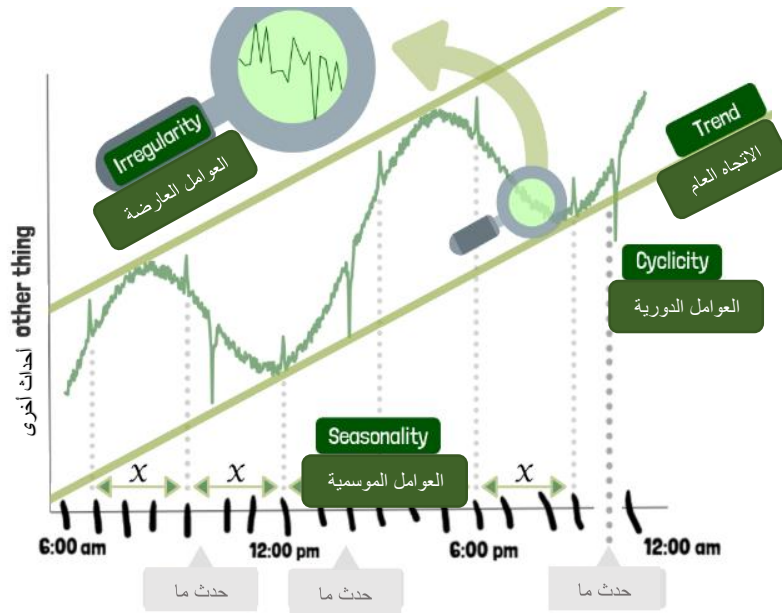
**العوامل الدورية Cycling:** تشابه العوامل الموسمية إلا أنها تتكرر ضمن فترات طويلة الأجل، عدة سنوات مثلاً، بالإضافة إلى أن طول الدورة قد لا يكون منتظماً مما يجعل من الصعب تقديره ويؤدي ذلك في

مسائل التنبؤ إلى عدم دراسته بحسب طول السلسلة المدروسة وتأثيره عليها. ومثالها الدورة الاقتصادية، أو الحضارية لبلد ما.

**الاتجاه العام Trend:** يعبر عن التغيرات تطراً على السلسلة على المدى الطويل وقد يكون بالزيادة أو النقصان. ولكيلا يحدث خلط بينه وبين العوامل الدورية، يكون من الأفضل إزالة أثر العوامل الدورية أولاً عند دراسة السلسلة الزمنية ثم إلغاء الاتجاه العام. ومثاله اتجاه السلسلة الزمنية الخاصة بسعر سلعة تزداد مع الزمن بتزايد سعر الصرف.

**العوامل العارضة Random:** هي تغيرات تسببها أحداث عشوائية تصيب السلسلة الزمنية ولا يمكن التنبؤ بها، ولا تستمر طويلاً.

إذاً تتأثر البارامترات سريعة التغير بالعاملين الموسمي والدوري بينما تتأثر البارامترات بطيئة التغير بالاتجاه العام.



الشكل 7 - مكونات السلسلة الزمنية [7]

ويمكن دراسة السلاسل الزمنية بعدة طرق يتطلب تنفيذ بعضها أن تكون السلسلة الزمنية مستقرة، ويمكن فحص استقرارها بعدة طرائق منها إحصائي مثلاً يمكن تجزئة السلسلة الزمنية إلى عدة أجزاء متساوية في

الطول، وتكون السلسلة الزمنية مستقرة إذا كانت ذات قيمة ثابتة في المتوسط والانحراف المعياري لجميع تلك الأجزاء [8]. ومنها بالرسم البياني لتابع الارتباط الذاتي أو الجزئي للبيانات.

### 1-5-2- العوامل المؤثرة في السلسلة الزمنية لبارامترات الطيران

تمتد الرحلة الطيرانية في الطائرة المدروسة لمدة 20 دقيقة وسطياً، تبدأ بالإقلاع والتسلق ثم تنفيذ المهمة المطلوبة ومن ثم الهبوط، وهذا يعني أن العامل الدوري لا أثر له في السلسلة.

أما العامل الموسمي فيظهر أثره في الحركة الطولية للطائرة قصيرة الدور Short Period وطويلة الدور Long Period. كما تتأثر بالاتجاه العام أثناء التسلق والهبوط ويظهر الاتجاه العام جلياً في بارامتر الارتفاع وهو من البارامترات التي تتغير ببطء في مسألتنا.

إذا السلسلة الزمنية قيد الدراسة تتكون من ثلاثة عوامل: عامل الاتجاه العام ويمكن تقديره وإزالته من السلسلة، وعامل الموسمية [9]. وعامل عارض لا يمكن تقديره وإزالته.

يمكن إلغاء أثر الاتجاه العام بعدة طرق منها طرح المتوسطات من السلسلة، أو بتحليل الانحدار الخطي بإيجاد الخط المناسب لاتجاه المعطيات بطريقة إحصائية، ومن ثم طرحه من قيم بيانات السلسلة وخرج هذه العملية هو residuals. تعطى عبارة الانحدار الخطي بالعلاقة التالية:

$$\hat{y} = a + bx$$

ويتم إيجاد الثوابت إحصائياً بالصيغتين التاليتين:

$$a = \frac{(\sum y \sum x^2) - (\sum x \sum xy)}{n (\sum x^2) - (\sum x)^2}$$

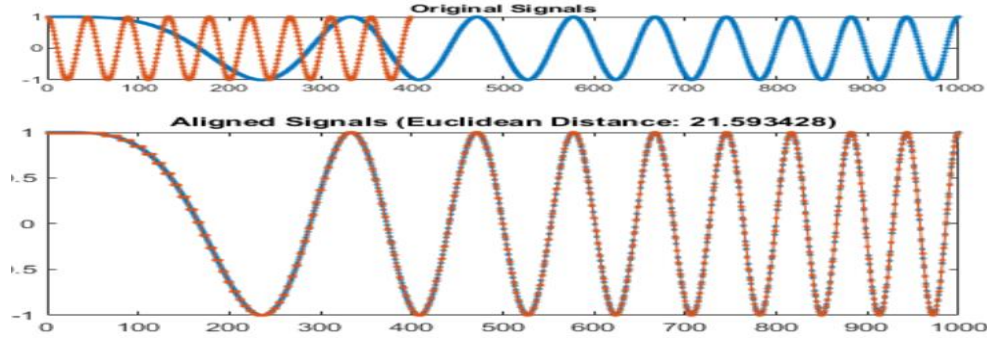
$$b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n (\sum x^2) - (\sum x)^2}$$

### 1-5-3- قياس التشابه بين سلسلتين زمنيتين

يمكن قياس التشابه بين سلسلتين زمنيتين باستخدام طريقة DTW Dynamic Time Warping، التي تقوم على عمل محاذاة بين السلسلتين بحيث يكون حساب المسافة الإقليدية بين سلسلتين زمنيتين هو الأصغر.

إذا كان طول كل من السلسلتين متساوياً، فلا داعي للمحاذاة، فقط نقوم بحساب المسافة بينهما. وإلا، فإننا بحاجة إلى المحاذاة. أبسط طريقة لذلك هي أن نقوم بتكبير التسلسل القصير بشكل خطي إلى نفس طول التسلسل الطويل ثم نقارن، أو نختصر الخط الطويل إلى نفس طول التسلسل القصير ثم نقارن.

تكمُن أهمية هذه الطريقة عندما يكون طول كل من السلسلتين الزمنيّتين مختلفاً ومثال ذلك في الشكل (8). أما إذا كان نفسه فيمكن استخدام مقاييس أخرى، مثلاً مقياس cosine في التشابه.




الشكل 8- محاذاة سلسلتين زمنيتين ثم قياس المسافة بينهما

## 6-1- الشبكات العصبونية

تتكون الشبكات العصبونية بشكل عام من عناصر معالجة بسيطة "عصبونات" ويتحدد سلوكها من خلال خوارزمية رياضية تعطي حلاً لعدد من المشكلات بشكل يحاكي الشبكة العصبونية الحيوية أي عن طريق وصلات موزونة بين مختلف عناصر الشبكة والبارامترات الفائقة. في الشكل (9) توضيح لبنية الشبكة العصبونية.

تتكون كل خلية عصبونية اصطناعية من ثلاثة أقسام رئيسية هي :

- الوزن: وهو عامل تثقيل لكل خلية يعبر عن مدى أهمية الارتباط بين العنصرين في طرفي الوصلة. وهو ما سنستخدمه في الكشف عن العلاقات السببية بين البارامترات.
- الجامع: وهو عبارة عن حاصل جمع وزن كل خلية مضروبة بالدخل.
- تابع التفعيل: يستخدم لمعالجة إشارة الخرج بحيث يطبق التابع على هذه الإشارة ومنه تنتج القيمة النهائية المطلوبة.




الشكل 9 - مكونات الشبكة العصبونية

يقوم العصبون بتطبيق تابع الجمع على خرج العصبونات مضروباً بأوزان الوصلات  $W_{ki}$ ، ثم تطبيق تابع تفعيل  $f$  على الناتج لتحديد الخرج ويقدمه للعصبون التالي، وأبسط أنواع توابع التفعيل، تابع قيمة العتبة الذي يعطي قيمة 1 إذا كانت النتيجة أكبر من قيمة معينة تدعى العتبة و 0 إذا كانت أقل منها.

$$y = f\left(\sum_{i=1}^n W_i X_i\right); \quad X: \text{input}; \quad n: \text{number of features}$$

ويمكن تطبيق أي تابع خطي أو غير خطي بشرط أن يكون مستمراً وقابلاً للاشتقاق، ويوضح الشكل (10) بعض توابع التفعيل منها الخطية على اليمين وغير الخطية على اليسار.



الشكل 10 - بعض توابع التفعيل المشهورة

وتتألف الشبكة العصبونية من طبقات من الخلايا الاصطناعية: طبقة داخلية وطبقة خارجية وطبقات مخفية تتواجد بين طبقتي الدخل وطبقة الخارج. تتصل كل خلية في كل طبقة بكافة العصبونات الموجودة في الطبقة التي تليها.

تختلف الشبكات العصبونية بحسب الوظيفة الموكلة إليها من خلال خوارزمية التعلم والبيانات التي تعالجها ونهتم في هذا البحث بالشبكات التي تستطيع معالجة السلاسل الزمنية، أي تلك التي تمتلك ذاكرة للاحتفاظ بالمعطيات السابقة لتستطيع كشف الارتباط بين البارامترات في عدة خطوات زمنية. كما في شبكات التعلم العميق مثل الشبكة العودية RNN، ومنها الذاكرة طويلة وقصيرة الأمد LSTM التي تصنف من شبكات التعلم العميق، وشبكة الانحدار الذاتي غير الخطي NARXNET.

### 1-6-1- الشبكات العصبونية العودية RNN

ساعد وجود شبكات عصبونية ذات تغذية راجعة على تطوير بنية جديدة تسمح بتعلم سلوك السلاسل الزمنية، وللشبكات العودية تركيبين أساسيين: شبكات التأخير الزمني Time Delayed، وشبكات المزامنة Simultaneous Network. تستخدم الأولى بكثرة في مسائل التنبؤ فهي مصممة لتتعلم على تصغير أخطاء التنبؤ قدر الإمكان وتدعى خوارزمية التعلم في هذا النمط بالانحدار المتناقص، بينما تستخدم التركيبية الثانية في تقريب التوابع. [10].


تختلف الشبكات العودية عن الشبكات العصبونية التقليدية في طريقة عمل العصبون حيث يتم تغذية الشبكة بالدخل الحالي إضافة إلى تغذية راجعة من الدخل السابق تخزن في الوحدات المخفية Hidden Unit  $h$  التي تمثل ذاكرة الشبكة كما في الشكل (11). يتم تغذية الشبكة بسلسلة مرتبة من أشعة الدخل وما يقابلها من أشعة الخرج، وتكون قيمة الحالة المخفية الابتدائية مساوية للصفر  $h_0=0$  [11].

تعطى الصيغة العودية للحالة المخفية  $h_t$  بالاعتماد على الحالة المخفية السابقة وشعاع الدخل  $X$  في اللحظة  $t$  كما يلي:

$$h_t = f(UX_t + Wh_{t-1} + b)$$

ويعطى شعاع الخرج بالاعتماد على الحالة المخفية الحالية، بالصيغة:

$$y_t = g(Vh_t) \quad \text{حيث } g \text{ تابع تفعيل خطي في مسائل التنبؤ.}$$




الشكل 11- شبكة عصبونية عودية بعد بسطها 3 خطوات من الزمن. مصدر الصورة [11]

من مميزات الشبكات العودية أنها تتيح الارتباط الكامل بين عناصرها شكل (12)، مما يكشف ترابطات تلك العناصر بين بعضها البعض في المستوى الأفقي و عبر الزمن في المستوي العمودي، وتدعى حينئذٍ الشبكة العودية كاملة الارتباط. وتعطى صيغة خرج الشبكة بالعلاقة التالية:

$$y_i^t = \sum_{j=1}^J w_{ji} y_j(t) + x_i(t); i = 1..J$$

حيث J عدد عناصر الشبكة العودية.




الشكل 12- بنية الشبكة العودية كاملة الارتباط [12]

تواجه الشبكة العصبونية العودية ضعفاً في عملية التعلم في حال وجود أكثر من 5 إلى 10 خطوات زمنية بين الدخل والخرج [11]، كما أنها تعاني من مشكلة تلاشي أو انفجار الانحدار التي تظهر أثناء تدريب الشبكة

باستخدام خوارزمية الانحدار المتناقص، عند استخدام عدد غير ملائم من العصبونات المخفية أو تعيين البارامترات الفائقة بشكل غير مدروس. يمثل التغيير بالانحدار تغييراً في أوزان الشبكة، ولأن عملية تعديل الأوزان تعتمد على الضرب المتكرر عبر الزمن، فقد ينتج عن عملية تعديل الأوزان أرقاماً صغيرة جداً يصعب على الحاسب التعامل معها وتصبح المشتقات إما معدومة "مشكلة التلاشي" أو غير معينة "مشكلة الانفجار" مثال ذلك شكل (13)، وبالتالي يصبح تعلم الشبكة بطيئاً جداً وقد لا تتعلم الشبكة أصلاً في حال عدم إمكانية تحديد ميل الانحدار. [13]

يمكن حل ظاهرة الانحدار المتناقص باستخدام عدة طرق منها:

- استخدام شبكة LSTM.
- استخدام تابع تفعيل لا يواجه مشكلة الانحدار المتناقص مثل تابع تفعيل ReLU.
- عتاد حاسبي أسرع بالمعالج أو كرت الفيديو.




الشكل 13- مشكلة الانحدار المتناقص عند تطبيق تابع تفعيل Sigmoid عدة مرات

## 1- شبكة LSTM

تعتبر شبكة LSTM شبكة مطورة من الشبكات العودية RNN وتعتمد خوارزمية التعلم تحت الإشراف على التدرج في ربط المعطيات التي يتم تغذيتها للشبكة لفترة طويلة من الزمن وبذلك تتجاوز مشكلة الشبكات العودية التقليدية في التعامل مع عدد صغير من الخطوات الزمنية. كما تتيح بنية هذه الشبكة المطورة التغلب على مشكلة تلاشي أو انفجار التدرجات بإضافة بوابة نسيان Forget Gate وعنصر حالة الخلية العصبونية Cell State

الذي يعتبر أساس الشبكة موضحاً بالشكل (14)، مما يمنع حالتها انعدام المشتقات أو عدم تعيينها والحفاظ عليها بقيمة ثابتة مع استمرار عملية التعلم، [14].



الشكل 14- بنية تفصيلية لشبكة LSTM تظهر تفاعل طبقاتها مع بعضهم البعض

تفيد حالة الخلية Cell State بتحديد ما سيتم الاحتفاظ به من الدخل السابق والحالة المخفية حتى الخرج. ويتم حساب الحالة المخفية من خلال أربع طبقات داخلية تتفاعل فيما بينها لتتمكن الشبكة من تحديد ما يجب تذكره أو نسيانه من العناصر السابقة في سلسلة الدخل، وهذه الطبقات هي:

- 1- طبقة بوابة النسيان Forgetting gate:  $f_t = \sigma(U_f X_t + W_f h_{t-1} + b_f)$
- 2- طبقة بوابة الإدخال Input gate:  $i_t = \sigma(U_i X_t + W_i h_{t-1} + b_i)$
- 3- طبقة حساب القيم المرشحة Candidate values:  $c_t = \tanh(U_c X_t + W_c h_{t-1} + b_c)$
- 4- طبقة بوابة الخرج Output gate:  $o_t = \sigma(U_o X_t + W_o h_{t-1} + b_o)$

ولتقرر الشبكة المعطيات التي ستحتفظ بها في حالة الخلية يتم أولاً تطبيق تابع تفعيل sigmoid في بوابة النسيان على الدخل الحالي والحالة المخفية السابقة ويعطي قيمة بين 0 و1 لتحديد الجزء الذي سيتم الاحتفاظ به من دخل التابع. ومن أجل نفس الخطوة الزمنية ونفس الدخل يتم في بوابة الدخل حساب القيم المرشحة أي التي سيتم تعديلها وحفظها في حالة الخلية، من خلال جمع قيم المرشح في الخطوة الزمنية الحالية والسابقة.

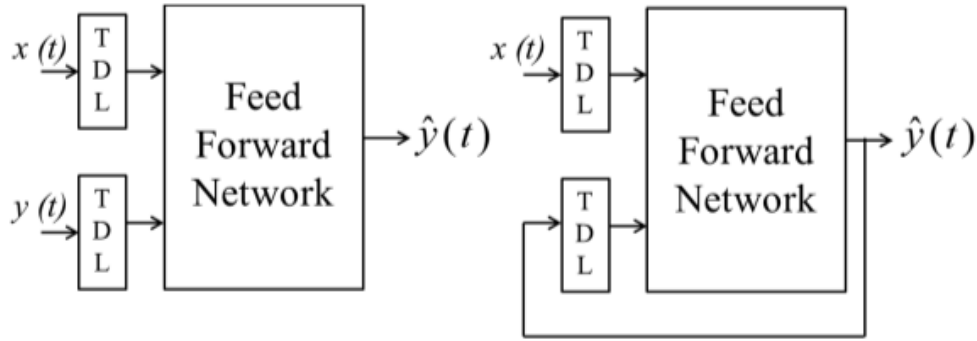
إذاً تنسى الشبكة ما يجب التخلص منه أولاً ثم تقوم بتحديث حالة الشبكة بالقيم المرشحة وتعيد توزيع القيم بين 1- و1 باستخدام تابع تفعيل  $\tanh$ ، ثم يحسب الخرج بناءً على حالة الخلية المعدلة، ثم تعيد الشبكة حساب الطبقة الخفية اعتماداً على الخرج الحالي وحالة الخلية الحالية. [14]

$$h_t = O_t * \tanh(C_t)$$

## 2- شبكة NARXNET

تعتبر هذه الشبكة العودية من الشبكات القياسية لتعرف الأنظمة، وتستخدم لنمذجة الأنظمة الديناميكية غير الخطية وتنبؤ السلاسل الزمنية غير الخطية باستخدام ذاكرة تربط مجموعة من القيم السابقة في السلسلة الزمنية. [15]. ولهذه الشبكة بنيانان أحدهما ذو حلقة مفتوحة، والآخر ذو حلقة مغلقة.

تحتوي بنية الشبكة على طبقة التأخير الزمني TDL، شكل (15)، للاحتفاظ بقيم الدخل والخرج السابق، وتغذية الشبكة بتلك القيم باستمرار، مما يجعلها مناسبة أيضاً للعمل في الزمن قرب الحقيقي.



الشكل 15 – بنية شبكة NARXNET. في اليمين شبكة ذات حلقة مغلقة، واليسار تمثل شبكة ذات حلقة مفتوحة

في نمط الحلقة المفتوحة كما هو موضح في الشكل السابق يتم التنبؤ بالاعتماد على القيم الحقيقية للدخل وقيم الخرج الحقيقية أيضاً، بينما في شبكة الحلقة المغلقة يتم الاعتماد في التنبؤ على قيم خرج التنبؤ السابقة، وهذا يساعد في التوقع لعدة خطوات زمنية.

### 1-6-2- قياس أخطاء التنبؤ

يحدد الخطأ في التنبؤ عند اللحظة  $t$  على أنه الفرق بين القيمة الحقيقية للبارامتر المقاسة وقيمة التنبؤ.

$$e_t = y_t - \hat{y}_t; \quad t = 1 \dots n \quad \text{حيث } n \text{ عدد المشاهدات}$$

يدلنا الخطأ على مدى ملاءمة نموذج التنبؤ للبيانات. فكلما كان صغيراً كلما كان التنبؤ أدق والعكس صحيح. ويكون التنبؤ أكثر دقة للخطوات الزمنية القريبة خاصة في المعطيات التي تحوي أنماطاً كتتالي إشارات جيبيية أو خطوة أما في المعطيات التي لا تحوي أنماطاً فيزداد الخطأ بمرور الزمن في حال لم يتم تصحيح المشاهدات بشكل مستمر.

هناك عدة طرق لقياس الخطأ ولكن ليست كلها تناسب السلاسل الزمنية فمثلاً مقياس مجموع الأخطاء SE Sum of Errors لا يعطي مقياساً مفيداً دائماً وذلك بسبب أنه مجموع الأخطاء يكون ضمن الحدود المقبولة بغض النظر عن حجم تلك الأخطاء. وتستخدم مع السلاسل الزمنية غالباً إحدى المقاييس التالية:

متوسط الانحرافات المطلق MAD، وفي بعض الأحيان يستخدم الوسيط Median بدلاً من الوسطي، ويعطى بالصيغة:

$$MAD = \frac{1}{n} \sum_{t=1}^n e_t$$

متوسط الأخطاء النسبية المطلقة MAPE، وصيغته:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{e_t}{y_t}$$

متوسط مربعات الأخطاء MSE:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

## 7-1- الكشف عن ارتباطات السببية بين البارامترات

يعد تحليل السببية من أدوات منهجيات البحث العلمي لتفسير الظواهر أو التنبؤ بها. والسبب بالمعنى الفيزيائي يدل على واقعة لها دور في حدوث واقعة أخرى تدعى بالنتيجة ولا يعني تحليل السببية بين البارامترات تحديد الارتباط بينها Correlation، فارتباط زوج من البارامترات في علم الإحصاء لا يعني بالضرورة أن أحدهما مسبب للآخر Correlation doesn't imply causation. بالإضافة إلى أن الارتباط لا يعطينا أي معرفة حول جهة التأثير بين البارامترات [16] وتتميز العلاقات السببية بين الوقائع بمميزات تمكننا من الكشف عنها وهي [17]:

1- التلازم في الوقوع (A=> B) وهو يفيد في كشف التعاقب الزمني.

2- التلازم في الغياب ( $B^{-1} \Rightarrow A^{-1}$ ).

3- الترابط بين تغيرات الشدة، حيث التغير في شدة السبب يؤدي لتغير في شدة النتيجة.

تظهر أهمية تحليل السببية في النماذج المعتمدة على البيانات في موطنين بشكل أساسي، الأول في عملية انتقاء البارامترات feature selection كحل لمشكلة "لعنة الأبعاد" في بيئة معطيات كبيرة متعددة الأبعاد. فاختيار البارامترات بشكل مناسب يخفف من كلفتي حساب وزمن المعالجة، كما يحسن من أداء نموذج التعلم (وهو نموذج تنبؤي في هذا البحث). أما الموطن الثاني فيشكل تحليل السببية بالاعتماد على المعطيات Data Driven أداة هامة في تشخيص الأعطال ومعرفة مسبباتها.

يمكن الحصول على بيان العلاقات السببية بين البارامترات بعدة طرق منها استخدام مصفوفة الدقة Precision Matrix [18] وهي مقلوب مصفوفة التغاير Inverse Covariance والذي يمثل العلاقات السببية بين البارامترات، أو بطريقة أشعة الانحدار الذاتي، أو من خلال إضافة معلم التنظيم Regularization parameter L1 أثناء تدريب الشبكات العصبونية بحيث تقوم الشبكة أثناء التعلم بالتخلص من البارامترات التي لا تؤثر في خرج الشبكة بوضع وزن صفري للبارامتر في مصفوفة الأوزان في عنصر الخرج الموافق [19].

#### 1-7-1- كشف العلاقات السببية باستخدام شعاع الانحدار الذاتي VAR

يعد العالم Granger<sup>6</sup> من أوائل من بحث في الكشف عن العلاقات السببية المؤقتة بين السلاسل الزمنية، معتمداً مبدأ التنبؤ في هذه الطريقة عن طريق دراسة فرضية فيما لو كان استخدام القيم السابقة لسلسلة زمنية  $x$  يفيد في تحسين نتائج تنبؤ سلسلة زمنية ثانية  $y$  [16] ، فإذا كانت نتيجة تلك الفرضية أقل من قيمة معينة  $\alpha$  تكون الفرضية مرفوضة ولا تؤثر السلسلة الزمنية الأولى في الثانية أي ليست مسبباً لها. وإلا يكون للسلسلة الأولى أثراً في السلسلة الثانية وعندها نكتب  $x \rightarrow y$ . وبالتالي يمكن من خلالها تحديد علاقة (السبب – الأثر) بين زوج من البارامترات باستخدام مصفوفة معاملات الانحدار الخطي VAR Vector Auto Regression. وتطبق هذه الطريقة على السلاسل الزمنية المستقرة، فإذا كانت غير ذلك نطبق اختبار الفرضيات على الفروق من المرتبة الأولى. [20].

<sup>6</sup> عالم بريطاني حائز على جائزة نوبل لعلوم الاقتصاد، له مساهمات عديدة في السلاسل الزمنية خاصة غير الخطية توفي عام 2009.

وفي حال سلسلتين زمنيتين  $x, y$ ، تكتب عبارة السلسلة  $y$ :

$$y_t = a_0 + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_m y_{t-m} + error_t$$

إذا ظهرت  $x$  في عبارة  $y$  على الشكل:

$$y_t = a_0 + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_m y_{t-m} + b_p x_{t-p} + \dots + b_q x_{t-q} + error_t$$

نقول إن  $x$  تؤثر في  $y$ ، أي  $x \rightarrow y$ .

وفي حال سلاسل زمنية متعددة يمكن تحليل علاقة السببية بين البارامترات باستخدام طريقة شعاع الانحدار الذاتي VAR، تكتب علاقة نموذج VAR بالرجوع  $L$  خطوة زمنية سابقة:

$$X(t) = \sum_{l=1}^L A_t X(t-l) + e(t)$$

وتكون السلسلة الزمنية  $X_i$  مؤثرة في سلسلة زمنية أخرى  $X_j$  إذا وجد على الأقل عنصر واحد أكبر من الصفر في عناصر المصفوفة  $A_t(j,i)$ ، من أجل كل  $L, t=1, \dots, L$ . [21]

### 2-7-1- كشف العلاقات السببية لسلاسل زمنية متعددة البارامترات باستخدام MVAR

يمكن تعميم الطريقة السابقة على سلاسل زمنية متعددة البارامترات يكون نموذج MVAR بالرجوع  $L$  خطوة زمنية سابقة لعدة بارامترات كما في العلاقة أعلاه مع الانتباه إلى أن كل من  $X, E$  تمثل أشعة من البعد  $n$ ، و  $A$  تمثل مصفوفات من البعد  $n * n$  لكل الخطوات الزمنية المدروسة. وبنفس الطريقة أعلاه وتكون السلسلة الزمنية  $X_i$  مؤثرة في سلسلة زمنية أخرى  $X_j$  إذا وجد على الأقل عنصر واحد أكبر من الصفر في عناصر المصفوفات  $A_t(j,i)$ ، من أجل كل  $L, t=1, \dots, L$ .

### 3-7-1- استنتاج السببية من مصفوفة أوزان الشبكة العصبونية العودية

ترتبط أوزان الشبكة العصبونية بين الدخل والخرج بقيم تحدد مدى تأثير الخرج بكل عنصر من عناصر شعاع الدخل. بالتالي نظرياً نستطيع استنتاج علاقة (سبب - أثر) من مصفوفة الأوزان. وتكمن صعوبة استنباط العلاقات السببية بين عناصر الدخل والخرج بسبب طبيعة مصفوفة الأوزان المتشابكة بين العصبونات في

الطبقات المخفية، لذا من المهم معرفة أوزان كل عنصر في شعاع الدخل خلال الخطوات الزمنية المدروسة lagged، لتحديد أثرها على عناصر الخرج.

إن مصفوفة الأوزان تعطي قيماً مختلفة لكافة عناصر شعاعي الدخل والخرج وبذلك فهي لا تستطيع تحديد فيما لو كان دخل معين لا يؤثر في خرج ما وبالتالي عدم وجود علاقة (سبب، أثر) بينهما، لذا يمكن تطبيق طريقة lasso التي تستخدم في تنظيم التبعر Regularization Sparsity على مصفوفة أوزان الشبكة العودية أثناء التدريب، بهدف تحديد عناصر الدخل ذات العلاقة بخرج معين، من خلال اختيار مجموعة عناصر الدخل ذات الأثر الأكبر لعنصر الخرج، وحذف عناصر الدخل التي ليس لها أثر في قيمة الخرج.

تعطى صيغة تنظيم التبعر الخطية بالصيغة التالية:

$$\min_{w \in R^d} \frac{1}{n} \sum_{i=1}^n V(y_i, \langle w, x_i \rangle) + \lambda \|w\|_0$$

حيث  $\|w\|_0$  تحدد عدد القيم غير الصفرية في الشعاع  $w$ .

نقول عن المقدار  $f(x) = \langle w, x_i \rangle$  أنه مبعثر إذا كانت القيمة  $\|w\|_0 = s < d$ . هذا يعني أننا نستطيع كتابة علاقة الخرج بمجموعة جزئية من عناصر الدخل.

أما فيما يخص تحليل السببية في مصفوفة أوزان شبكة LSTM، نستخدم ما يدعى Sparse Graphical Model حيث ننظر إلى مصفوفة الأوزان كبيان graph وتمثل عقد البيان nodes، البارامترات وتعبر الوصلات edges عن وجود ارتباط شرطي بين العقد، وللتحقق من ذلك يتم حساب مصفوفة مقلوب مصفوفة التغيرات لمصفوفة الأوزان وكل خلية غير صفرية في مصفوفة المقلوب لأنها تعبر عن وجود ارتباط شرطي بين البارامترين الموافقين للخلية، أما القيم الصفرية فتعبر عن استقلال شرطي للبارامترين الموافقين للخلية، بينما تعبر مصفوفة التغيرات عن وجود ارتباط غير شرطي بين البارامترات أي ليس بالضرورة أن يعتمد بارامتر على آخر بشكل مباشر. وهكذا نحصل على بيان العلاقات السببية بين البارامترات في مصفوفة الأوزان.

في الشبكات العودية التقليدية RNN نقول إن أحد بارامترات الدخل  $i$  لا يؤثر ببارامتر خرج  $z$  إذا كان عمود الأوزان لبارامتر الدخل  $i$  في مصفوفة الأوزان  $w$ ، قيمته "0" من أجل جميع الخطوات الزمنية  $K$ . [19]

وبالمثل، في شبكة LSTM نحصل على 3 مصفوفات أوزان، مصفوفة أوزان الدخل، ومصفوفة الأوزان العودية، ومصفوفة الانحياز. أما مصفوفة أوزان الدخل فتتكون من 4 مصفوفات فرعية. تتوضع المصفوفات عمودياً بالترتيب التالي: مصفوفة أوزان الدخل، ومصفوفة بوابة النسيان، ومصفوفة القيم المرشحة، ومصفوفة أوزان الخرج، لكل من المصفوفات الثلاث [22].

$$w = \begin{bmatrix} w_i \\ w_f \\ w_c \\ w_o \end{bmatrix}, \quad R = \begin{bmatrix} R \\ R_f \\ R_c \\ R_o \end{bmatrix}, \quad b = \begin{bmatrix} b_i \\ b_f \\ b_c \\ b_o \end{bmatrix}$$

ونقول إن أحد بارامترات الدخل  $i$  لا يؤثر ببارامتر خرج  $j$  إذا كان عمود الأوزان لبارامتر الدخل  $i$  في مصفوفة أوزان الدخل  $w$ ، قيمته 0 من أجل جميع الخطوات الزمنية  $K$ . [19]

**ملاحظة 1:** لا يعطي تطبيق تنظيم "L2" Ridge نفس النتيجة كونه لا يقوم بالتخلص من البارامترات التي يمكن الاستغناء عنها، والشيء نفسه في حال عدم استخدام عامل تنظيم في الشبكة، حيث نحصل في الحالتين السابقتين على بيان كامل غير موجه ويتوجب حينها اللجوء إلى إحدى طرق كشف السببية من النماذج البيانية [23]

**ملاحظة 2:** ركزنا في البحث على استنتاج العلاقات السببية فقط من مصفوفة أوزان الشبكات العصبونية العودية ذلك أن الطرق الأخرى التي أتينا على ذكرها متشابهة كونها نماذج تعلم خطية ويمكن التعامل معها بنفس الأسلوب بينما تابع التفعيل في الشبكات العصبونية المختارة هنا غير خطي.

#### 4-7-1- عامل التنظيم LASSO وعامل التنظيم RIDGE

يعتمد كلا عملي التنظيم أساساً على الانحدار الخطي Linear Regression. يستخدم عامل التنظيم L1 LASSO Regularization في كل من علم الإحصاء والتعلم التلقائي بهدف اختيار البارامترات Variable Selection وتحسين التنبؤ وتفسير نتائجه بجعل قيم المعاملات التي يمكن الاستغناء عنها صفراً. واستخدم بداية على نماذج التنبؤ الخطي من بسبب قدرته على تعديل النموذج المستخدم بتحديد المجموعة الأفضل من البارامترات التي تؤثر في الخرج بدلاً من استخدامها جميعاً، وأيضاً يمنع الوصول لحالة التعلم الزائد .Overfitting.

أما عامل التنظيم Ridge Regularization L2 فيشبه كثير عامل تنظيم L1 ولكنه لا يستطيع التخلص من البارامترات الزائدة بسبب أنه يعتمد مربعات الأوزان وبالتالي لا ينعلم المعامل عند اشتقاق تابع الكلفة. وإنما فقط يمنع حالة التعلم الزائد من الحدوث. [24]

$$\begin{array}{l}
 \text{L1 Regularization} \\
 \text{Cost} = \sum_{i=0}^N (y_i - \sum_{j=0}^M x_{ij} W_j)^2 + \lambda \sum_{j=0}^M |W_j| \quad * \\
 \\
 \text{L2 Regularization} \\
 \text{Cost} = \underbrace{\sum_{i=0}^N (y_i - \sum_{j=0}^M x_{ij} W_j)^2}_{\text{Loss function}} + \lambda \underbrace{\sum_{j=0}^M W_j^2}_{\text{Regularization Term}} \quad **
 \end{array}$$

#### 1-7-5- تمثيل بيان العلاقات السببية اعتماداً على مصفوفة أوزان الشبكة المعدلة

يمكن اعتماداً على مصفوفة المعاملات الناتجة من إحدى الطرق السابقة إنشاء بيان موجه حول العلاقات السببية بين البارامترات. حيث تمثل البارامترات عقداً للبيان الموجه ويمثل قيمة الارتباط في المصفوفة وصلة بين العقدتين موجهة من البارامتر في الخطوة الزمنية السابقة إلى الخطوة الزمنية التالية وتمثل حينها قيمة الارتباط في المصفوفة الناتجة كمية المعلومات المتبادلة بين البارامترات في نفس الخطوة الزمنية وكمية المعلومات المنقولة عبر الخطوات الزمنية من الأقدم إلى الأحدث [18]، وبسبب أن الطرق السابقة لاستنتاج العلاقات السببية، خطية فإنه من الممكن اعتبار كمية المعلومات المتبادلة أو المنقولة بين العقد أوزاناً في البيان الموجه وذلك بحسب تعريف الوزن من حيث أنه ثابت ضرب multiplicative constant [25].

# الفصل الثاني

## الدراسة المرجعية

### 1-2- تمهيد

تقدمت الكثير من الأبحاث في السنوات الأخيرة في مجال توقع الأعطال عن طريق كشف الشذوذات ومعالجة تدفق المعطيات بشكل عام وتحليل بارامترات الطيران بشكل خاص وتنوعت التقنيات المستخدمة للتعامل مع هكذا نوع من المسائل الذي يحتوي عدد من الحساسات المختلفة تولد بمرور الزمن أحجام كبيرة من المعطيات ويتم تحصيل قيمها بترددات ثابتة في حالتها حركة (Stream) وسكون (Batch) المعطيات. نذكر من هذه الأبحاث:

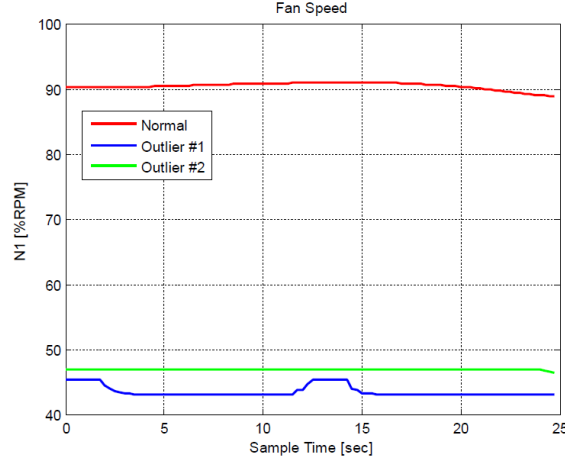
### 2-2- كشف مواطن الخلل في معطيات محرك الطائرة

#### Anomaly Detection of Aircraft Engine Data in FDR [26]

يهدف هذا البحث إلى كشف الأعطال التي حصلت على محرك طائرة نقل، وذلك بعد نهاية الرحلة. يقوم البحث على استخدام مجموعة ضخمة من تسجيلات رحلات الطيران (ملفات FDR) مقدمة من وكالة NASA ناسا وعددها 3.328 ملف. يحتوي كل ملف من هذه الملفات على 168 بارامتر، تم اختيار ما يكفي لمعالجة المسألة من البارامترات الخاصة بالمحرك، عددهم 11 بارامتراً من خلال خوارزمية PCA وحساب مصفوفة الترابط لتخفيض الأبعاد وتبسيط كلفة الحسابات والاستغناء عن البارامترات غير المؤثرة. اعتمد البحث طريقة تعلم من دون إشراف، باستخدام تقنية العنقدة المعتمدة على الكثافة مع ضجيج باستخدام خوارزمية DBSCAN بسبب قدرتها على كشف الشذوذات. وتحددت بارامترات العنقدة تجريبياً بشكل يدوي عدد نقط الجوار  $N_{min}=5$ ، ونصف قطر دائرة الجوار  $e=3$ ، حيث كان من الأفضل استخدام إحدى الطرائق المتبعة في تحديد هذه البارامترات مثل خوارزمية BIC أو Cross Validation، واستخدمت المسافة الإقليدية لقياس مقدار التشابه بين معطيات الرحلات.

أظهرت نتائج البحث ثلاث عناقيد الأولى تظهر الرحلات في الحالة الطبيعية والتي لم يحصل فيها أعطال، والثانية تظهر الرحلات التي حصل في خلل في أداء المحرك تم كشفه من خلال تغيرات كبيرة في كل من درجة حرارة وضغط الزيت، أما العنقود الثالث يضم الرحلات التي حصل فيها خلل في أداء المحرك من خلال

كشفت تغيير مفاجئ في سرعة دوران مروحة المحرك. أما الشذوذات الموجودة فتتعلق بتغيرات غير طبيعية في البارامترات أثناء دوران المحرك ويوضح الشكل (16) الفرق بين الحالة الطبيعية لنسبة النقل N1 بين دوران المحرك والمروحة وانخفاض تلك النسبة في حالة الكشف عن شذوذ قد يدلنا على عطل في المحرك.



الشكل 16- جزء من اختبارات خوارزمية DBSCAN في الكشف عن الشذوذات بين مجموعة من الرحلات

نلاحظ أن الطريقة المقدمة هنا أظهرت نتائج جيدة وفقاً للبارامترات المدروسة، وبمنظرة أعمق فإن هذه البارامترات بعضها يرتبط ببعض بعلاقات فيزيائية وبالتالي فإن حدوث تغيير في قيمة أحدها سيؤثر في قيم بعض البارامترات الأخرى، دون الاهتمام بالزمن فمصفوفة الترابط لا تعطي مؤشراً حول البارامترات التي يظهر أثر ترابطها بتقدم الزمن بل تبين فقط وجود علاقة إيجابية أم سلبية بينها. من ناحية أخرى نجد أن هذه الطريقة تصلح لمعالجة المعطيات في حالة السكون، ولا تعمل في الكشف المبكر عن الأعطال ويقتصر عملها في المساعدة على تحديد الصيانات الشرطية والتحقيق في الحوادث بعد حصولها.

### 3-2- نمذجة سلاسل الطيران، مقارنة بين VAR و LSTM

#### Multivariate Aviation Time Series Modeling: VARs vs. LSTMs [27]

اهتم البحث بإجراء مقارنة بين أداء تقنيتي LSTM و VAR ودقة تنبؤ كل منها لخطوة واحدة و عدة خطوات بالسلاسل الزمنية المتعددة وانتهى البحث بتفضيل VAR على LSTM في ذلك. في البداية قدم البحث لمحة عن كل من التقنيتين واستخدامات كل منهما، وبعض الدراسات المشابهة والرديفة، ثم التجارب التي قام عليها البحث بالعودة إلى 10 خطوات سابقة  $\text{time lag} = 10$ ، ومجموعة بيانات حقيقية واصطناعية.

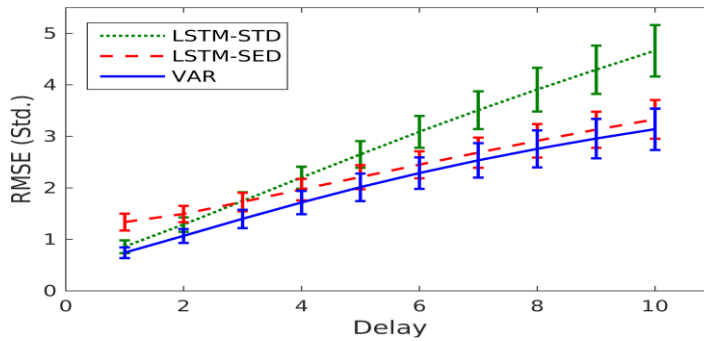
مجموعة بيانات التدريب تحوي حوالي 300 تم اختيار 42 بارامتراً فقط، بتردد 1Hz خلال الرحلة. البارامترات مستمرة ومتقطعة، وتم اختيار العمل ضمن ارتفاع أقل من 1000 قدم حتى ملامسة العجلات للأرض عند الهبوط، وكان حجم مجموعة البيانات 77000 حيث قسمت إلى مجموعتي تدريب واختبار بنسبة 10:1. وتم توليد مجموعة معطيات مشابهة للرحلات الحقيقية بعدد بارامترات يساوي 42 بارامتراً مستمراً. وبحجم يساوي حجم المجموعة السابقة وبنفس التقسيم لمجموعتي تدريب واختبار. وتم تقييس مجموعات المعطيات باستخدام طريقة min-max normalization.

بالنسبة لتقنية VAR يكون عدد البارامترات من أجل شعاع دخل مكون من 42 عنصر يكون حجم بارامترات التعلم  $10d^2$  أي 17640 بارامتر.

أما من أجل شبكة LSTM تم استخدام نمطين من بنيان الشبكة وبعده وحدات مخفية مختلفة مع تابع تفعيل ReLu وبنفس عدد عناصر شعاع الدخل المستخدم في VAR ويكون عدد البارامترات 30442 بارامتر.

يظهر في الشكل (19) تفوق VAR عند التنبؤ لخطوة واحدة للأمام وعند التنبؤ لخمس خطوات زمنية أي 5 ثوانٍ للأمام ثم أعيدت التجربة لأجل 10 خطوات زمنية، حيث يبدأ الخطأ بالازدياد بشكل تراكمي يتوضح بالشكل (17). وتم قياس الخطأ باستخدام جذر متوسط مربعات الأخطاء RMSE Root Mean Squared Error يحوي الشكل (18) جدولاً بقيم الخطأ لكل نموذج.

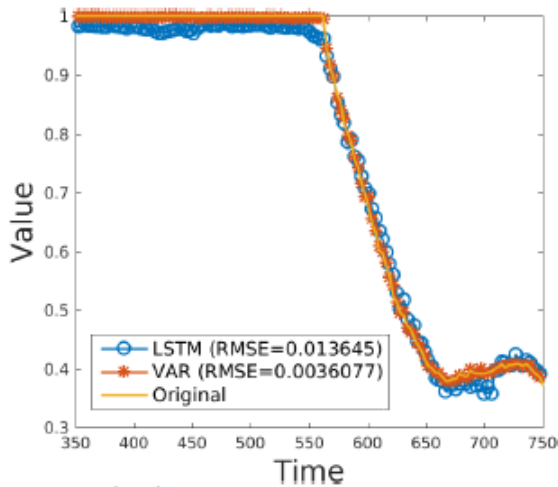
وأظهر البحث النتائج التالية:



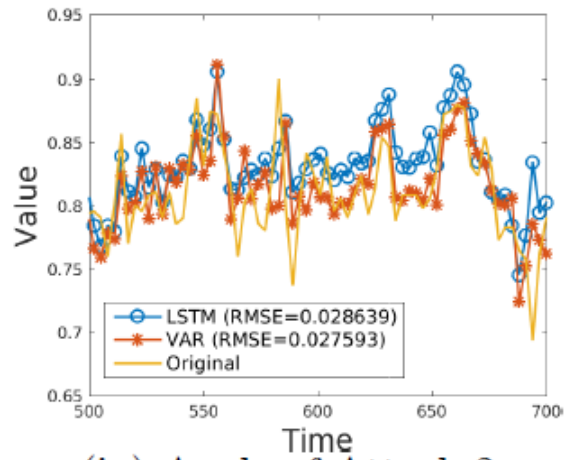
الشكل 17- نمو الخطأ مع الزمن في كل من النماذج

Model	Delay					
	1	2	3	4	5	10
VAR	0.752*(0.103)	1.093*(0.130)	1.439*(0.173)	1.767*(0.220)	2.073*(0.263)	3.138*(0.402)
LSTM-STD	0.867 (0.120)	1.304 (0.137)	1.769 (0.169)	2.236 (0.205)	2.694 (0.246)	4.663 (0.501)
LSTM-SED	1.105 (0.160)	1.319 (0.163)	1.607 (0.185)	1.914 (0.209)	2.209 (0.231)	3.329 (0.375)

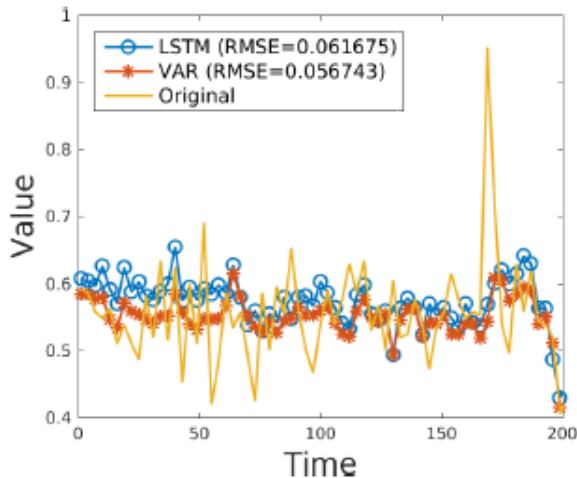
الشكل 18- قياس RMSE لكل خطوة مستقبلية في كل من النماذج الثلاث



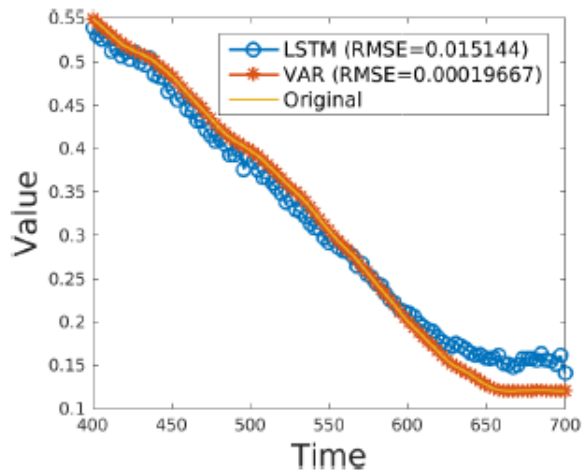
(iii) Radio Altitude



(iv) Angle of Attack 2



(i) Altitude Rate



(ii) Baro Correct Altitude

الشكل 19- جزء من الاختبارات لكل من نمونجي LSTM, VAR

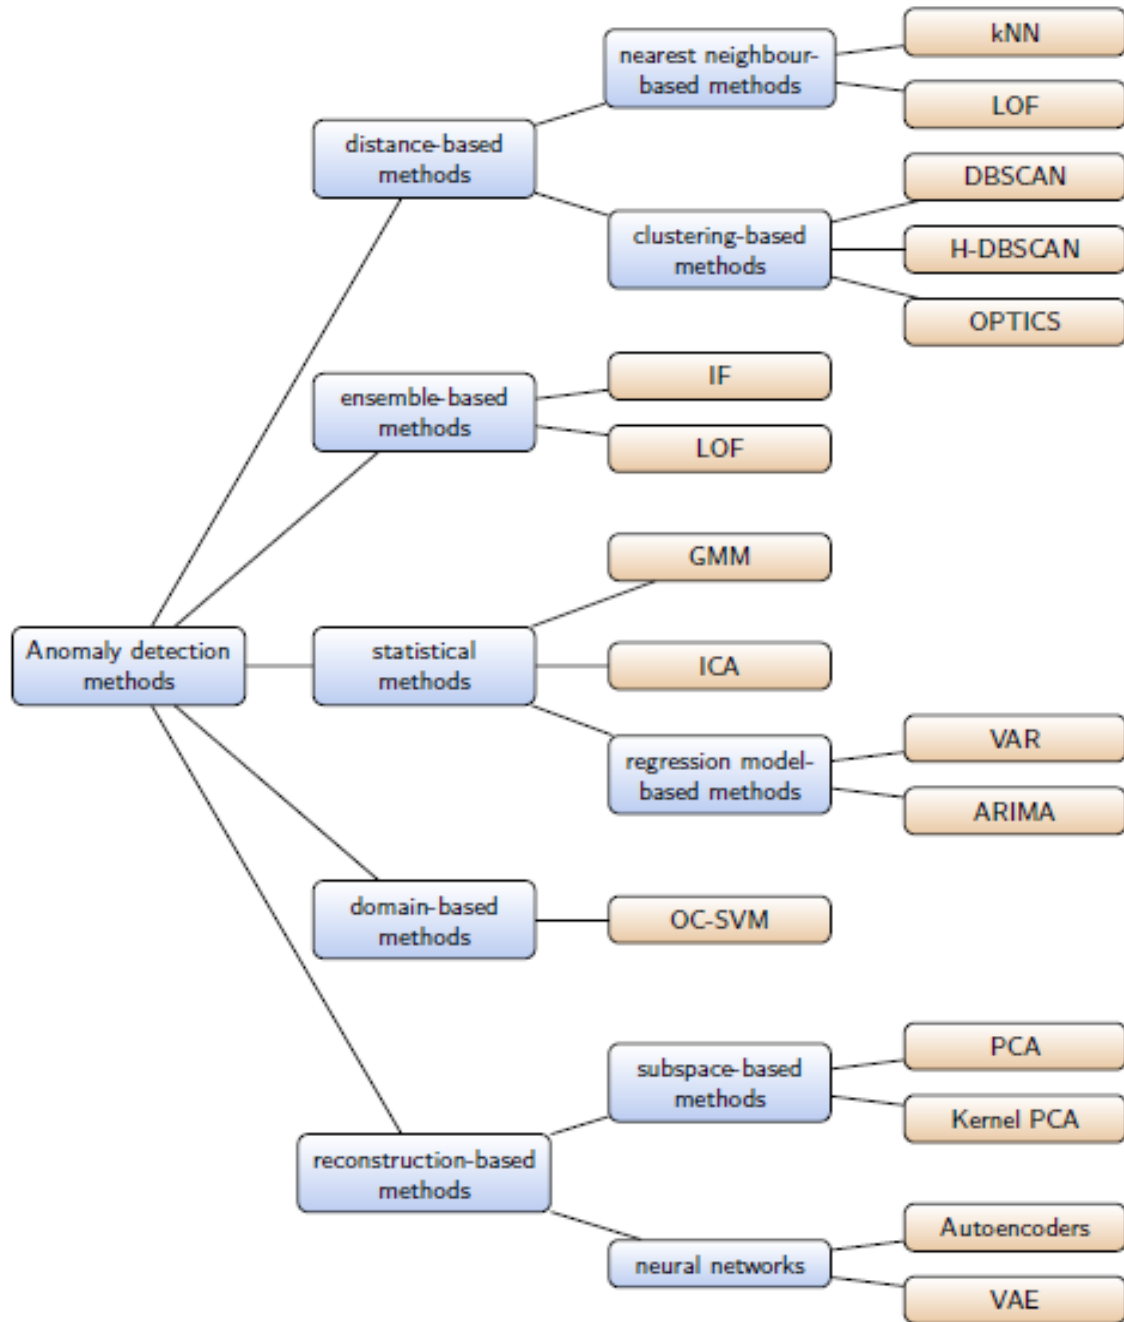
أظهر البحث قدرة تقنية VAR الخطية على التنبؤ لمسائل غير خطية بالمقارنة مع شبكة LSTM. ولكنه أغفل المعالجة الأولية التي قام بها للوصول إلى تلك النتائج وفيما لو كانت السلسلة مستقرة أم لا عند تدريب شبكتي LSTM حيث من المعلوم قدرة الشبكة على التعامل مع سلاسل زمنية غير مستقرة. أيضاً كان من الممكن تحديد عدد خطوات زمنية أكبر للتنبؤ وبشكل أوتوماتيكي لتحديد قدرة VAR بشكل أدق. أي لم نستطع معرفة فيما لو كانت ستبقى هذه التقنية بنفس الفعالية، خاصة أنه لم يذكر مجالات الأخطاء المسموحة!

#### 4-2- الطرائق الحديثة في كشف الشذوذات في تطبيقات مجال الطيران

##### Recent Advances in Anomaly Detection Methods Applied to Aviation [28]

تقدم المقالة دراسة استقصائية Survey حول آخر الطرائق المعتمدة على المعطيات والمطبقة في مجال الطيران للكشف عن الشذوذات في معطيات أنظمة الطائرة شكل (20)، وشكل (21) من خلال تعريف بأنواع الشذوذات (النقطية، والسياق، الجماعية)، والتركيز على الشذوذات بحسب السياق والشذوذات الجماعية كونها تحدث في السلاسل الزمنية.

بينت الدراسة أن الشذوذات التي تظهر في مسائل التنبؤ بهدف الصيانة الوقائية تتم بطرق إحصائية، كما في حال موضوع بحثنا هذا، ويتم تحديد الشذوذات عن طريق دراسة فروقات الأخطاء بين قيم التنبؤ والقيم الحقيقية على نوافذ زمنية. أما تحديد شذوذات الطيران حسب السياق فيتم بحساب ما يسمى سياق قيم البارامترات، وهو يعتمد بشكل أساسي على تحديد مرحلة الطيران phase of flight (إقلاع، مناورات، هبوط، إلخ...)، وعلى قيم مجموعة من البارامترات المرتبطة به.



الشكل 20- الطرق العامة الكلاسيكية في الكشف عن الشذوذات

Section 4.1.1 Domain-based	<i>Abnormal approaches with MKAD: [104] (2011)</i> <i>GA approach and landing anomalies with OC-SVM: [105] (2017)</i>
Section 4.1.2 Distance-based	<i>Anomalous pilot switching with SequenceMiner: [18] (2008)</i> <i>Anomalous take-off and approach operations: [19] (2011), [20] (2015)</i> <i>Anomalous safety events with LoOP: [16] (2019)</i> <i>Anomalous taxi paths with hierarchical clustering: [22] (2019)</i> <i>Anomalous radiotelephony readbacks with kNN: [106] (2018)</i>
Section 4.1.3 Reconstruction-based	<i>Atypical aviation safety data with KPCA: [107] (2017)</i> <i>Atypical approaches and landings with FPCA: [52] (2018)</i> <i>Anomalous trajectories in TMA and en-route: [108] (2018), [109] (2019)</i> <i>Anomalous transitions between sector configurations: [110] (2018)</i> <i>Anomalous ADS-B messages with ConvLSTM-AE: [86] (2019)</i>
Section 4.1.4 Statistical-based	<i>Anomalous flights with VARX: [38] (2016),</i> <i>Anomalous flight switches with VAR: [39] (2016)</i> <i>Abnormal flight data with GMM: [21] (2016)</i> <i>Anomalous air traffic congestion with ICA: [37] (2019)</i>
Section 4.1.5 Temporal-logic based	<i>Anomalous trajectories in terminal airspace with TempAD: [103], [111] (2019)</i>


الشكل 21 – طرق كشف الشذوذات المستخدمة في تطبيقات الطيران المختلفة

## 5-2- تحليل السببية في السلاسل الزمنية غير الخطية باستخدام الشبكات العصبونية

### Neural Granger Causality for Nonlinear Time Series [19]

استطاع مقدمو البحث من استخراج علاقة السببية Granger Causality غير الخطية من البارامترات من مصفوفة أوزان الشبكة العصبونية، وذلك لكل من شبكة MLP، وشبكة LSTM وذلك باستخدام تطبيق مرشح غير خطي لتنظيم البعثرة Group lasso على مصفوفة الأوزان مما يؤدي إلى جعل بعض قيم الأوزان تساوي 0 وهذا يعني أن الدخل المتعلق بالوزن الصفري لا يؤثر بالخرج أي ليس سبباً له Granger Non Causal. فقرة 1-7-1.


تم بناء عدة شبكات عصبونية لكل مجموعة من مجموعات توابع مرشح البعثرة group lasso لتسهيل عملية فصل المؤثرات بين الدخل والخرج، وتمت الدراسة على أوزان الطبقة الأولى المخفية من طبقات MLP والموضحة بالشكل (22) فإذا كان العمود  $z$  في مصفوفة أوزان الطبقة الأولى يحوي قيمة صفرية لأجل كل القيم الزمنية في السلسلة  $i$  تكون السلسلة  $z$  لا تؤثر في السلسلة  $i$ . أما من أجل شبكة LSTM فقد تم دراسة أوزان الدخل مصفوفة الأوزان التي تتكون من 4 مكونات كما ذكر سابقاً.



الشكل 22- مخطط توضيحي لبنية شبكة MLP للكشف عن السببية من خلال أوزان الطبقة المخفية الأولى لكل دخل

تم اختبار الخوارزمية على مجموعة معطيات MoCap تمثل حركة جسم الإنسان باستخدام 54 نقطة مفصلية بالإضافة إلى مواضع الجسم خلالها لخطوات زمنية قدرها 2024 خطوة ويظهر الشكل (23) بيانات Graphs العلاقات السببية مع عوامل تنظيم  $\lambda$  مختلفة في مجموعة بيانات MoCap بحيث تمثل العقد مواضع المفاصل لجسم الإنسان. استطاعت الخوارزمية كشف اعتمادية مناطق الجسم المختلفة على بعضها خلال الحركة، بعدة عيارات للشبكتين العصبونيتين المختارتين.

قدم هذا البحث طريقة فعالة في الكشف عن العلاقات السببية بتحديد العلاقات اللاسببية بين البارامترات وحذفها من البيان الناتج، ولكنها لم تقدم طريقة لتحديد عدد الخطوات الزمنية بين بارامتر المؤثر والنتيجة. فالسبب يسبق النتيجة كما نعلم.

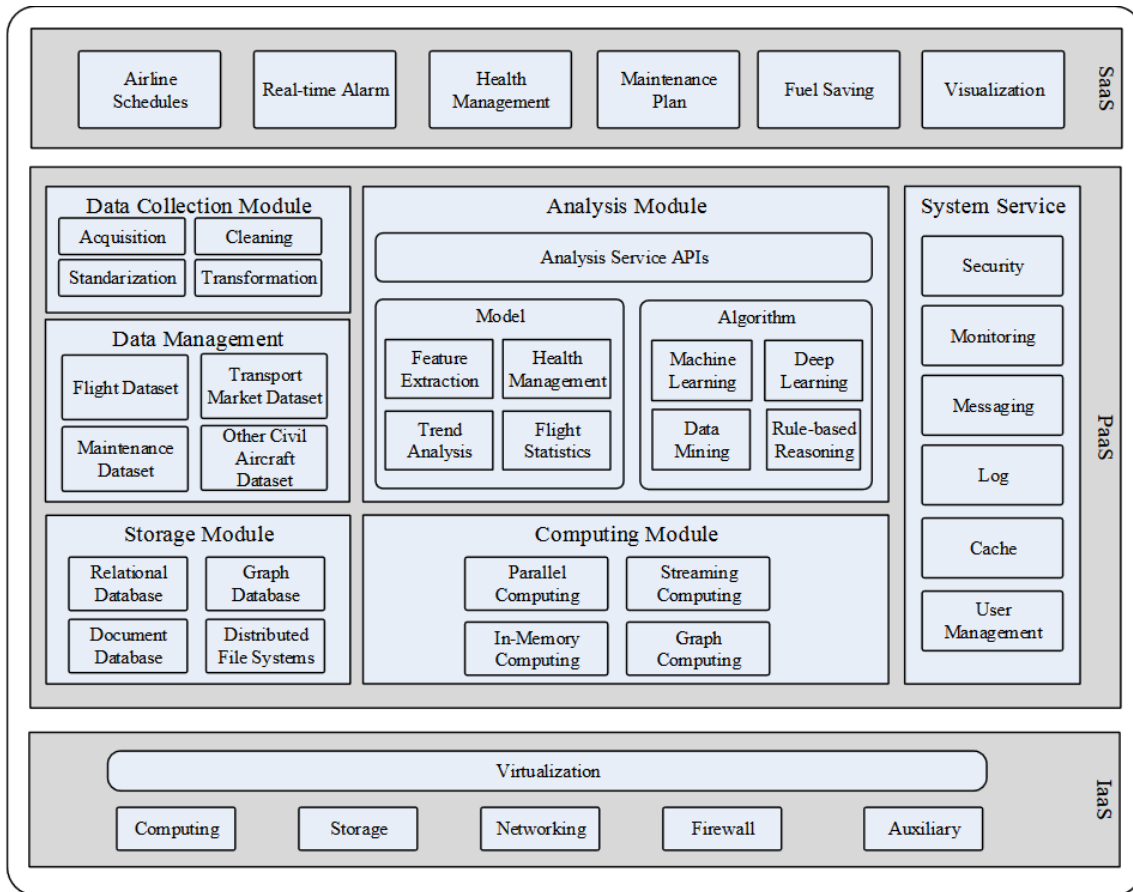


الشكل 23 - جزء من اختبارات خوارزمية كشف اللاسببية بين البارامترات من أجل عوامل تنظيم  $\lambda$  مختلفة

## 6-2- منصة المعطيات الكبيرة للطيران المدني

### Civil Aircraft Big Data Platform [29]

قدمت المقالة بنية متكاملة هدفها تقديم معظم الخدمات في مجال الطيران ضمن خدمات الحوسبة السحابية، من بنية حساب وتخزين وحماية واتصال وغيرها من التجهيزات المساعدة في طبقة IaaS. أما في طبقة PaaS نستفيد من الإمكانيات لجميع المعطيات من مختلف المصادر ومعالجتها مبدئياً إلى تحليلها من خلال بناء نماذج بحسب الخدمة التي يحتاجها المستثمر باستخدام تشكيلة من خوارزميات تعلم الآلة وتنقيب المعطيات واعتماداً على نماذج المعالجة كالمعالجة في الزمن الحقيقي أو قرب الحقيقي بشكل تفرعي أو موزع باستخدام معالج كرت الفيديو. وتقدم هذه المعالجة مغلقة بشكل موثوق وآمن لتنفيذ الخدمة المطلوبة.



الشكل 24 – منصة نظام متكامل لتقديم خدمات في مجال الطيران ضمن بيئة معطيات كبيرة

## الفصل الثالث

# النموذج المقترح لنظام مراقبة بارامترات طائرة خفيفة

### 1-3- تمهيد

يعتمد بناء نموذج الحل على الإجابة عن بعض الأسئلة الهامة أهمها تحديد نمط العمل في حالة سكون المعطيات أم حركتها، أم كليهما؟ بالإضافة إلى تحديد طبيعة السلسلة الزمنية المدروسة وتحديد خطوات المعالجة الأولية التي يجب أن تطبق على البارامترات.

يتضح مما سبق أن المعالجة في مسألة البحث هنا تتم في حالة حركة المعطيات. كما يعتمد النموذج على طبيعة السلسلة الزمنية فهي غير نمطية في نفس الرحلة وتحتوي بعض العشوائية سببها تحكم الطيار ببارامترات الدخل بالإضافة للضجيج الناتج عن الاهتزازات أثناء الحركة. ويجب الانتباه إلى وجود اتجاه عام متزايد أو متناقص في السلسلة الزمنية Trend مثلاً أثناء الإقلاع والهبوط. أما كسلوك فيزيائي فهي متشابهة مع الرحلات الطيران لطائرة من نفس النوع. ولتسهيل العمل نفترض عدم وجود انقطاعات في تحصيل المعطيات من الطائرة ولذلك تم تحصيل المعطيات من مقلد طيران X-Plane 10.

### 2-3- طبيعة السلسلة الزمنية للمسألة المطروحة

إن السلسلة الزمنية المدروسة هي سلسلة زمنية متعددة البارامترات تحوي بارامترات فنوية Categorical مثل وضعية مفتاح القلاب، ثنائية Binary مثل الفرامل، مستمرة Continuous كالسرعة والارتفاع ودرجة الحرارة إلخ...


ومن المهم الانتباه إلى الخلط الذي يمكن أن يحصل أثناء المعالجة الأولية والذي قد يؤدي إلى إزالة بعض البارامترات الهامة كالفنوية أو الثنائية أو بعض البارامترات المتطابقة التي تمثل جزءاً من بعض أنظمة الطائرة. مثلاً من المهم معرفة أن الطيار في الطائرة الخفيفة قد يقوم برحلة طيران كاملة دون أن يستخدم القلابات<sup>7</sup>، ولكن في حال استخدمها فهي تؤثر في سلوك الطائرة.

<sup>7</sup> القلابات جزء متحرك على الجناح يتم تحريكه للتحكم بالرفع والكبح الناتجين عن الجناح (زيادة الرفع عند الإقلاع أو زيادة الكبح عند الهبوط)، أي هناك قلابة على كل جناح تتحرك على حافته الخلفية للأسفل بشكل متساوٍ بين القلابتين.

في مجموعة التدريب سنجد أن هناك بارامترين يعبران عن حركة القلابة ولكن كل منهما يمثل جزءاً متناظراً لنظام القلابات في الطائرة في الجانبين الأيمن والأيسر.

أيضاً نذكر الجنيحان الأيمن والأيسر في الطائرة وهما زوج من السطوح الرافعة على الجناح (جنيح على كل جناح)، يتحكمان بدوران الطائرة حول محورها الطولي ويتم التحكم بهما عن طريق عصا القيادة. أما حركتهما فعكسية ولكنها قد تكون غير متساوية بحسب نوع الطائرة. وبحسب الهدف من المشروع يكون من الخطأ إزالة مثل تلك البارامترات أثناء المعالجة الأولية لمجموعة التدريب.

ننوه أيضاً إلى الفارق بين دخل نموذج الطائرة ودخل نظام التنبؤ المقترح، حيث تعتبر أوامر تحكم الطيار متمثلة بعصا القيادة ومقود التحكم بالمحرك دخلاً لنظام الطائرة، أما دخل نموذج التنبؤ المقترح فيضاف إليه شعاع حالة الطائرة كتغذية راجعة.



الشكل 25 - تمثيل لحركة البيانات في نموذج مقلد طيران يمثل خرجه دخلاً للنموذج المقترح

### 3-3- النموذج المقترح لمسألة البحث

يوضح الشكل (27) المخطط الصندوقي لسلوك نموذج الحل المقترح في مراقبة بارامترات طائرة خفيفة بالاعتماد على تحليل الأخطاء التي يتنبأ بها النظام مقارنة بالقيم الحقيقية التي يتم تحصيلها من الطائرة بعد كشف ترابطات البارامترات السببية بين الدخل والخرج مما يمكن مستقبلاً من رفع سوية أمان الطائرة، من خلال الكشف المبكر عن وجود عطل ما. ويتكون النموذج من 5 مراحل كما يلي:

#### 3-3-1- المعالجة الأولية لبارامترات الدخل

##### 1- تردد أخذ العينات Sampling rate

إن طبيعة السلسلة الزمنية المدروسة في مسألة البحث متعددة البارامترات multi-variate، وهذه البارامترات تنقسم، بشكل عام إلى: سريعة، وبطيئة من حيث سرعة تغيرها خلال الرحلة وبالاعتماد على أن الحركة الطولية للطائرة لها نمطي حركة طويلة وقصيرة الدور. وبالرغم من أن بعض

تجهيزات العدادات الإلكترونية تظهر عدة ترددات مختلفة من مضاعفات 2 بين 1 إلى 16 عينة في الثانية بحسب طبيعة تغير البارامتر، ولكن التكيف مع عملية التعلم يوجب توحيد تردد أخذ العينات إلى أحد هذه الترددات على كل حال.

أما الترددات البطيئة فهي اقتصادية من حيث كلفة زمن التدريب وحجم التخزين، ولكنها قد تكون السبب في تسرب بعض الشذوذات التي قد تشير إلى أعطال هامة دون تحليلها، بينما الترددات السريعة تعطي دقة أكبر في الكشف عن القيم الشاذة عند تحليل البارامترات التي تتغير بسرعة مع الزمن، ولكنها تحتاج زمناً أكبر في التدريب وحجوماً أكبر للتخزين تكون أحياناً غير ذات فائدة عند تحليل البارامترات التي تتغير ببطء مع الزمن، وهذا ما دفعنا للتفكير بطريقة لاختزال الحجم الزائدة بدون التأثير على دقة المعالجة.

لتوصيف العينات بشكل جيد يمكن اعتماد عدد عينات  $N$  موافق لكل دور وسنفرض للحركة قصيرة الدور  $N=20$  فإذا كان دور نمط الحركة القصيرة  $T_s=2 \text{ sec}$  يكون الفاصل الزمني لأخذ العينات:

$$f_s = \frac{N}{T_s} = 10 \text{ hz} \text{ وتردد أخذ العينات الموافق } t_s = \frac{T_s}{N} = \frac{2}{20} = 0.1 \text{ sec}$$

دلت التجارب أن مدة تدريب 5 دقائق كافية لتدريب شبكة عصبونية على بارامترات الحركة قصيرة الدور ويوافق ذلك عدد عينات تدريب  $N_{tr} = t_{tr} * f_s = 5 * 60 * 10 = 3000$ .

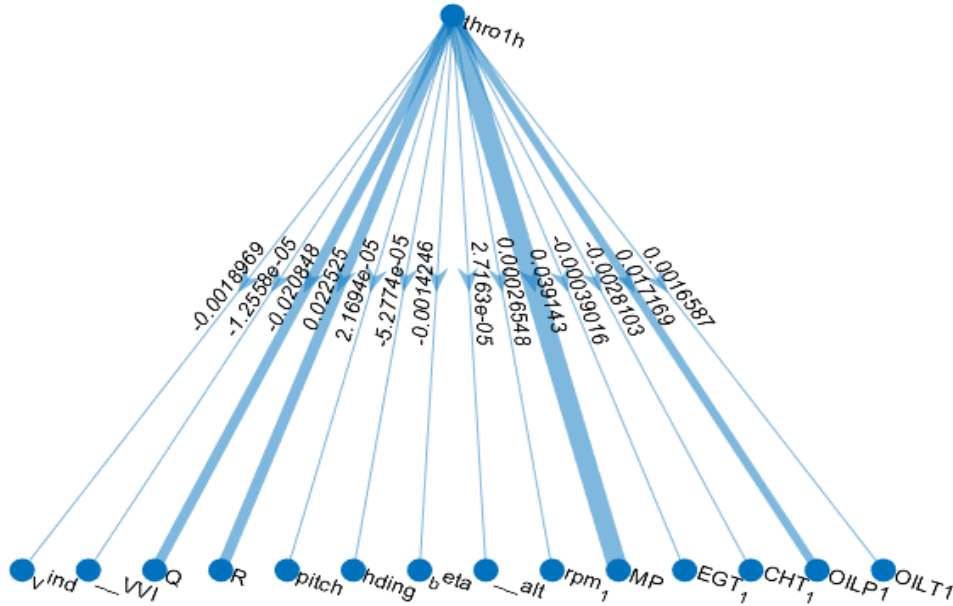
أما بالنسبة للحركة طويلة الدور نعتمد نفس عدد العينات خلال دور واحد  $N=20$  Resolution يكون  $t_l = \frac{T_l}{N} = \frac{120}{20} = 6 \text{ sec}$  حيث  $T_l$  دور الحركة طويلة الدور، يكون  $f_l = \frac{N}{T_l} = \frac{1}{6} \text{ hz}$  أي عينة كل 6 ثواني، وقمنا بزيادة تردد أخذ العينات لبارامترات الحركة طويلة الدور بسبب التردد العالي لأوامر الدخل للجملة وتم اعتماد  $f_l = 1 \text{ hz}$  أي عينة كل ثانية أي للحصول على 3000 عينة يلزم تسجيل 50 دقيقة، وبذلك تم تخفيض الحجم بالحركة طويلة الدور بالمقارنة مع الحركة قصيرة الدور 10 مرات!

## 2- انتقاء السمات Feature Selection

لانتقاء السمات أهمية كبيرة في الحصول على تمثيلات للبيانات في فضاء أبعاد أقل بعد التخلص من السمات الزائدة عن الحاجة، مع الحفاظ على خصائص مجموعة البيانات وما يمكن أن تخبئه من

معلومات مما يسهل تحليل البيانات وفهمها. هناك العديد من الطرق لاختيار السمات [31] [30] بعضها مع الإشراف وبعضها بدون إشراف، ولها عدة تصنيفات منها المرشحات كمرشح ترابط بيرسون، أو طريقة LASSO التي تم شرحها بالفصل الأول فقرة 7.

يمكن معرفة الارتباط بين كل أمر من أوامر التحكم التي يعطيها الطيار، على باقي بارامترات الخرج واستبعاد البارامترات الزائدة أو الضعيفة، بتطبيق طريقة LASSO لانتقاء السمات. في هذا البحث قمنا بالتركيز على اختيار البارامترات المتعلقة بالحركة الطولية بنمطها قصيرة وسريعة الدور، ويظهر الشكل (26) مثلاً عن البارامترات وعددها 14 التي تتأثر بدخل مقود التحكم بالمحرك Throttle من أصل 32 بارامتراً موضحة في الملحق المرفق. حيث تم حذف البارامترات التي قيمة تأثيرها تساوي 0، أما الوصلات السمكية في الشكل تدل على قوة التأثير بين العقدتين، والإشارة السالبة تدل على وجود علاقة عكسية بين العقدتين.

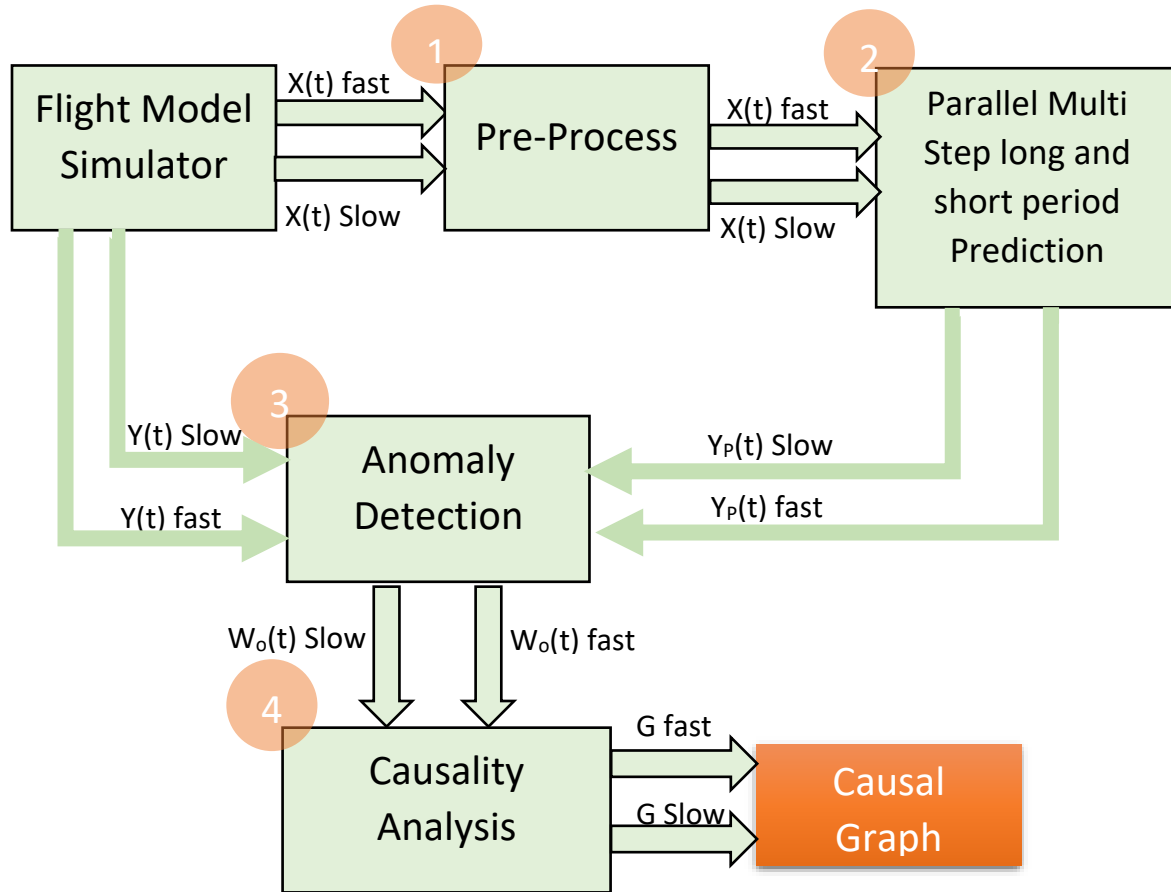


الشكل 26- تأثير أمر التحكم بالمحرك على 14 بارامتر خرج من أصل 26 باستخدام LASSO

**ملاحظة 1:** في حال قمنا باستخدام عامل التنظيم LASSO أثناء عملية التدريب ستقوم الشبكة بعملية انتقاء للبارامترات المؤثرة بشكل طبيعي وبالتالي ليس هناك داعٍ لعملية انتقاء السمات، أما بحالة عدم استخدامه أثناء التعلم فقد يؤدي إلى نتائج تنبؤ سيئة لتضمين بارامترات زائدة على عملية التعلم.

### 3- التقييس Standardization

تأتي أهمية هذه المرحلة من كون قيم البارامترات ذات مقاييس ووحدات مختلفة، مثلاً، يقاس الارتفاع بمئات وآلاف المترات، بينما يقاس انحراف عصا القيادة بالراديان، أما التحكم بالقلبات فليس له واحدة بينما انتقال القلابة إلى الموضع الذي يوافق أمر التحكم يقاس بالراديان أيضاً، وهكذا. وبالتالي نحتاج إلى التقييس لنلغي المعنى الفيزيائي من البارامترات من جهة ولنتخلص من انحياز معاملات التدريب باتجاه البارامترات ذات القيم الأكبر من جهة ثانية.



الشكل 27 - المخطط الصندوقي للنموذج المقترح

ومع أن طبيعة بعض البارامترات فنوية categorical وقد لا تتغير باستمرار على طول الرحلة، ولأن تلك البارامترات تؤثر على سلوك الطائرة كالقلبات، وكون التنبؤ يتم أثناء حركة البارامترات، فهذا يعني أن تلك البارامترات قد تكون ثابتة على طول دفعة التنبؤ batch إلا أن الحل الأفضل هو تقييسها أو ترك قيمتها كما هي وليس حذفها من مجموعة التدريب.

يمكن التقييس بالاعتماد على إحدى الصيغتين التاليتين:

$$1. \text{ Standardized value} = (X - \mu) / \sigma$$

حيث  $\mu$ ،  $\sigma$  هما المتوسط والانحراف المعياري لمجموعة التدريب.

$$2. \text{ Normalized value} = (X - \min_x) / (\max_x - \min_x)$$

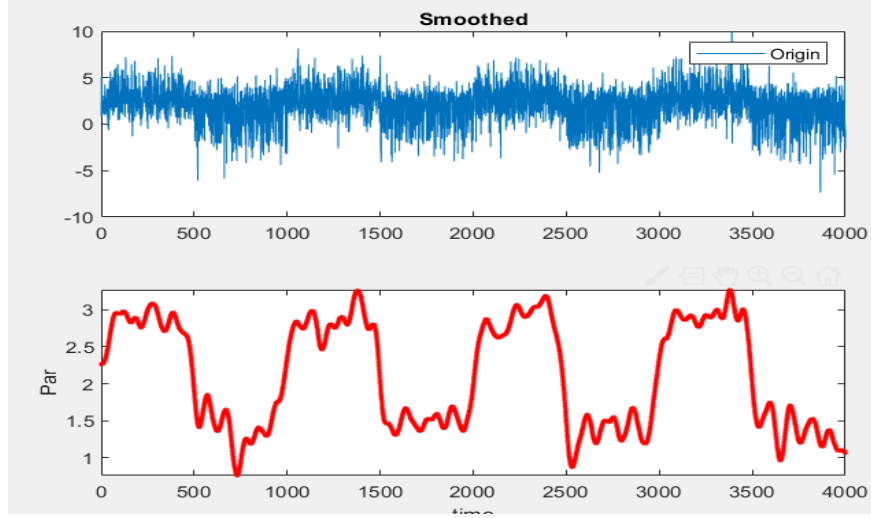
وفي الصيغة الأولى نحول توزيع قيم البارامترات إلى الوسطي 0 والانحراف المعياري 1، بينما في الصيغة الثانية نحول مجال القيم بين 0 و1.

تستخدم الصيغة الأولى عندما يكون لدينا معرفة مسبقة أو يمكننا افتراض أن المعطيات تخضع للتوزيع الطبيعي، طبعاً ليس من الضروري أن تكون كذلك ولكن هذه الطريقة أكثر فعالية عندئذٍ. تناسب هذه الصيغة خوارزميات التعلم التي تفترض التوزيع الطبيعي لقيم البارامترات مثل طرائق الانحدار الخطي linear regression، والانحدار اللوجستي logistic regression.

بينما تستخدم الصيغة الثانية بشكل فعال عندما لا يكون لدينا معرفة مسبقة عن توزيع قيم البارامترات فيما لو كانت تخضع للتوزيع الطبيعي أم لا [32]. استخدمنا الصيغة الأولى للتقييس في البحث للبارامترات المستمرة والصيغة الثانية للبارامترات الفئوية للتخلص من حالة عدم التعيين الناتجة عن انعدام الانحراف المعياري بسبب وجود قيمة وحيدة أحياناً للبارامترات الفئوية في دفعة المعالجة.

#### 4- إلغاء أثر الضجيج

ينتج الضجيج في الحالة الحقيقية عن الاهتزازات التي تؤثر على حساسات تحصيل المعطيات، ومن الضجيج الأبيض الغوسي سببه الأثر الكهربائي للتجهيزات. يمكن محاكاة الضجيج وإضافته إلى مجموعة بيانات التدريب للحصول على حالة أقرب للواقع، ونقوم بإلغاء أثره بعدة طرق منها استخدام مرشح غوسي GF Gaussian filter من خلال تابع `smoothdata(data, method, window)` في بيئة ماتلاب. واحتجنا لإلغاء الضجيج عند الاختبار على مجموعة بيانات MKAD التي تحوي بارامترات مع ضجيج ويظهر في الشكل (28) الشكل الأصلي للإشارة \_باللون الأزرق\_ مع ضجيج والإشارة \_باللون الأحمر\_ بعد حذف الضجيج بتطبيق مرشح غوسي وهي إشارة نمطية تشبه تتالي إشارات خطوة. حيث قيمة البارامتر في المحور العمودي والزمن بالميلي ثانية يمثله المحور الأفقي.




الشكل 28- إلغاء أثر الضجيج في مجموعة بيانات MKAD

#### 5- إلغاء الاتجاه العام Trend

إن طبيعة السلسلة الزمنية في نفس الرحلة الطيرانية تحوي اتجاهًا عامًا متزايدًا أثناء التسلق أو متناقصًا أثناء الهبوط. يظهر هذا الأثر جلياً في البارامترات ذات الحركة البطيئة كالارتفاع. وخلال دفعة يدل الاتجاه العام على تغير في وسطي البارامتر مما يؤثر على التنبؤ ويعطي نتائج خاطئة. ويمكن إلغاء الاتجاه العام بعدة طرق منها طرح المتوسط من جميع قيم البارامتر خلال الدفعة. أو باستخدام نموذج الانحدار regression. وتوفر بيئة ماتلاب باستخدام التابع  $detrend(data)$  إلغاء الاتجاه العام باستخدام صيغة least squares regression line.

تظهر بعض الدراسات أن شبكات RNN قادرة على التعامل مع السلاسل الزمنية غير المستقرة Non Stationary، وبالتالي لا داعي لإلغاء الاتجاه العام من السلسلة إلا عند الضرورة. [33]. ويبين الشكل (29) عدم قدرة شبكة LSTM على التنبؤ بشكل مقبول بقيم الارتفاع حيث تزداد قيمة الخطأ في الارتفاع وهو المحور العمودي في الشكل (29) مع الزمن بالملي ثانية في المحور الأفقي.



الشكل 29- التنبؤ بقيم الارتفاع بدون إلغاء أثر الاتجاه العام

### 2-3-3- التنبؤ لعدة خطوات زمنية

هناك عدة طرق في الأدبيات للتنبؤ تعاملنا مع ثلاث منها وهي LSTM, NARXNET, MVAR والتي شرحناها بالدراسة النظرية بالفصل الأول وبالتجارب تبين أن شبكة LSTM ذات أداء الأفضل ولذا استخدمناها بالنموذج المقترح أثناء تدفق البيانات وسنأتي عليها بتفصيل أكثر. بسبب الحجم الكبير لدخل الشبكة العصبونية الذي يتألف في البحث من دخل خطوتين سابقتين لجميع البارامترات الطيرانية، ولأن دخل الشبكة يجب أن يمثل دور نمطي الحركة الطويلة والقصيرة معاً والحركة الطويلة تحتاج إلى قيم متباعدة زمنياً كون بارامتراتنا تتغير ببطء مع الزمن، تم بناء شبكتين عصبونيتين، إحداهما لتوقع خرج البارامترات قصيرة الدور والثانية لتنبؤ قيم البارامترات طويلة الدور بهدف تسريع عملية التعلم.

يتيح العمل ضمن بيئة ماتلاب عدة خيارات مفيدة في عملية التدريب والاختبار، إذ يمكننا من التنبؤ لعدة خطوات مستقبلية اعتماداً على قيم التنبؤ السابقة. ويمكن تصحيح التنبؤ بعد عدة خطوات زمنية. ولكننا لا نعتمد على القيم الحقيقية للبارامترات في التنبؤ بكل خطوة زمنية خاصة بمرحلة اختيار نموذج التعلم وإعداداته، ومن ثم نقوم بتصحيح التنبؤ بعد عدد محدد من الخطوات الزمنية. فلماذا؟

عند اختبار الشبكة لدينا خياران، إما الاعتماد على القيم الحقيقية للبارامترات في الخطوة السابقة، أو الاعتماد على قيم التنبؤ في الخطوة السابقة لتنبؤ الخطوات التالية. من شأن الخيار الأول أن يعطي قيمة أكثر دقة في التنبؤ، ولكنه يناسب التطبيقات ذات الخطوات الزمنية المتباعدة أكثر، ففي تطبيقنا تصل القيم الحقيقية كل 0.05 ثانية، ويقوم النظام بالتنبؤ بنفس الخطوة الزمنية بشكل نظري دون أي معوقات، أما عملياً هناك بعض التأخيرات الزمنية مثل الاتصال بين الطائرة ومركز تحصيل المعطيات وزمن تحصيل دفعة المعالجة، والمعالجة الأولية، هذا إذا لم يحصل انقطاع بالاتصال بين الطائرة

ومركز تحصيل المعطيات. وهذا يجعل من الاعتماد على القيم الحقيقية للبارامترات في الخطوة السابقة والتنبؤ لخطوة واحدة فقط أمراً غير فعال أحياناً. ولذلك نعتمد على قيم التنبؤ لعدة خطوات زمنية إلى الأمام.

من ناحية ثانية فقد نحصل في بعض الأحيان على نتائج ممتازة في التنبؤ باعتمادنا على القيم الحقيقية للبارامترات في الخطوة السابقة فالأخطاء تكون صغيرة جداً من رتبة  $10^{-3}$  أو أقل، ولكن لا يعني ذلك بالضرورة أن نموذج التنبؤ مناسب للمعطيات. إن التنبؤ لعدة خطوات زمنية للأمام يفيد في معرفة مدى مناسبة نموذج التعلم الذي حصلنا عليه بالتدريب. ظهر بالتجربة أنه عندما نعتمد على قيم البارامترات الحقيقية للحصول على التنبؤات المستقبلية، قد لا نلاحظ فيما لو كان نموذج التنبؤ غير مناسب للبيانات تماماً بسبب أن أخطاء الاختبار تكون صغيرة وضمن مجال مقبول، بينما لو اعتمدنا على قيم التنبؤ سنلاحظ في هذه الحالة ازدياد الخطأ بشكل غير مقبول بحالة النموذج غير مناسب وفي حال كان النموذج جيداً سنلاحظ استقرار قيم الأخطاء مع الزمن.

بناءً على ما سبق يكون من المفيد تصحيح قيم التنبؤ بتغذيته بقيم حقيقية للبارامترات كل بضعة خطوات زمنية، كأن نقوم بالتصحيح عند تخطي الخطأ لقيمة معينة ضمن مجال خطأ مسموح. أو أن نقوم بالتصحيح كل  $i$  خطوة زمنية مثلاً كل دور حركة سريعة. كما أن عملية التصحيح لن يكون لها فائدة تذكر في حال كان نموذج التعلم الذي حصلنا عليه بالتدريب غير مناسب، إلا إذا قمنا بالتصحيح بخطوات زمنية أسرع.

أما بالنسبة لحجم مجموعة التدريب المناسب، فإن الرحلة الطيرانية لا تحوي أنماطاً واضحة، كما في بعض التطبيقات كالإشارة الناتجة عن راسم إشارة القلب ففي تلك الحالة لا نحتاج إلى مجموعة تدريب كبيرة ويمكن الاكتفاء بدور حركة للتدريب على إشارة قلب طبيعية بوضع مستقر وبدون ضجيج. وكذا الحال في التدريب على الإشارات الجيبية والإشارات ذات الأنماط المتكررة. وستكون الشبكة قادرة على التنبؤ بأخطاء مقبولة حتى لو تغير تردد الإشارة أو مطالها كما سنرى في الفصل الرابع. بالإضافة إلى عدد البارامترات الكبير الذي يسبب حجماً إضافياً لمجموعة المعطيات.

تمتلك كل طائرة مجموعة من الخواص تميزها عن غيرها من الطائرات، هذا يعني أن كل الطائرة في حالتها الطبيعية لها نفس الاستجابة الديناميكية في كل رحلة بالشكل الطبيعي. وهذا يدلنا أن تغذية نموذج التعلم ببيانات مولدة من نموذج طائرة بحالتها الطبيعية مع كافة التبدلات التي تطرأ عليها خلال

الرحلة الجوية يكفي لتدريب الشبكة على النموذج. مثلاً، حمولة الطائرة في قيمتها العظمى إلى قيمتها الصغرى مما يغير في مركز ثقل الطائرة ودفع المحرك وأثر ذلك على سلوك الطائرة، بالإضافة إلى كافة الأنماط التي تقوم بها الطائرة الخفيفة في الجو مثلاً الطيران المقلوب، وهكذا. ويكون طول مجموعة التدريب إذا علمنا أن مدة الرحلة وسطياً تساوي 20 دقيقة. وبمعدل أخذ عينات كل 0.05 ثانية يصبح عدد العينات 48 ألف شعاع دخل بالحد الأدنى تحتاجها الشبكة للتدريب.

### 3-3-3- بيان العلاقات السببية بين البارامترات

بعد القيام بتدريب الشبكة العصبونية نقوم بتطبيق طريقة LASSO على مجموعة محددة فقط من الأوزان، أي التي تتعلق بطبقة الخرج  $W_0$ ، (فقرة استنتاج السببية، ص 25) من مصفوفة أوزان الشبكة العصبونية العودية فقط وليس لكل أوزان الشبكة. ذلك أن مصفوفة  $W_0$  تعطي الأوزان النهائية للبارامترات بعد انتهاء عملية التدريب. يساعدنا ذلك في الاستغناء عن تدريب الشبكة المتكرر للحصول على القيمة الأفضل لعامل التنظيم، بالإضافة إلى أن القيم الجديدة في خرج التابع ذات صفة خطية كونه يعتمد على الانحدار الذاتي في إيجاد معاملات الدخل والتي هي أوزان الخرج في الشبكة العصبونية وبالتالي يمكن اعتماد النتائج في نقض فرضية السببية التي قدمها Granger.

ندرس تأثير بارامترات الدخل وبارامترات التغذية الراجعة على بارامترات الخرج لأن بارامترات دخل النظام متمثلة بعصا القيادة ومقود التحكم بالمحرك مستقلان ولا يتأثران بأي من بارامترات الخرج. ويمكن الهدف في الحصول على ارتباطات بارامترات الدخل وتأثيرها على بارامترات الخرج عبر اللحظات الزمنية المختلفة، وبالتالي يمكن أن نحصل على بيان موجه من اللحظة السابقة إلى اللحظة اللاحقة، وليس الهدف تحسين التنبؤ في هذه الحالة.

تقوم الفكرة على أن بيان الشبكة الناتج بعد عملية التدريب ثابتاً بالنسبة لأوزان الشبكة من أجل مجموعة تدريب ما. وفي حالة حدوث عطل ستقوم الشبكة بعمل تحديث أوزانها أثناء التنبؤ بشكل يعكس أثر العطل على ارتباطات البارامترات وبالتالي سيتشكل بيان مختلف عن البيان الناتج عن عملية التدريب! مع الانتباه أن البيان الناتج في هذه الحالة يمثل ارتباطات البارامترات بين بعضها خلال الزمن وصولاً للعطل ولا يمثل العطل وأسبابه.

ويضاف إلى ذلك إلى أننا قد لا نتمكن في الحالة العامة من استنتاج أسباب أعطال الطيران من بيانات العلاقات السببية بشكل مباشر، فقد يكون السبب في حصول العطل عوامل غير مقاسة، مخفية

وبالتالي لا يمكن استنتاج أثرها، مثلاً في طائرة اختبارية، لا يمكن التكهّن بعطل زيادة الكبح بسبب فتح أحد الأغطية أو الفرامل الهوائية بشكل غير مخطط له. بينما يمكن التكهّن بانخفاض فعالية عصا القيادة في الطائرة بسبب تغير في معامل النقل في القناة الطولية بين العصا ودفة العمق مما يؤدي إلى شذوذ في استجابة الطائرة في القناة الطولية في حال قياس انحراف العصا والدفة.

إنّ يتيح الحصول على بيان العلاقات السببية فهماً أفضل لسلوك البارامترات في الحالة الطبيعية وفي حالات الأعطال المختلفة وبذلك يمكننا بكشف الخلل في ارتباطات البارامترات التنبؤ بحدوث عطل في النظام المدروس بشكل مبكر من خلال عمل دراسة إحصائية. وتكمن أهمية هذه الفكرة بإمكانية تنفيذها على تطبيقات مختلفة وقد تتوضح بشكل أفضل في تطبيقات مختلفة، صحية مثلاً.

# الفصل الرابع

## اختبار النموذج ونتائج البحث

### 1-4- تمهيد

تم العمل ضمن بيئة ماتلاب 2018، وأجريت جميع التجارب على حاسب ذو معالج Core i7 8th Gen بكرت فيديو Nvidia GeForce GTX 6G، وذاكرة وصول عشوائي 8 غيغا. أما بالنسبة لمجموعات البيانات المدروسة فهي ثلاث مجموعات:

- مجموعة البيانات المولدة من نموذج ماتلاب: كانت الفائدة من نموذج الحركة الطولية المعروف في الفصل الأول هي تبسيط العمل من جهة والتمكن من زراعة أعطال غير بديهية للطيار من جهة ثانية ويضاف إلى ذلك مشابهة طريقة توليد البيانات لتجهيزات العدادات الإلكترونية الحديثة التي ترسل البيانات بأكثر من تردد، حيث قمنا بتسجيل البيانات بترددية أخذ عينات. تم تسجيل 10 ملفات من إشارات Step, Sine و42 ملف بإشارات حقيقية باستخدام Joystick لمدة زمنية كلية لجميع الملفات تتجاوز ثلاث رحلات طيران بطول 20 دقيقة للرحلة الواحدة، وتحتوي 13 بارامتراً تم شرح دلالاتها ضمن الفصل الأول في الفقرة (1-2)، وتمثل البارامترات نمطي الحركة الطولية القصيرة والحركة الطويلة الدور، بمعدل أخذ عينات 20 لدور الحركة القصيرة و10 لدور الحركة الطويلة للتخلص من الحجم الزائدة الناتجة من توحيد عدد العينات في البارامترات.

- مجموعة بيانات MKAD هي مجموعة بيانات صناعية نمطية [34] مقدمة من NASA National Aeronautics and Space Administration، الهدف من استخدام هذه المجموعة هو اختبار نموذج الكشف عن الشذوذ الذي قمنا ببنائه. تقدم المجموعة 150 ملف تدريب كل منها يحتوي 15 بارامتر غير موسوم Unlabeled وهي ذات سلوك نمطي في عدة بارامترات مثلاً البارامترات (2,3,6,8,..) وتتكون من تتالي إشارات خطوة متطابقة في المطال وموضع البداية في أغلب ملفات التدريب. وأما بالنسبة لملفات الاختبار فهي 150 ملف. كل من الملفات يحتوي 1000 خطوة زمنية تحوي بعض بارامترات ملفات الاختبار أعطالاً من ثلاثة أنماط.

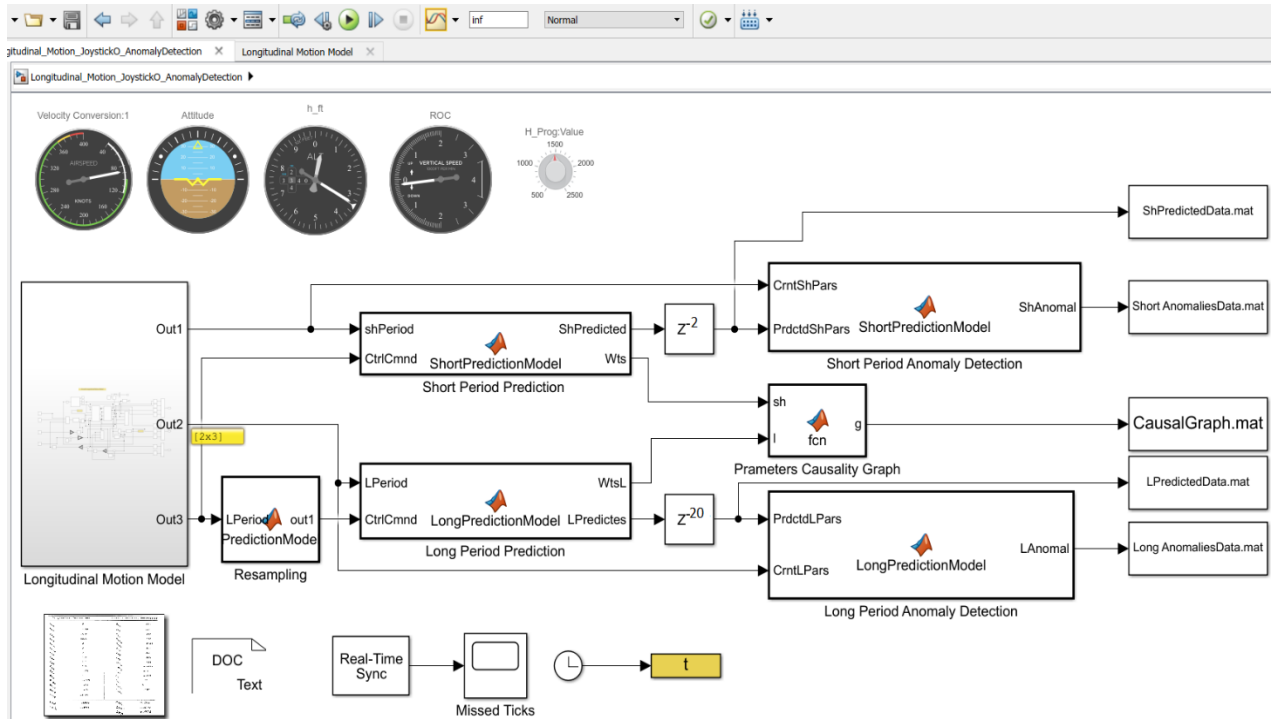
- مجموعة بيانات من برنامج X-Plane تم تسجيل ملفي بيانات لمدة 30 دقيقة منها دقيقتين للاختبار، وتحتوي 32 بارامتراً، والهدف من هذه المجموعة هو الاختبار على نموذج كامل لطائرة خفيفة

(الحركات الطولية والعرضية والاتجاه مع بعض بارامترات المحرك)، بمعدل أخذ عينات موحد لكل البارامترات 10 مرات بالثانية وذلك بسبب أن برنامج X-Plane لا يتيح أخذ العينات بترددات مختلفة. ويبين الملحق في نهاية التقرير رموز ودلالة تلك البارامترات.

## 2-4- إعدادات العمل ضمن بيئة ماتلاب

### 1-2-4- تدفق المعطيات من نموذج الحركة الطولية في ماتلاب

تمت مقارنة ثلاث تقنيات للتنبؤ LSTM, NARXNET, VARM واختيار التقنية ذات النتائج الأفضل وهي LSTM في النموذج. بعد تدريب الشبكة يمكن استخدام نموذج التعلم الناتج أثناء تدفق المعطيات باستخدام: كتلة الزمن الحقيقي الموجودة في Simulink، وبوضع خيار inf في مربع الزمن، ثم نقوم بتحديد طول الدفعة Batch باستخدام كتلة التأخير الزمني Tapped Delay الموجودة في كتلة نموذج الحركة الطولية التي تعمل كخازن للمعطيات ونقوم بتوليد المعطيات بوصل عصا اللعب أو استخدام إشارات نمطية. يبين الشكل (30) النموذج المقترح لمراقبة بارامترات الحركة الطولية لطائرة خفيفة والكشف عن الشذوذ في أي منها واستنتاج العلاقات السببية بين بارامترات الدخل والخرج.



الشكل 30-النموذج المقترح في ماتلاب للكشف عن الشذوذات أثناء حركة المعطيات

تعرفنا في الفصل الأول على نموذج الحركة الطولية لطائرة خفيفة بنمطي الحركة القصيرة وطويلة الدور، قمنا ابتداءً من اليسار بحساب بارامترات الحركة الطولية في الكتلة Longitudinal Motion Model وخرج الكتلة هو مجموعة البارامترات تمثل أوامر الطيار للتحكم بالعصا على القناة الطولية والتحكم بمقود المحرك المذكورة في الجدول (1) فقرة (1-2) بمعدلي أخذ عينات مختلفين بحيث يكون لكلا الحركتين نفس عدد العينات في الدور الواحد لنمطي الحركة كما ورد بالفصل الثالث فقرة 1-3-1 تردد أخذ العينات، حيث ذكرنا سابقاً أن بارامترات نمط الحركة طويلة الدور لا تتغير بسرعة ويمكن تحديد معدل أخذ عيناتها بما يحقق حجماً أقل دون التأثير على الأداء سلباً. وتستخدم هذه البارامترات في كتلتي التنبؤ Prediction Model لنمطي الحركة قصيرة وطويلة الدور. تعطي كل كتلة خرجين الأول هو مجموعة بارامترات التنبؤ وتستخدم في الكشف عن الشذوذ في البارامترات من خلال كتلة Anomaly Detection Block ولكن بعد إدخاله إلى كتلة تأخير زمني بحيث يكون التأخير لبارامترات نمط الحركة طويلة الدور أكثر 10 مرات من التأخير لبارامترات نمط الحركة الطولية قصيرة الدور، أما الخرج الثاني هو عبارة عن مصفوفة أوزان الشبكة العصبونية المحدثة عند كل دفعة بيانات ومنها نقوم بتوليد بيان العلاقات السببية بين البارامترات، ولاحقاً في المستقبل نقوم بعد حفظها بتحليلها لتحديد سلوك البارامترات في الحالات الطبيعية وحالات الأعطال من خلال التقنيات المناسبة كدراسة التشابه بينها وبالتالي إمكانية تحديد الأعطال.

مثلاً للتنبؤ بخطوتين زمنييتين، ابتداءً من اللحظة الثانية من تشغيل النموذج يتم ما يلي:

1. نحصل على قيم البارامترات في اللحظتين الأولى والثانية من كتلة نموذج الحركة الطولية، وفي هذه اللحظة تكون قيم بارامترات نمط الحركة طويلة الدور ثابتة.
2. نتنبأ بقيم البارامترات للحظتين الثالثة والرابعة ونقوم بالاحتفاظ بقيم التنبؤ من خلال كتلة التأخير الزمني Delay لاستخدامها لاحقاً.
3. نقوم بتحصيل أوزان الشبكتين العصبونيتين لنمطي الحركة قصيرة وطويلة الدور ونرسم بيان العلاقات السببية لكل منهما.
4. نخزن قيم البارامترات الحقيقية والمتنبأ بها وقيم الشذوذ وبيان العلاقات السببية الناتجة في ملفات ذات صيغة ..mat

وفي اللحظة الزمنية الرابعة يكون قد تم تخزين بارامترات نمط الحركة قصيرة الدور في اللحظتين الثالثة والرابعة ونقوم بمقارنة قيمهما مع قيم البارامترات المتنبأ بها من اللحظة الثانية وحساب الخطأ بينهما

فإذا كانت قيم الأخطاء أقل من قيمة محددة تكون حالة البارامترات سليمة بإعطاء قيمة صفر، وخلاف ذلك يكون تم الكشف عن شذوذ بإعطاء قيمة واحد في خرج كتلة الكشف. أما بارامترات نمط الحركة طويلة الدور فتبدأ عملية كشف الشذوذات عند اللحظة 20 حيث تتنبأ ببارامترات اللحظتين الزميتين 40 و60 وهكذا.

#### 4-2-2- استقبال المعطيات من برنامج X-Plane 10

يتيح برنامج X-Plane نقل المعطيات عبر بروتوكول مخطط بيانات المستخدم UDP الذي يسمح بنقل الرسائل بشكل أسرع من غيره من بروتوكولات الاتصالات، نقوم باختيار مجموعات البارامترات التي نريد إرسالها من برنامج X-Plane ونحدد نمط الإرسال عبر UDP ومعدل أخذ المعطيات 20 وذلك لأن البرنامج لا يوفر ميزة الإرسال بترددات مختلفة، ثم يتم البدء بإرسال المعطيات عبر الشبكة على شكل مصفوفة من البايتات. نقوم في برنامج نموذج العمل في ماتلاب باستقبال المعطيات وتحويلها من مصفوفة بايتات إلى أرقام مقروءة ابتداءً من العنصر الخامس فيها حيث تمثل كل أربع عناصر متتالية قيمة ما إما رقم المجموعة المختارة أو قيمة بارامتر ما علماً أن كل مجموعة تحوي قيم 8 بارامترات. أما تتالي العمليات على التنبؤ فهي تماماً كما في العمل على نموذج ماتلاب.

```
udpr = dsp.UDPReceiver('IPPort',port);  
setup(udpr);  
dataReceived = udpr();
```

#### 4-2-3- تخفيف الحمل

تمتلك بيئة ماتلاب العديد من الإمكانيات للتعامل مع المعطيات الكبيرة، كما أن العديد من توابع برنامج ماتلاب تعمل بنمط تفرعي أوتوماتيكياً مثل تابع تدريب الشبكة وتابع التنظيم LASSO وغيرها العديد من التوابع التي يمكن استخدامها لتسريع العمل، استخدمنا منها:

- التابع MatFile:

يتيح هذا التابع الوصول إلى ملفات المعطيات وتعديلها دون تحميلها مباشرة إلى الذاكرة. تمت الاستفادة منه أثناء المعالجة الأولية: لتقييس البارامترات، وتوسعة شعاع الدخل بإضافة اللحظة السابقة، وأثناء تدريب الشبكة حيث تمكنا من تلافي مشكلة توقف التدريب لخمس شبكات على التفرع. أدى العمل على القرص إلى

زيادة في زمن التدريب بمقدار دقيقتين تقريباً من أجل مجموعة التدريب نفسها وهذه الزيادة في الزمن لا تؤثر على أداء النموذج، لأن السرعة تصبح مطلوبة أثناء الاختبار أو الاستثمار الفعلي حيث تتم معالجة البارامترات في الذاكرة وليس على القرص.

- إعدادات تدريب الشبكات العصبونية في ماتلاب:

إن السلسلة الزمنية عبارة عن تتالي قيم مترابطة مع بعضها عبر الزمن، ومن شعاع دخل واحد لا يمكن الحكم على حالة الطائرة، لذا تكون عملية التدريب في مثل هذه الحالات تسلسلياً. يتيح بيئة ماتلاب ضمن خيارات تدريب شبكة LSTM إعدادات تمكن من تخفيف حمل الحسابات عن المعالج مثل استخدام كرت الفيديو GPU، نستفيد من استخدامنا لكرت الفيديو من العدد الكبير لوحدات المعالجة لحساب مصفوفة الأوزان وتعديلها بشكل تفرعي ويفضل العمل ضمن بيئة GPU في حال كانت مجموعة التدريب كبيرة وشعاع البارامترات كبير. أما شبكة NARXNET فهي لا تتيح العمل التدريب على GPU، وبهذا تتميز شبكة LSTM عنها.

### 3-4- نتائج العمل

#### 1-3-4- نتائج التدريب والاختبار على مجموعة MKAD

تم التدريب باستخدام شبكة LSTM لخطوتين زمنيتين على كامل البارامترات كدخل للشبكة العصبونية أي 30 بارامتر، وبسبب أن البارامترات غير موسومة وليس لها دلالة واضحة اخترنا التنبؤ لكامل شعاع البارامترات أي 15 بارامتر.

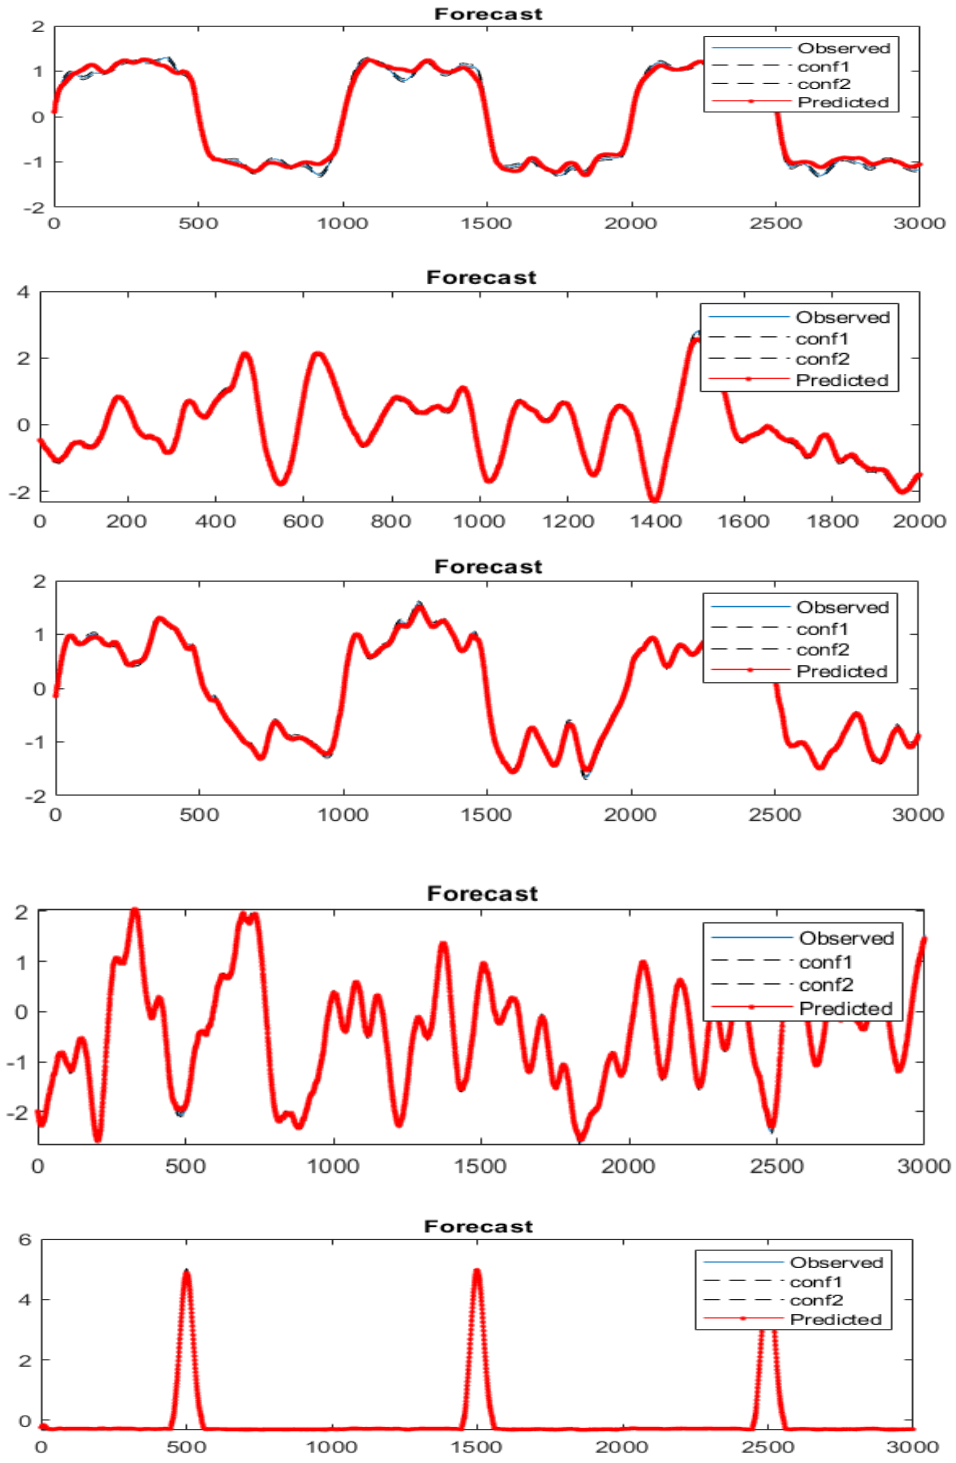
استغرق تدريب الشبكة على GPU وحيد حوالي 30 دقيقة على زمن (Epoch) 150. ويوضح الشكل (31) منحنيات التنبؤ لخمس من بارامترات المجموعة (من البارامتر 10 إلى 15) باستخدام شبكة LSTM بعد إزالة الضجيج من البارامترات التي تحوي ضجيج منها.

بعد تدريب شبكة LSTM على كامل مجموعة التدريب قمنا بالاختبار على ثلاث ملفات اثنين منها مع عطل والثالث بدون أعطال وتم الكشف عن عطل في الملف 00230 في البارامترات التي تحوي إشارة Step وهو من النمط 1، وفي الملف 00260 في البارامتر 7 وهو من النمط 11، ولم يكشف عن أعطال في الملف 00201.

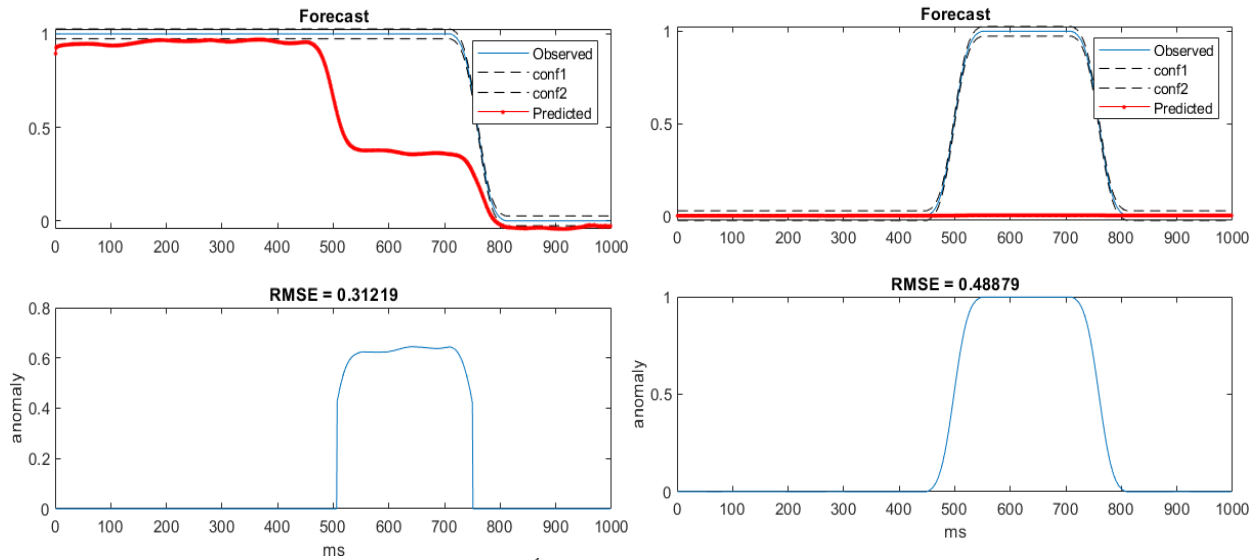
يمثل المنحني باللون الأزرق البيانات الحقيقية، أما المنحني باللون الأحمر فهي منحنيات التنبؤ، ويمثل الخطان المتقطعان باللون الأسود حد خطأ التنبؤ وكانت رتبة الخطأ ضمن مقياس مجموع مربعات الأخطاء RMSE من رتبة  $10^{-2}$  البارامترات. تم تصحيح التنبؤ كل 10 خطوة زمنية.

أما عتبة كشف الشذوذ تم تحديدها تجريبياً بأكبر أو أصغر من ثلاث أضعاف الانحراف المعياري للبيانات الحقيقية كما هو واضح في الشكل (32) لاثنتين من بارامترات المجموعة، وعند تجاوز هذه العتبة يتم إطلاق تنبيه بالكشف عن خلل بالبارامترات. نلاحظ ارتفاع قيمة RMSE إلى رتبة  $10^{-1}$  وهذا خطأ يتم عنده إطلاق تنبيه لاكتشاف خلل في البارامترات. أما شبكة NARXNET لم تظهر أي نتيجة مقبولة على هذه المجموعة، ولا حتى عند الاعتماد على القيم السابقة في التنبؤ.


أما فيما يتعلق بكشف العلاقات السببية فبعد تدريب الشبكة تم تطبيق تابع التنظيم LASSO لكل من الأوزان الموافقة لبارامترات الخرج وعددها 15 وما يؤثر عليها من بارامترات الدخل في اللحظتين السابقتين ما عدا الوزن الموافق لبارامتر الخرج المدروس أي 29 بارامتر. وتبين وجود بارامتر يتأثر بتغير عدة بارامترات وهو  $X_3$  وهو عبارة عن تلاحق إشارات خطوة في مجموعة التدريب، يتأثر هذا البارامتر في الحالة الطبيعية بتغير عدة بارامترات أكثرها تأثيراً  $Prev\_x15$  في الحالة الطبيعية، بينما عند حدوث عطل مثلاً كالعطل من النمط III نلاحظ انخفاض تأثير  $Prev\_x15$  في تغير قيمة  $X_3$  بالإضافة إلى تغير في بعض العلاقات كما هو موضح في الشكلين التاليين (33)، (34). ويمثل عرض الوصلة قوة التأثير بين العقدتين في طرفيها مثل الوصلة بين  $\langle Prev\_X15, X3 \rangle$ ، كما تم حذف البارامترات التي قيمة تأثرها تساوي 0.




الشكل 31- نتائج التنبؤ على بعض بارامترات مجموعة MKAD



الشكل 32- اختبار كشف شذوذ من النمط الأول في مجموعة MKAD



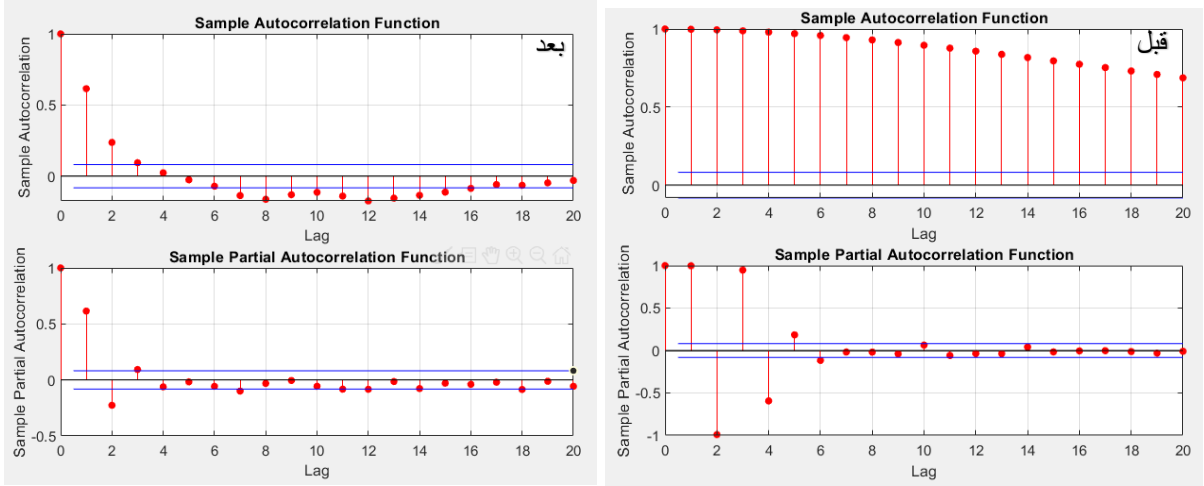
الشكل 33- بيانات من مجموعة MKAD لملفين لحالة سليمة 201، 202



الشكل 34- بيانات السببية من مجموعة MKAD لملفين من العطل III 238، 325

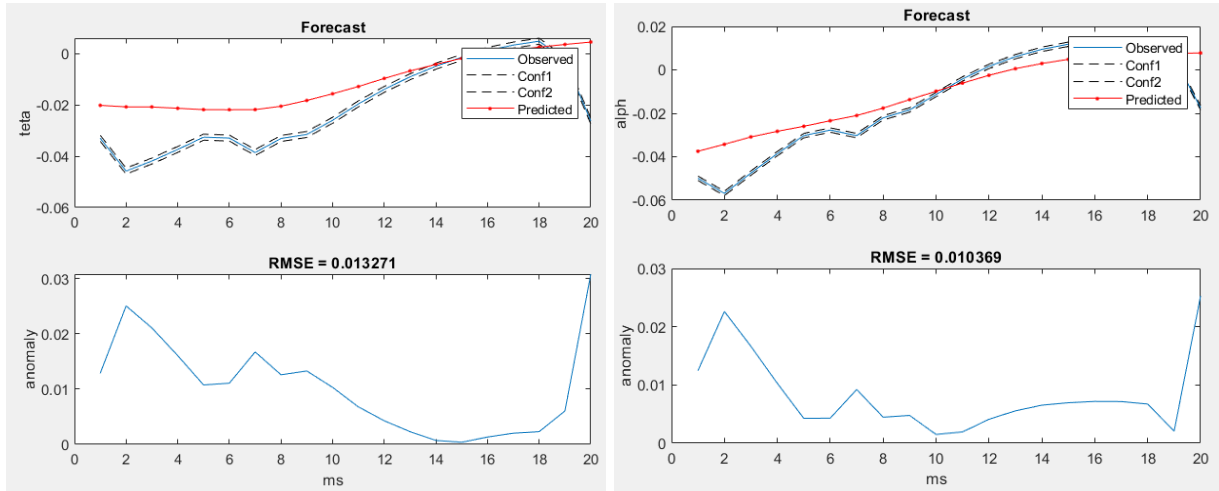
#### 2-3-4- نتائج مجموعة ماتلاب

A- باستخدام شعاع الانحدار الذاتي متعدد البارامترات VARM تم استخدام ملفات سليمة للتدريب وملفات سليمة وأخرى مع أعطال للاختبار على بارامترات الحركة الطولية قصيرة الدور. نقوم أولاً بالتأكد من أن البيانات مستقرة Stationary. ويتيح ماتلاب عدة توابع لاختبار البيانات منها إحصائي  $Kpsstest(y)$ ,  $ADF(y)$ ، ومنها بالرسم البياني باستخدام توابع الارتباط الذاتي والارتباط الجزئي  $Autocorr(y)$ ,  $Parcorr(y)$ . يبين الشكل (35) بارامتر معدل الغوص Q قبل وبعد إلغاء عدم الاستقرار منه حيث نلاحظ تباطؤ بانخفاض قيمة الارتباط الذاتي للبارامتر بازدياد الخطوات Lags وهذا يدل على أن البارامتر غير مستقر (الجزء الأيمن من الشكل)، بإلغاء حالة عدم الاستقرار نلاحظ انخفاض أسي بقيمة الارتباط الذاتي للبارامتر باتجاه الصفر وهذا يدل على أن البارامتر أصبح مستقراً (الجزء الأيسر من الشكل) وتأكدنا إحصائياً باستخدام تابع  $Kpsstest$  من استقرار البارامتر وبهذا أصبح يمكن استخدامه في تدريب نموذج انحدار ذاتي متعدد البارامترات.



الشكل 35- بارامتر معدل الغوص Q قبل وبعد إلغاء عدم الاستقرار

ثم إلغاء عدم الاستقرار منها باستخدام تابع  $\text{Detrend}(y)$ ، وبعد ذلك نقوم ببناء نموذج الانحدار الذاتي الخطي متعدد البارامترات بخطوتين  $\text{Lag}=10$ ، ثم نقوم بالتدريب على ملفات التدريب السليمة، ويظهر الشكل (36) نتيجة التنبؤ لعدة خطوات زمنية مع تصحيح كل 20 خطوة باستخدام النموذج الناتج لكل من زاويتي الغوص والهجوم.



الشكل 36- نتيجة التنبؤ لمدة 20 خطوة زمنية للأمام باستخدام نموذج VARM

B- باستخدام شبكة LSTM

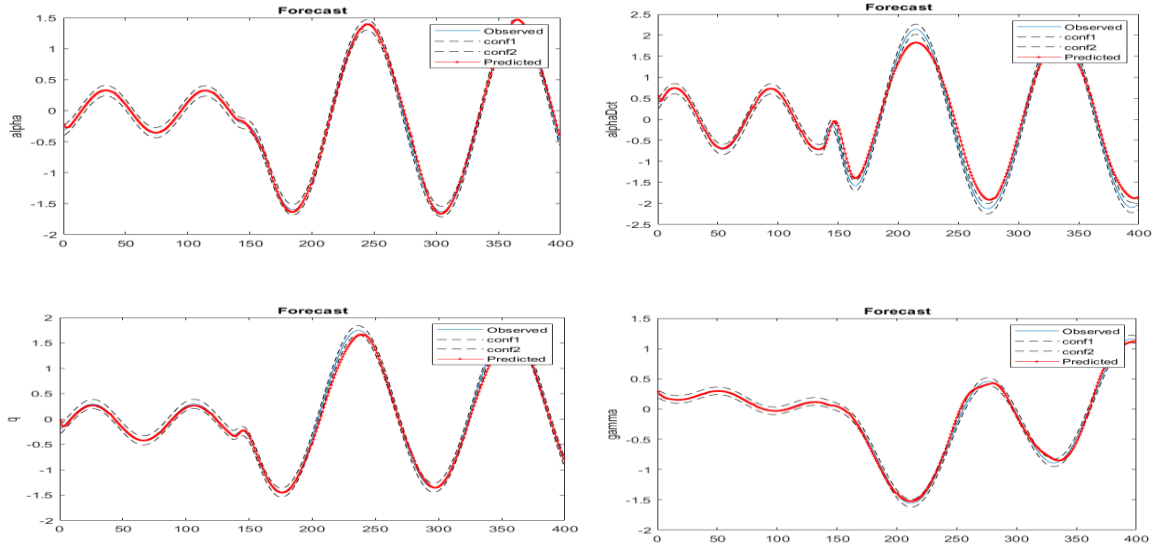
استغرق التدريب 10 ثانية للمجموعة النمطية 30 ثانية للمجموعة الحقيقية بمقياس خطأ RMSE

يساوي 0.04، و 0.12 على التوالي، وذلك لنفس بنية الشبكة بالبارامترات المبينة في الجدول (2).





الجدول 2- عبارات شبكة LSTM لكل من مجموعتي البيانات النمطية وبيانات المقاد الحقيقية

بيانات مقاد حقيقية مع Joystick	مجموعة بيانات نمطية	
16	16	عدد بارامترات الدخل
5	5	عدد بارامترات الخرج
7200 شعاع	1600 شعاع	حجم مجموعة التدريب
خطوتان	خطوتان	الخطوات الزمنية السابقة
10	45	عدد عناصر الطبقة الخفية
150	150	عدد دورات التعلم Epoch

يظهر في الشكلين التاليين (37)، (38) قدرة الشبكة على تنبؤ 20 ثانية للأمام بدون الرجوع إلى القيم السابقة للبارامترات ضمن حدود القيم الحقيقية للبيانات مضافاً إليها أو منقوصاً منها ثلاث أضعاف قيمة انحرافها المعياري، وذلك لكل من بارامترات الحركة القصيرة مثل زاوية الهجوم Alpha، ومعدل الغوص Q وبارامترات الحركة الطويلة مثل زاوية ميل المسار Gamma، والارتفاع H.



الشكل 37- نتائج تنبؤ 20 ثانية للأمام لمجموعة تدريب نمطية باستخدام شبكة LSTM




الشكل 38 - نتائج تنبؤ 20 ثانية للأمام لمجموعة تدريب حقيقية باستخدام شبكة LSTM

### C- باستخدام شبكة NARXNET


أظهرت شبكة NARXNET نتائج بمقياس أخطاء RMSE من رتبة  $10^{-3}$  مع التصحيح كل 10 خطوات زمنية في البيانات النمطية مثل معدل الغوص Teta شكل (39)، ونلاحظ في الشكل (40) قيم خطأ التنبؤ خلال الزمن لكل من NARXNET, LSTM, VARM على بيانات نمطية حيث الخطأ أما VARM فكانت الأخطاء من رتبة  $10^{-2}$  مع التصحيح كل 10 خطوات زمنية. ولكن أداء شبكة LSTM أثبت أداءً أفضل عند عدم التصحيح لفترة تتجاوز 5 ثانية أي 100 خطوة زمنية بينما يتراجع أداء VARM ليصبح أضعف من NARXNET ويبين الجدول (3) التالي الأخطاء بمقياس RMSE لبارامترات الحركة الطولية بنمطها قصيرة الدور وطويلة الدور عند التصحيح كل 10 خطوات زمنية:

الجدول 3- مقارنة بين تقنيات LSTM, NARXNET, VARM بمقياس RMSE

VARM	NARXNET	LSTM		
0.0466	0.0013	0.0165	TETA	قصيرة الدور
0.0455	0.0023	0.0261	Q	
0.0160	0.0007	0.0238	Alpha	
0.0187	0.0009	0.0632	ALPHADOT	
0.0481	0.1519	0.0343	V	طويلة الدور
0.0036	0.0016	0.0175	GAMMA	
0.3078	0.4127	0.0241	H	
0.2447	0.3194	0.0174	HDOT	



الشكل 39 - التنبؤ باستخدام NARXNET لبيانات نمطية



الشكل 40- منحنى خطأ التنبؤ لكل من LSTM, NARXNET, VARM لزاوية الغوص

#### D - نتائج اختبار التنبؤ بشكل تفرعي باستخدام شبكة LSTM

قمنا بتدريب شبكتين على التفرع باستخدام حلقة *Parfor* في ماتلاب، للتنبؤ ببارامترات دور الحركة السريعة والبطيئة معاً على مجموعة بيانات من 12000 شعاع دخل، حيث طول الشعاع 20 بارامتراً ومصفوفة من عناصر الطبقة المخفية. استغرق التنفيذ 132.8 ثانية على مدى 150 مرة كما هو موضح في الشكل (41). الهدف من عدم تخفيض الحجم في الحركة بطيئة الدور وأخذها بنفس حجم الحركة سريعة الدور فقط لاختبار زمن التدريب في كلا الشبكتين.

```
numHiddenUnits = Low:High;
parfor idx = 1:numel(numHiddenUnits)
    % Train networks in parallel workers
    net = trainNetwork(inputTrain',outShortPeriodTrain'...
        ,layersShort,options);
    % Save the trained networks for further work.
    trainedNetworks{idx} = net;
end
```

```
Starting parallel pool (parpool) using the 'local' profile ...
connected to 6 workers.
Training on single GPU.
Training on single GPU.
```


Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch RMSE	Mini-batch Loss	Base Learning Rate
1	1	00:00:08	1.06	0.6	0.0100
1	1	00:00:08	0.90	0.4	0.0100
50	50	00:00:34	0.15	1.1e-02	0.0100
50	50	00:00:34	0.09	4.0e-03	0.0100
100	100	00:00:58	0.07	2.1e-03	0.0100
100	100	00:00:57	0.06	1.7e-03	0.0100
150	150	00:01:21	0.05	1.3e-03	0.0100
150	150	00:01:21	0.04	8.4e-04	0.0100

الشكل 41 - نتائج تدريب شبكتي LSTM على التفرع للحركة الطولية بدورها السريعة والبطيئة


قمنا بإعادة التجربة مرتين مرة بتحميل ملف التدريب إلى الذاكرة والثانية بتدريب الشبكة مباشرة من القرص الصلب. ومن أجل ثلاث شبكات تعمل على التفرع تمثل العناصر المخفية [20:20:60] ومن ثم الاحتفاظ بالشبكة ذات خطأ التنبؤ الأقل. استغرق زمن التنفيذ 157.6 ثانية في الحالة الأولى، أما الحالة الثانية استغرق زمناً أكبر قدره 240.7 ثانية تقريباً 4 دقائق.

ومن أجل تدريب الشبكة على عناصر مخفية [40:10:80] تفرعياً استغرق التنفيذ زمناً قدره 298 ثانية تقريباً 5 دقائق.

أيضاً تم اختبار شبكة التنبؤ بشكل تفرعي من أجل نمطي الحركة قصيرة وطويلة الدور. ويبين الشكلان التاليان (42)، (43) منحنى التنبؤ باللون الأحمر بالمقارنة مع القيم الحقيقية باللون الأزرق، للبارامترين AlphaDot معدل زاوية الهجوم بين محور الطائرة وشعاع السرعة، وزاوية ميل المسار و Gamma الزاوية بين مستوي الطائرة والمستوي الأفقي.



الشكل 43 - تنبؤ لأحد بارامترات الحركة البطيئة



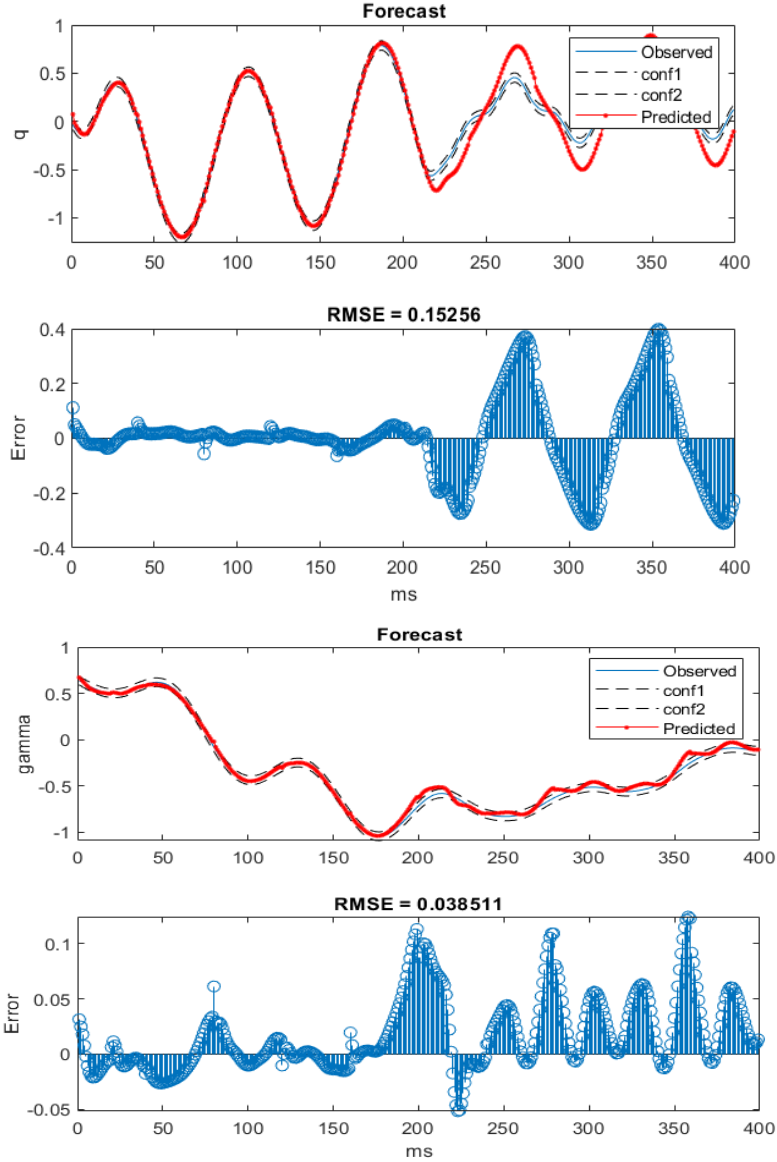
الشكل 42 - تنبؤ ثانية لأحد بارامترات الحركة السريعة

نلاحظ في الشكل (43) في منحنى Gamma ازدياد الخطأ بتغير مطال الحركة في الخطوة الزمنية الأولى ثم تناقصه تدريجياً حتى الخطوة 100، وفي الخطوة الزمنية 800 ثم يعود ليتناقص مع الزمن، يمكن تفسير ذلك بالاستجابة البطيئة له فهو من بارامترات نمط الحركة طويلة الدور، مقارنة بالخطأ الصغير AlphaDot من بارامترات نمط الحركة قصيرة الدور.

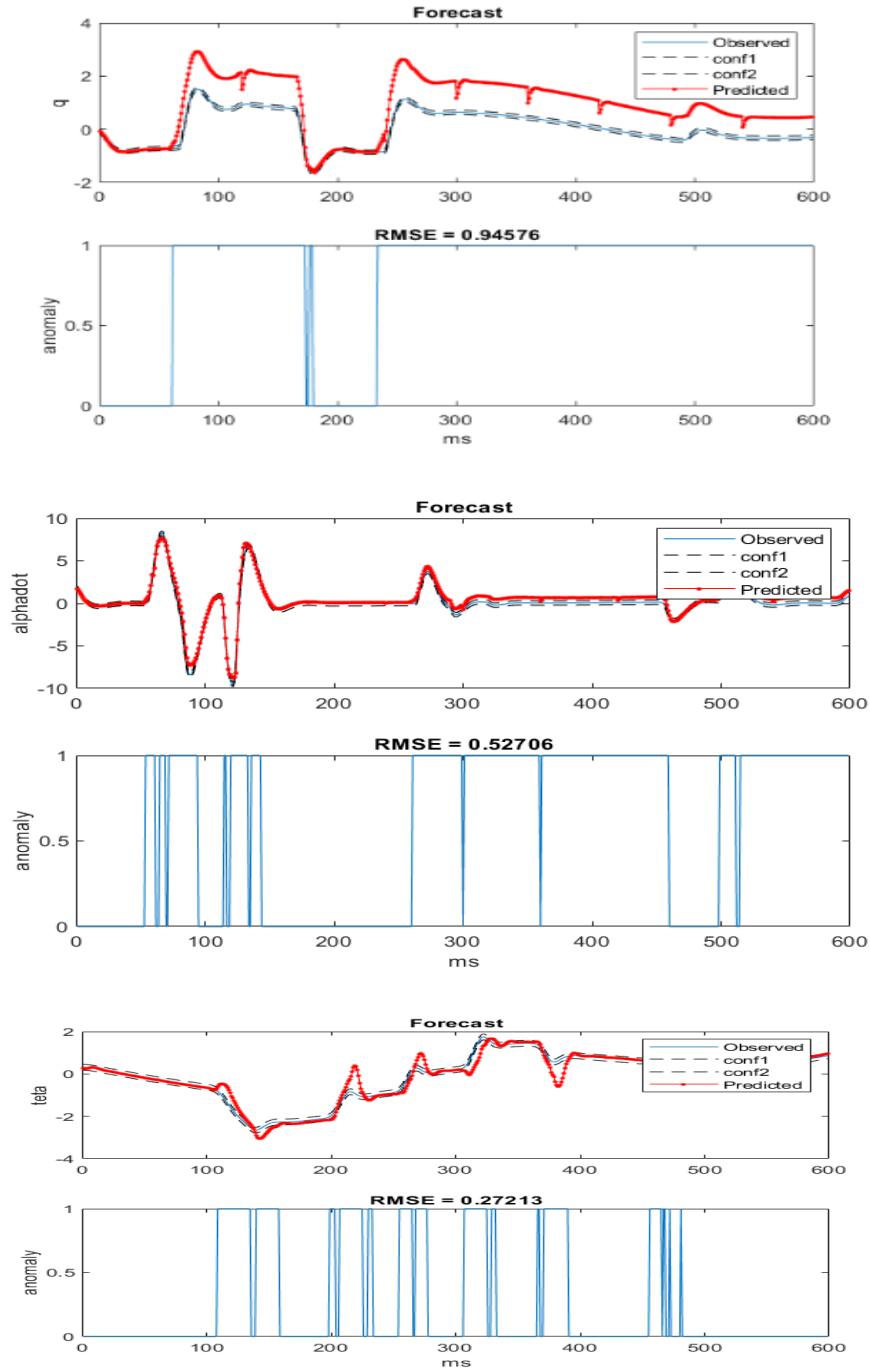
#### E- نتائج الكشف عن الشذوذات

قمنا بتسجيل عدة ملفات مع حالات عطل منها لمنطقة مية في انحراف عصا القيادة أو نقص في فعاليتها، أو تغير في عزم العطالة الطولي. تظهر الإشارة التالية تسجيلاً لحركة تكون طبيعية ثم في منتصف الإشارة يحصل عطل المنطقة المية ابتداءً من الثانية 10 أي الخطوة 100، لإشارة طولها 20 ثانية في القيادة الطولية. ظهر بنتيجة التجربة قدرة الشبكة على كشف عطل المنطقة المية، ويظهر ذلك في بارامترات الحركة القصيرة

مثل زاوية الغوص Q بشكل واضح وبخطاً RMSE من رتبة  $10^{-1}$  لمقدار. بينما لم تتأثر زاوية المسار Gamma من بارامترات الحركة الطويلة بالعتل وتأثيره كان طفيفاً إذ قيمة RMSE من رتبة  $10^{-2}$  كما يبين الشكل (44):



الشكل 44 - كشف الشذوذ في بيانات مع عطل منطقة ميتة باستخدام LSTM



الشكل 45- الكشف عن شذوذات تعبر عن أعطال في القناة الطولية لعصا القيادة

يعرض الشكل (45) اعتماداً على التنبؤ بقيم ثلاث بارامترات Q, AlphaDot, Teta ابتداءً من الأعلى الكشف عن حدوث شذوذ anomaly في البيانات تعبر عن ثلاث أعطال في القناة الطولية: نقص بفعالية العصا على القناة الطولية يظهر بمنحني التنبؤ ببارامتر Q، يليه عطل أدى إلى تغير في عزم العطالة الطولي للطائرة

كانفصال كاميرا معلقة على الذيل، كمنحني AlphaDot. وأخيراً، لا خطية ناجمة عن منطقة ميتة Dead zone في حركة العصا على القناة الطولية سببه ارتخاء في أحد أجزاء نظام القيادة الطولي نراه في منحني .Teta.

كما يبين الشكل السابق، انعكاس فيزيائية الأعطال الثلاث السابقة: فنقص فعالية العصا يتم كشفه على كافة نقاط مجموعة الاختبار يتضح في مواطن الخلل المكتشفة في بارامتر Q. أما عطل التغيير في عزم العطالة الطولي يتم كشفه عند حصول تسارع زاوي (القمة والقاع في منحني AlphaDot)، أما العطل الثالث الذي يمثل منطقة ميتة يتم كشفه عند لحظات التغيير ضمن المجال الذي يحوي المنطقة الميتة أي حول 0 غالباً.

F- استخدام تابع الكثافة الاحتمالي

تقوم الفكرة على تحديد تابع الكثافة الاحتمالي للبارامترات في رحلة خالية من الشذوذات ثم حساب انزياح (الوسطي والانحراف المعياري) في الحالات التي تحوي شذوذ. ولكن الفكرة لا تعطي نتيجة صحيحة في حالتنا لأن الكثافة الاحتمالية تقوم على حساب التكرار في قيم البارامترات، وفي حالة بارامترات الطيران فتكرار وقوع البارامترات ضمن مجال ما ليس له معنى خاصة أننا نتعامل مع سلاسل زمنية غير مستقرة، أي أن خصائصها الإحصائية غير ثابتة. وللتأكد من عدم صحة الفكرة قمنا باستخدام 3 ملفات تدريب اثنين منها لا يحويان أي شذوذ والثالث يحوي عطل تغيير في عزم العطالة الطولي. كل من الملفات يحوي 6 بارامترات تمثل بارامترات الحركة الطولية قصيرة الدور.

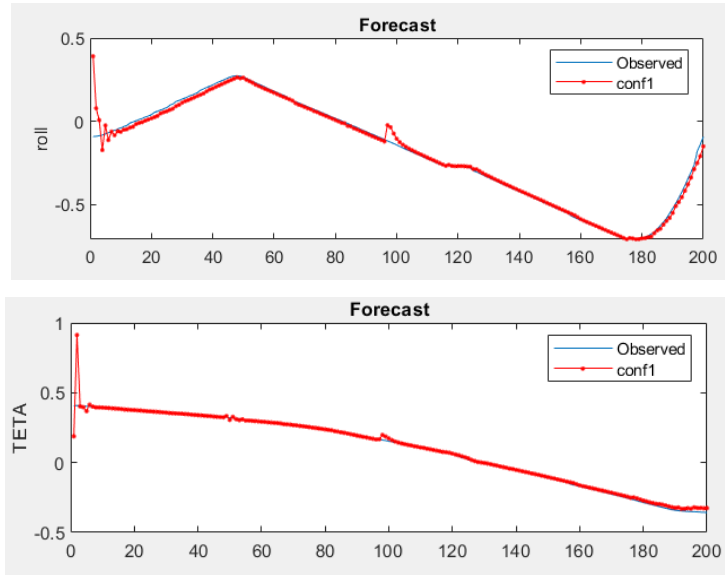
قمنا بتطبيق تابع Mvnpdf الذي يقوم بحساب تابع الكثافة الاحتمالي للبارامترات ضمن التوزيع الطبيعي  $(\mu, \sigma)$ . حيث  $\mu$  هو شعاع المتوسط الحسابي لكل بارامتر، و  $\sigma$  هو شعاع الانحراف المعياري. أظهرت النتيجة وجود انزياح في الوسطي أكبر من  $3\sigma$  بين الملفين اللذين لا يحويان أي شذوذ وأقل من  $3\sigma$  بين الملف الذي يحوي شذوذ وملف آخر سليم. وبالتالي لا يمكن اعتماد تابع الكثافة الاحتمالي لبارامترات متعددة للكشف عن الشذوذ في هذه الحالة.

تمت توسعة التجربة على كامل مجموعة التدريب المولدة في ماتلاب حيث قمنا بدراسة انزياح الوسطي لبارامترات الحركة القصيرة لكافة الملفات عن أحد الملفات السليمة وأظهرت نتيجة مشابهة أي لم نتتمكن من تحديد الملفات التي تحوي أعطالاً من الملفات السليمة من خلال الاعتماد على تابع الكثافة الاحتمالي.


3-3-4- مجموعة بيانات X-Plane

نتائج اختبار الحركة طويلة الدور: عدد بارامترات الدخل لخطوتين زمنيتين 48 بارامتراً. عدد بارامترات الخرج 10 بارامتر حصلنا عليها بتطبيق LASSO على أمر التحكم بالمحرك مع باقي بارامترات

الدخل. حجم مجموعة التدريب تقريباً 15,000 شعاع. عدد العناصر الخفية 60 استغرق التدريب حوالي 3 دقائق. ويبين الشكل (46) نتيجة التنبؤ مع التصحيح 5 ثواني للأمام لكل من زاوية دوران الطائرة حول المحور الطولاني R، وزاوية الغوص TETA في الشكل (47)، ونلاحظ ازدياد قيمة RMSE إلى رتبة  $10^{-1}$  ويفسر ذلك بزيادة تعقيد النموذج المدروس ليشتمل بارامترات القناة العرضية والتوجه وإضافة بعض بارامترات المحرك، ويبين الجدول (4) أخطاء التنبؤ لبعض بارامترات الحركة قصيرة الدور وطويلة الدور لشبكة LSTM، واكتفينا بشبكة LSTM بسبب أن نتائجها كانت أدق عند الاختبار على مجموعة بيانات ماتلاب.



الشكل 46- نتائج التنبؤ لزاويتي الغوص والدوران للحركة قصيرة الدور في مجموعة X-Plane

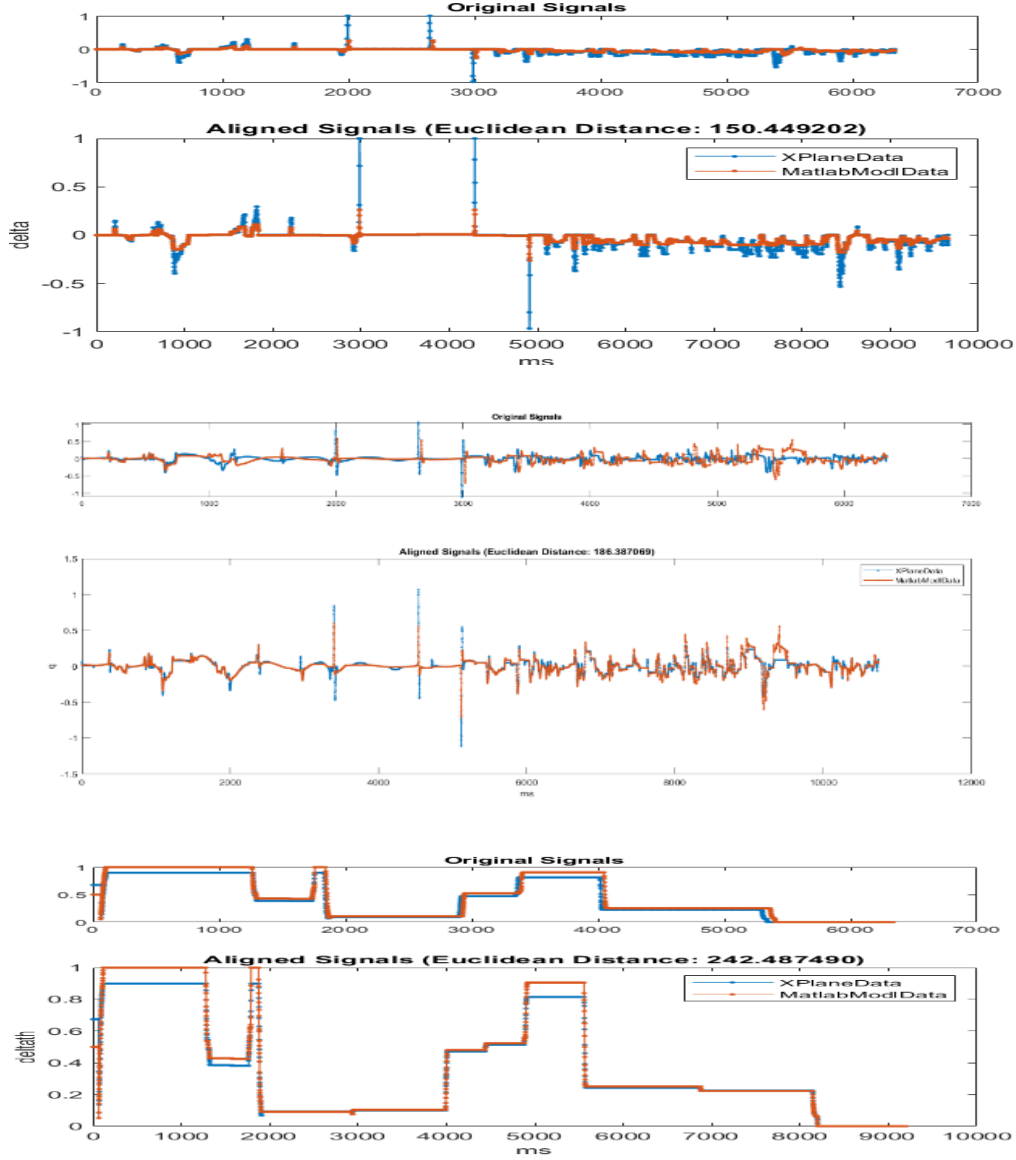


الشكل 47- نتائج التنبؤ للسرعة ودوران المحرك للحركة طويلة الدور في مجموعة X-Plane

الجدول 4- أخطاء التنبؤ لبعض بارامترات الحركة قصيرة الدور وطويلة الدور لشبكة LSTM

0.3042	TETA	قصيرة الدور
0.2112	Q	
0.2261	Alpha	
0.1752	ROLL	
0.2100	V	طويلة الدور
0.2032	RPM	
0.1261	OILP	
0.8963	H	

مقارنة استجابة نموذج الحركة الطولية المصمم محلياً مع نموذج برنامج X-Plane 10  
 تمكنا بواسطة عصا اللعب من تسجيل معطيات من كلا النموذجين X-Plane ونموذج ماتلاب بشكل  
 متزامن لمدة لا تتجاوز 10 دقائق. أظهرت التجربة تشابهاً بين استجابة النموذجين ويفسر عدم تطابق الإشارتين  
 بشكل كامل إلى أن قيم البارامترات في نموذج ماتلاب يعتمد على مجموعة صغيرة من البارامترات في حساب  
 ديناميك الطائرة للحركة الطولية فقط، ويبقى نموذج Simullink مبسطاً عن برنامج المقلد. وتمت مقارنة الأداء  
 باستخدام قياس التشابه بين سلسلتين زمنيتين DTW كونها تستخدم مع الإشارات مختلفة الأطوال كما ذكرنا في  
 الفصل الثالث فقرة (3-5-1). ويبين الشكل (48) ابتداءً من الأعلى التشابه بالاستجابة لكل من البارامترات  
 انحراف العصا على القناة الطولية Delta، ومعدل غوص الطائرة Q، ومقود التحكم بالمحرك Delta  
 Throttle.



الشكل 48- مقارنة استجابة المقلد *X-Plane* مع النموذج في *MATLAB* على بعض البارامترات


#### 4-3-4- استنتاج علاقات السببية من مصفوفة أوزان شبكة التعلم

كما ذكرنا سابقاً ترتبط البارامترات بين بعضها البعض عن طريق مجموعة من المعادلات التفاضلية العادية اللاخطية، بالإضافة لمجموعة من المعادلات التي توصف الترابطات السينيماتيكية بين البارامترات الحركية للطائرة كما ذكر بالفصل الأول فقرة (1-2).


مثلاً ترتبط زاوية الغوص  $Teta$  بالبارامترات التالية في اللحظة السابقة: زاوية انحراف كل من دفة العمق ومقود التحكم بالمحرك بالإضافة لمقدار تغيرها  $q$ . إن تغير قيمة زاوية انحراف دفة العمق يتسبب بتغير

زاوية الغوص Teta أما تغير انحراف مقود التحكم بالمحرك فيتسبب بتغير بزاوية الغوص ولكن بوزن أقل وكذلك الحال بالنسبة لمعدل الغوص باللحظة السابقة إن هذه التغيرات تؤدي إلى تغير بارتراف الطائرة في المستوي الشاقولي.


نلاحظ من البيانات التالية تغير تأثير البارامترات بين بعضها عند حدوث شذوذات وتميل لتشكيل بيان مختلف في كل حالة للمسألة المدروسة. لم تستكمل اختبارات هذا النموذج بسبب عدم وجود ملفات اختبار كافية للدراسة الإحصائية اللازمة لتحديد سلوك البارامترات وتأثيرها على بعضها خلال الزمن من أجل بناء نموذج احتمالي للأعطال يمكننا بالتنبؤ بحصول عطل بشكل مبكر، وسنقوم باستكمالها في المستقبل القريب. قمنا بتطبيق عامل تنظيم Lasso على مصفوفة أوزان الشبكة العصبونية لبارامترات الدخل والتغذية الراجعة ودراسة أثرها على معاملات بارامترات الخرج فقط، باستخدام WO في مصفوفة الأوزان في شبكة LSTM ونلاحظ في الشكل (49) الذي يعبر عن العلاقات السببية بين البارامترات في الحالة الطبيعية نلاحظ عدم وجود وصلة بين  $\langle Teta, Q \rangle$  وبين  $\langle PrevDeltath, Q \rangle$ ، تظهر الوصلتان الأولى والثانية في حالة عطل تغير العزم الطولي في الشكل (50)، وتخفي الوصلة  $\langle Alpha, Q \rangle$  من بيان عطل المنطقة الميتة في الشكل (51). كما يظهر لدينا اتجاه الترابطات عبر الزمن من اللحظة الزمنية الأقدم إلى الأحدث فقط.



الشكل 49- بيان العلاقات السببية للحركة الطولية بدون أعطال من مجموعتي اختبار مختلفتين 1،2



الشكل 50- بيان العلاقات السببية للحركة الطولية يمثل تغير في عزم العطالة الطولي من المجموعتين 1،3



الشكل 51- بيان العلاقات السببية للحركة الطولية يمثل عطل منطقة ميتة بالقناة الطولية من المجموعتين 8، 10

#### 4-4- التوصيات

- عمل تقييم ودراسة إحصائية وتوثيق النتائج.
- العمل على زيادة وثوقية عمل نظام التنبؤ المقترح.
- استكمال تقييم وعمل دراسة إحصائية للبيانات الناتجة من الكشف عن العلاقات السببية للبارامترات.

#### 4-5- الآفاق المستقبلية

- توسعة النموذج بإضافة باقي الحركات العرضية والاتجاه بكافة بارامتراتهما. والاستفادة من بارامترات المطار والجو والملاحة حيث يمكن الاستفادة من بارامترات المطار في تنظيم الحركة الجوية للطائرات والإقلاع والهبوط، بينما نستفيد من معطيات الملاحة الجوية في زيادة كفاءة التنبؤ في النموذج المقترح. وبناء نموذج احتمالي للأعطال.
- استخدام الكشف المبكر عن الأعطال عن طريق السياق: يتم تحسين كشف الأعطال عن طريق تحديد مرحلة الطيران phase of flight ومن خلال اعتمادية بعض البارامترات على بعضها البعض في تعريف سياق البارامترات. ويتم تحديد مرحلة الطيران من خلال إما خوارزميات تعتمد على قواعد موجودة مسبقاً لكل صنف من أصناف الطائرات أو من خلال خوارزميات تعلم آلي تحت الإشراف لتصنيف مراحل الطيران. والاستفادة من البيانات الدلالية في ذلك.
- تعميم النموذج للعمل على سرب من الطائرات حيث يمكن توسعة النظام بحيث يعمل على مراقبة بارامترات سرب من الطائرات معاً. بحيث أولاً يستفاد من خبرات التعلم الناتجة من بارامترات طائرة ما لباقي طائرات السرب. بالإضافة إلى تنظيم استهلاك الموارد كالوقود وعمليات الصيانة، والإنذار المبكر في كل طائرة على حدة. وتخزين الرحلات في مخزن معطيات مناسب لتحليل ما بعد الرحلة كحساب العمر الفني للطائرة.
- بناء مخزن معطيات للرحلات: تتميز معطيات الرحلات الطيرانية أنها مرتبة زمنياً خلال فترات زمنية متساوية، ويمكن حفظ كل سلسلة زمنية متعددة البارامترات لرحلات الطيران والأحداث التي حصلت خلال الزمن ومعلومات الرحلة، طول الرحلة وطاقم الطيارين منفذي الرحلة، المهمة المنفذة، وغيرها من المعطيات بهدف الحصول على معلومات وإحصاءات وتقارير مفيدة من خلال تطبيق بعض نماذج التنقيب عن المعطيات. كما يمكن تدريب نظام خبير يقوم بمراقبة ومتابعة حالة الطائرة لمعرفة عمرها الفني وجاهزيتها للعمل.

#### 6-4- الخاتمة

قدمنا من خلال هذا البحث نموذج أولي لمراقبة بارامترات طائرة خفيفة باستخدام عدة نماذج منها الشبكات العصبونية العودية LSTM و NARXNET بالإضافة لنموذج الانحدار الذاتي متعدد البارامترات VARM، حيث تم التنبؤ بقيم البارامترات لكل من دوري الحركة السريعة والبطيئة للطائرة بدقة عالية وأظهرت النتائج قدرة LSTM على التنبؤ بدقة أعلى من كل من NARXNET و VARM. أعطت نتيجة التنبؤ باستخدام LSTM خطأ نسبياً لا يتجاوز 3% لمدة 3 ثواني من قيمة البارامترات وهي مدة مناسبة للإنذار عن حصول عطل بالمنظومة. كما تمت الاستفادة من التنبؤ في تحليل الأخطاء الناتجة في كشف الشذوذات من أجل كل نافذة معتمدين على كشف السببية بين البارامترات بتطبيق LASSO على مصفوفة أوزان الشبكة العصبونية لتحديد قيم تأثير بارامترات الدخل على الخرج حيث نتمكن من دراسة سلوك العلاقات السببية للبارامترات بين بعضها عبر الزمن وتقديم نموذجاً لكشف الأعطال.

لتنفيذ النموذج المقترح قمنا أولاً ببناء نموذج للحركة الذاتية الطولية للطائرة بدورها القصير والطويل، مستفيدين من ذلك بتخفيض حجم البيانات المتولد في السلسلة الزمنية متعددة البارامترات من خلال تجزئتها إلى جزأين بحسب ترددات نمطي الحركة السريعة والبطيئة حيث انخفض حجم البيانات 10 مرات في السلسلة الزمنية متعددة البارامترات الخاصة بالحركة البطيئة لنفس عدد العينات خلال الدور الواحد لكل من نمطي الحركة. كما قمنا أيضاً بمقارنة أداء هذا النموذج مع أداء برنامج المحاكاة X-Plane للحركة الطولية من خلال تحصيل نفس البارامترات في النموذجين وقياس التشابه بينهما.

- [1] M. Cook, Flight Dynamics Principles, Burlington: Elsevier Ltd, 2007.
- [2] S. NEUMARK, Techn.Sc.D. and A.F.R.Ae.8. , "Analysis of Short-period Longitudinal Oscillations of an Aircraft-Interpretation of Flight Tests," NACA AERONAUTICAL RESEARCH COUNCIL REPORTS AND MEMORANDA, London, 1956.
- [3] U. Durak, J. Becker, S. Hartmann and N. S. Voros, Advances in Aeronautical Informatics - Technologies Towards Flight 4.0, Springer, 2018.
- [4] a. s. c. S. Cowell, Interviewee, *what-real-time-tracking-why-dont-airplanes-use-it*. [Interview]. 1 May 2014.
- [5] V. Emmanuell, A. ZAMFIROIU and R. BONCEA, "Big Data in the Aerospace Industry," *Informatica Economică vol. 22*, p. 8, 2018.
- [6] س. م. شعراوي، مقدمة في التحليل الحديث للسلاسل الزمنية، جدة: مركز النشر العلمي - جامعة الملك عبد العزيز، 2005.
- [7] P. Turner, "time series analysis and climate change," 4 June 2019. [Online]. Available: <https://towardsdatascience.com/time-series-analysis-and-climate-change-7bb4371021e>.
- [8] J. Zhang and P. Zhang, Time Series Analysis Methods and Applications for flight data, Beijing: Springer, 2017.
- [9] "Deseasonalized data - Oxford Reference," 2008. [Online]. Available: <https://www.oxfordreference.com/view/10.1093/oi/authority.20110803095712605>.
- [10] K.-L. DU and M. N. S. SWAMY, Neural Networks and Statistical Learning, research gate, 2013.
- [11] ع. درويش، "بناء نظام للتنبؤ بالخارطة الصحية في سورية،" المعهد العالي للعلوم التطبيقية والتكنولوجيا، دمشق، 2019.
- [12] K. I. Q. H.-K. L. B. X. X. Yin, "Three layer feed forward fully connected neural network," October 2016. [Online]. Available: [https://www.researchgate.net/figure/Three-layer-feed-forward-fully-connected-neural-network\\_fig8\\_309200152](https://www.researchgate.net/figure/Three-layer-feed-forward-fully-connected-neural-network_fig8_309200152).
- [13] "A Beginner's Guide to LSTMs and Recurrent Neural Networks," 20. [Online]. Available: <https://pathmind.com/wiki/lstm>.
- [14] Colah, "Understanding LSTM Networks," 2015. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [15] Z. Boussaada, O. Curea, A. Remaci, H. Camblong and N. Bellaaj, "A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation," *MDPI*, 2018.

- [16] T. Schack, M. Muma, M. Feng, C. Guan and A. M. Zoubir, "Robust Nonlinear Causality Analysis of Non-Stationary Multivariate Physiological Time," *IEEE*, p. 14, 2016.
- [17] د. خازم، منهجيات البحث العلمي، دمشق، 2018.
- [18] T. Aste and T. D. Matteo, "Sparse Causality Network Retrieval from Short Time Series," *Hindawi*, p. 14, 2017.
- [19] A. Tank, A. Shojaie, I. Covert, N. J. Foti and E. B. Fox, "Neural Granger Causality for Nonlinear Time Series," *stat.ML*, p. 18, 2018.
- [20] E. Alizadeh, M. El Koujok, A. Ragab and M. Amazouz, "A Data-Driven Causality Analysis Tool for Fault Diagnosis in Industrial Processes," *ScienceDirect*, p. 6, 2018.
- [21] T. Schack, M. Muma, M. Feng, C. Guan and A. M. Zoubir, "Robust Nonlinear Causality Analysis of Non-Stationary Multivariate Physiological TimeSeries," *ieeexplore*, p. 14, 2018.
- [22] MathWorks, "LSTM Layer," in *Matlab Help*, 2018.
- [23] C. Glymour, K. Zhang and P. Spirtes, "Review of Causal Discovery Methods Based on Graphical Models," *Frontiers*, p. 15, 2019.
- [24] D. Taunk, "l1-vs-l2-regularization-which-is-better," 15 March 2020. [Online]. Available: <https://medium.com/analytics-vidhya/l1-vs-l2-regularization-which-is-better-d01068e6658c>.
- [25] mathworld.wolfram, "<https://mathworld.wolfram.com/Weight.html>," mathworld.wolfram, 2020.
- [26] C.-H. Lee, H.-S. Shin, A. Tsourdos and Z. Skaf, "Anomaly Detection of Aircraft Engine Data in FDR," in *IET 3rd International Conference on Intelligent Signal Processing*, London, 2017.
- [27] H. Goel, I. Melnyk, N. Oza, B. Matthews and A. Banerjee, "Multivariate Aviation Time Series Modeling: VARs vs. LSTMs," *semantic scholar*, p. 13, 2016.
- [28] L. Basora, X. Olive and T. Dubot, "Recent Advances in Anomaly Detection Methods Applied to Aviation," *MDPI*, p. 28, 2019.
- [29] S. Li, Y. Yang, L. Yang, H. Su, G. Zhang and J. Wang, "Civil Aircraft Big Data Platform," in *International Conference on Semantic Computing*, Beijing, 2017.
- [30] S. Kaushik, "introduction-to-feature-selection-methods-with-an-example-or-how-to-select-the-right-variables," analyticsvidhya, 12 Dec. 2016. [Online]. Available: <https://www.analyticsvidhya.com/blog/2016/12/introduction-to-feature-selection-methods-with-an-example-or-how-to-select-the-right-variables/>.
- [31] J. Brownlee, "feature-selection-with-real-and-categorical-data," machinelearningmastery, 20 August 2020. [Online]. Available: <https://machinelearningmastery.com/feature-selection-with-real-and-categorical-data/>.

- [32] S. Lakshmanan, "how-when-and-why-should-you-normalize-standardize-rescale-your-data," 16 May 2019. [Online]. Available: <https://towardsai.net/p/data-science/how-when-and-why-should-you-normalize-standardize-rescale-your-data-3f083def38ff>.
- [33] A. Stepchenko, J. Chizhov, L. Aleksejeva and J. Tolujew, "Nonlinear, Non-stationary and Seasonal Time Series Forecasting Using Different Methods Coupled with Data Preprocessing," *ScienceDirect*, p. 8, 2016.
- [34] NASA, "mkad-synthetic-data," NASA, 2 5 2019. [Online]. Available: <https://catalog.data.gov/dataset/mkad-synthetic-data>.
- [35] M. Nauta, D. Bucur and C. Seifert, "Causal Discovery with Attention-Based Convolutional Neural Networks," *MDPI*, p. 28, 2019.
- [36] A. H. Kassem, "Efficient Neural Network Modeling for Flight and SpaceDynamics Simulation," *Hindawi*, p. 8, 2011.
- [37] "Flight\_Dynamics\_Model," 29 March 2020. [Online]. Available: [http://wiki.flightgear.org/Flight\\_Dynamics\\_Model](http://wiki.flightgear.org/Flight_Dynamics_Model).
- [38] T. Hastie, R. Tibshirani and M. Wainwright, *Statistical Learning with Sparsity*, CRC Press, 2016.

## ملحق بارامترات الطائرة

الرقم	البارامتر	الوحدة	النمط	التغير	الوصف
1	Time	Ms			الوقت المنقضي منذ تحميل الطائرة في المقعد.
2	Vind	Knots	خرج	بطيء	مؤشر السرعة الهوائية بالعقدة.
3	VVI	Fpm	خرج	بطيء	معدل التسلق.
4	Elevator	قيمة بين -1 و 1	دخل	سريع	انحراف عصا القيادة يؤدي لدوران الطائرة حول الأفقي
5	Aileron	قيمة بين -1 و 1	دخل	سريع	انحراف عصا القيادة يؤدي لدوران الطائرة حول المحور الطولاني
6	Elevn	Deg	خرج	سريع	انحراف دفة العمق.
7	Lailn	Deg	خرج	سريع	انحراف الجنيح الأيسر
8	Railn	Deg	خرج	سريع	انحراف الجنيح الأيمن
9	rudrn	Deg	خرج	سريع	انحراف دفة الاتجاه
10	Flap	3 أوضاع	دخل	سريع	أمر تحكم وضعية القلابات
11	Flap	Deg	خرج	سريع	انحراف القلابات
12	Thron	قيمة بين 0 و 1	دخل	بطيء	أمر التحكم بالثروتل
13	Alpha	Deg	خرج	سريع	زاوية هجوم الطائرة.
14	Beta	Deg	خرج	سريع	زاوية الانزلاق الجانبي للطائرة.
15	Pitch	Deg	خرج	سريع	زاوية الغوص
16	Hding	Hding	خرج	سريع	اتجاه الطائرة.
17	roll	Deg	خرج	سريع	زاوية دوران ميل الطائرة
18	Mixtn	قيمة بين 0 و 1	دخل	بطيء	أمر تحكم مزيج الهواء والقود
19	mixtn	قيمة بين 0 و 1	خرج	بطيء	نسبة مزيج الهواء والقود
20	alt	Feet	خرج	بطيء	ارتفاع الطائرة عن سطح الأرض
21	Q	rad/s	خرج	سريع	معدل الغوص.
22	R	rad/s	خرج	سريع	معدل ميل الطائرة
25	P	rad/s	خرج	سريع	معدل اتجاه الطائرة

الضغط المنتشعب في المحرك	بطيء	خرج	inhg	MP	26
تدفق الوقود في المحرك	بطيء	خرج	lb/h	FF	27
حرارة غاز العادم	بطيء	خرج	deg	EGT	28
درجة حرارة رأس الأسطوانة في المحرك	بطيء	خرج	deg	CHT	29
ضغط زيت المحرك	بطيء	خرج	psi	OILP	30
حرارة زيت المحرك	بطيء	خرج	deg	OILT	31
ضغط وقود المحرك	بطيء	خرج	psi	FUEP	32