

تحسين متحكم تنبؤي MPC قائم على النموذج باستخدام نموذج احصائي هجين ARIMA/GARCH

مقادراً بالبيانات / دراسة تطبيقية مقارنة على بيانات OhioT1DM

رود الأصفر * د. جمانا دياب ** د. أحمد كردي ***

(الإيداع: 10 كانون الثاني 2025، القبول: 15 آذار 2026)

الملخص:

يُعد المتحكم التنبؤي MPC القائم على النموذج من أكثر خوارزميات التحكم استخداماً في الأنظمة الطبية الحيوية، إذ يعتمد بشكل جوهري على دقة النموذج الرياضي الذي يُبنى عليه. فكلما كان النموذج أكثر قدرة على تمثيل ديناميكيات النظام، انعكس ذلك على أداء المتحكم وفعاليته. ومن هنا تتبع أهمية تحسين النماذج الرياضية لتطوير المتحكمات القائمة على النموذج مما يعزز الأداء الكلي للنظام.

يهدف هذا البحث إلى تطوير متحكم تنبؤي قائم على نموذج رياضي ديناميكي باستخدام نماذج ARIMA/GARCH لتحسين دقة التنبؤ بمستوى الجلوكوز في الدم لدى مرضى السكري من النوع الأول. يتم دمج النموذج الهجين التنبؤي ضمن إطار (MPC) Model Predictive Control لحساب جرعات الأنسولين المثلى، مع مراعاة القيود السريرية والعملية المرتبطة بالأنظمة الطبية الحيوية.

يمثل الإسهام العلمي لهذا العمل في ابتكار إطار هجين يجمع بين قدرة نماذج ARIMA على النقاط الاتجاهات الزمنية وقدرة نماذج GARCH على توصيف تقلبات التباين، مما يوفر نموذجاً أكثر دقة ومرونة للتنبؤ. إضافةً إلى ذلك، يقدم البحث مقارنة شاملة لأداء النموذج المقترح مع نماذج في التعلم العميق (مثل LSTM و DRL) والتعلم الآلة (مثل XGBoost و LightGBM و CatBoost)، وغيرها من النماذج المستخدمة في أحدث الدراسات السابقة وذلك باستخدام نفس مجموعة البيانات القياسية OhioT1DM.

أظهرت النتائج أن النموذج الهجين المقترح قدم أداءً أفضل في التنبؤ، مما عزز من فعالية المتحكم التنبؤي في الأنظمة الطبية الحيوية T1DM.

الكلمات المفتاحية: المتحكم التنبؤي MPC، نموذج هجين ARIMA/GARCH، مرض السكري T1DM، بيانات OhioT1DM.

*طالبة دكتوراه – اختصاص التحكم الآلي و الحواسيب – كلية الهندسة الميكانيكية – جامعة حمص..
** أستاذ مساعد - قسم التحكم الآلي والحواسيب - كلية الهندسة الميكانيكية - في جامعة حمص.
*** مدرس – اختصاص أمن المعلومات نظم سكادا – كلية التطبيقية - جامعة حماة.

1- مقدمة

يُعد المتحكم التنبؤي القائم على النموذج (MPC - Model Predictive Control) من أبرز أدوات التحكم الحديثة التي أثبتت فعاليتها في التعامل مع الأنظمة الديناميكية المعقدة، خاصة تلك التي تتطلب قرارات دقيقة في الزمن الحقيقي. تعتمد هذه التقنية على نموذج رياضي يُستخدم لتوقع (تنبؤ) سلوك النظام المستقبلي، ومن ثم حساب إجراءات التحكم المثلى التي تحقق الأداء المطلوب، مع مراعاة القيود المفروضة على النظام.

تُستخدم هذه المنهجية في العديد من المجالات مثل الأنظمة الصناعية والطبية، ويُعد البنكرياس الاصطناعي مثالاً تطبيقياً بارزاً، حيث يستخدم MPC لحساب جرعات الأنسولين بناءً على التنبؤ بمستوى الجلوكوز في الدم. ومع ذلك، فإن هذا البحث لا يركز على التطبيق الطبي بحد ذاته، بل يهدف إلى تصميم نموذج تنبؤي ديناميكي باستخدام نماذج ARIMA/GARCH ودمجه ضمن إطار تحكم MPC، مع تقييم أدائه مقارنةً بنماذج التعلم العميق مثل LSTM و DRL والتعلم الآلة وغيرها من النماذج المستخدمة في دراسات سابقة حديثة وذلك على نفس مجموعة بيانات OhioT1DM القياسية.

2- الدراسات السابقة:

تُقسم الدراسات السابقة في مجال التنبؤ بمستوى الجلوكوز إلى نوعين رئيسيين: دراسات ركزت على بناء النموذج التنبؤي فقط، وأخرى ركزت على بناء النموذج الرياضي ودمجه ضمن إطار تحكم تنبؤي قائم على النموذج (MPC).

-الدراسات التي اهتمت ببناء النموذج فقط على قاعدة بيانات OhioT1DM

قدم Domanski وآخرون [1]مقالة تقترح منهجية جديدة لنمذجة السلاسل الزمنية لمستويات الجلوكوز في الدم لدى مرضى السكري من النوع الأول، وذلك باستخدام شبكة مشفرة-فك مشفرة (وهي بنية شبكية تتكون من جزأين: جزء المشفرة الذي يحول البيانات إلى تمثيل مضغوط يلخص المعلومات المهمة، وجزء فك التشفير الذي يعيد بناء أو يتنبأ بالبيانات المستقبلية بناءً على هذا التمثيل) ذات اتصالات كثيفة بالاقتران مع شبكة LSTM ، وصياغة المهمة كمسألة تعلم معزز عميق (DRL) وقام الباحثون بتقييم النتائج باستخدام مجموعة بيانات أوهايو (OhioT1DM) كمعيار مرجعي. وتم المقارنة بالأعمال السابقة التي حققت أفضل دقة تنبؤية، فقد حققت الطريقة المقترحة باستخدام التعلم المعزز تحسناً بنسبة 18.4% و 22.5% في أفق التنبؤ لمدة 30 دقيقة و 45 دقيقة على التوالي، وذلك وفقاً لمتوسط الخطأ المطلق MAE والجذر التربيعي لمتوسط مربع الأخطاء RMSE.

بينما قدم Nemat وآخرون عام 2023 [2] مقالة تقوم بدراسة العلاقات السببية بين مستوى الجلوكوز في الدم (BGL) والمتغيرات المؤثرة في إدارة السكري من النوع الأول (الكربوهيدرات، الأنسولين البولي، النشاط البدني) باستخدام منهجي CCM و ECCM لقياس قوة السببية والتأخير الزمني الأمثل. ثم استُخدمت هذه المعلومات كمعرفة مسبقة لتحسين نموذجي التنبؤ LSTM و CRNN على بيانات أوهايو (OhioT1DM) للتنبؤ بمستوى الجلوكوز لمدة 30 و 60 دقيقة، عبر منهجيتين مبنيتين على السببية (CCMBA و ECCMBA) لدمج معلومات السببية في عملية التنبؤ. في نهج CCMBA، استُخدمت قوة السببية كأوزان للمتغيرات. أما في نهج ECCMBA، فتم استخدام التأخير الزمني الأمثل للسببية كإزالة (Shift) لكل متغير، مرجحاً بقوة السببية المقابلة له.

أظهرت النتائج أن بيانات النشاط البدني (HR/MA) تمتلك أقوى علاقة سببية مع الجلوكوز مقارنة بالكربوهيدرات أو الأنسولين، كما أن نهج CCMBA أكثر فعالية من نهج ECCMBA في توظيف معلومات السببية لتحسين التنبؤ بمستوى الجلوكوز في الدم.

فعلى الرغم من أن النهج المقترحة تم اختبارها على نموذجين للتنبؤ فقط ومجموعتي بيانات اوهايو 2018 و2020، إلا أنه يلزم إجراء مزيد من التقييم لقابلية تطبيقها على نماذج ومجموعات بيانات أخرى للتنبؤ بمستوى الجلوكوز في الدم مع مقارنتها بطرق أخرى أيضاً.

أما Musa وآخرون عام 2025 [3] قدموا مقالة تهدف إلى تقييم أداء نماذج التعلم الآلة والتعلم العميق المختلفة في التنبؤ بمستوى جلوكوز الدم (BGL) لدى مرضى السكري من النوع الأول، معتمدة على بيانات مجموعة OhioT1DM المكونة من قراءات مستمرة لـ 12 مريضاً.

استخدمت الدراسة مجموعة متنوعة من النماذج تشمل نماذج التعلم الآلة التقليدية مثل الانحدار الخطي ونماذج التعزيز التدريجي (XGBoost, LightGBM, CatBoost)، إضافة إلى نماذج التعلم العميق LSTM و Bi-LSTM.

تم تقييم هذه النماذج عبر إعدادين: أحادي المتغير (باستخدام قيم الجلوكوز السابقة فقط) ومتعدد المتغيرات (يشمل ميزات إضافية مثل جرعات الإنسولين وقياسات فيزيولوجية أخرى).

ركزت الدراسة على فترتي تنبؤ رئيسيتين هما 30 و 60 دقيقة، واستخدمت مقاييس دقيقة شاملة مثل جذر متوسط مربع الخطأ (RMSE) ومعامل التحديد (R^2) لمقارنة أداء النماذج بطريقة تشمل جميع المرضى.

أبرزت النتائج أن نموذج LSTM أقدم أفضل أداء في أفق التنبؤ لمدة 30 دقيقة بإحراز أدنى RMSE وأعلى R^2 في الإعداد أحادي المتغير، في حين تفوق Bi-LSTM في تنبؤات أطول أو إعداد متعدد المتغيرات ولكنه كان أكثر استهلاكاً للموارد الحسابية. بالمقابل، حققت نماذج التعزيز التدريجي أداءً مقارباً مع كفاءة حسابية أعلى بكثير مقارنة بالتعلم العميق. تقدم هذه الدراسة دليلاً قوياً على قدرة نماذج التعلم الآلة المتقدمة على تحقيق نتائج تضاهي أو تفوق نماذج التعلم العميق، مع توفير موارد حسابية أقل، مما يجعلها مناسبة أكثر للتطبيقات السريرية الحية ذات القيود الزمنية والحاسوبية.

كما قدم Nemat وآخرون عام 2024 [4] دراسة هدفت إلى مقارنة فعالية عدة أساليب تعتمد على البيانات للتنبؤ بمستوى الجلوكوز من حيث دقة التنبؤ، سرعة التدريب، وأثر استخدام مدخلات متعددة مقابل استخدام متحول واحد فقط. استخدمت الدراسة مجموعتين من بيانات Ohio T1DM تتضمن بيانات من 12 مريضاً، تشمل بيانات الجلوكوز، جرعات الإنسولين، تناول الكربوهيدرات، ومستوى النشاط البدني.

استخدمت طرق ومنها: طرق السلاسل الزمنية (CTF Classical Time Series Forecasting) كنموذج ARIMA، التعلم الآلي التقليدي (TML Traditional Machine Learning) SVM، والشبكات العصبية العميقة (DNN).

المدخلات: قورنت بين نموذجين، أحدهما يستخدم مدخل واحد (univariate) وهو بيانات الجلوكوز فقط، والآخر متعدد المتغيرات (multivariate) يشمل بيانات إضافية مثل الكربوهيدرات والإنسولين والنشاط البدني.

التقييم: استخدمت معايير تقييم إحصائية وطبية مثل RMSE، MAE، معامل ارتباط ماثيو (MCC)، وشبكة الخطأ السريري (SE)، إلى جانب اختبارات إحصائية للتأكد من الفروق بين النماذج.

النتائج أشارت إلى أن النماذج كانت متقاربة الأداء في كثير من الحالات، لكن نموذج التعلم الآلة التقليدي (TML) كان يتفوق في الدقة خاصة عند استخدام مدخلات متعددة كما كان الأسرع من حيث وقت التدريب.

لم تتحسن دقة التنبؤ بشكل كبير مع إضافة المتغيرات الإضافية في بعض النماذج، بينما في نماذج أخرى مثل TML لوحظ تأثير إيجابي.

تحليل البيانات أظهر أن استخدام المتحول الواحد (بيانات الجلوكوز فقط) كان كافياً.

قدم Krishnamoorthy وآخرون عام 2024 [5] مقالة تم تنفيذ نماذج الشبكات العصبية القائمة على تعلم الآلة للتنبؤ بمستويات الجلوكوز والكوليسترول في الدم، حيث استخدمت خوارزمتا التنبؤ ARIMA (المتوسط المتحرك التكاملية الذاتي) و LSTM (الذاكرة قصيرة الطويلة الأجل) للتنبؤ بمستويات الجلوكوز والكوليسترول عبر بيانات متغيرة زمنيًا. وأستخدم نموذج ARIMA للتنبؤ بالتغيرات الديناميكية للجلوكوز والكوليسترول في الوقت الفعلي، بينما تمتلك LSTM القدرة على التقاط السياق الحالي والسابق لتسلسل المدخلات بشكل أفضل، مع تعلم تحديد الميزات الرئيسية، وإزالة الضوضاء الخلفية، والاحتفاظ بالتبعيات طويلة الأجل. تم إجراء مقارنة تنبؤية بين نمودجي ARIMA و LSTM. ونظرًا لإجراء تجربة في الوقت الفعلي للتحقق من دقة التنبؤات بناءً على بيانات مراقبة الجلوكوز المستمرة (CGM) حيث أن البيانات المستخدمة في هذه المقالة لم تكن بيانات أوهايو، فقد استنتجت النتائج التجريبية أن نموذج التنبؤ ARIMA يمكنه تحسين دقة التنبؤ بنجاح مقارنة ب LSTM.

دراسات قامت ببناء نموذج وتطبيقه ضمن المتحكم القائم على النموذج

تتناول دراسة Aiello وآخرون [6] 2023 تصميم وتقييم نظام للتحكم في حقن الأنسولين بشكل آلي يعتمد على نمودجين رئيسيين للتحكم وهما نمودج (LSTM-MPC (Long Short-Term Memory – Model Predictive Control متعدد الخطوات حيث يعتمد على شبكة الذاكرة الطويلة القصيرة الأجل (LSTM) للتنبؤ بمستويات الجلوكوز في الدم لعدة خطوات مستقبلية.

يتم تدريب الشبكة العصبونية على بيانات أجهزة قياس الجلوكوز المستمرة (CGM)، جرعات الأنسولين السابقة، والكربوهيدرات المتأولة، المخرجات هي تنبؤات دقيقة لتركيزات الجلوكوز المستقبلية وأيضاً تم دمج هذه المخرجات مع نمودج التحكم التنبؤي الخطي المتغير بالزمن (LTV-MPC) لتحسين الأداء العام.

بينما النمودج الثاني نمودج (ARX-MPC (Auto-Regressive with Exogenous – Model Predictive Control يستند إلى نمودج الانحدار الذاتي مع المدخلات الخارجية (ARX) للتنبؤ بمستوى الجلوكوز خطوة واحدة للأمام، تم تحديد النمودج من بيانات CGM السابقة والحالية، جرعات الأنسولين السابقة، والكربوهيدرات المتأولة.

تمت مقارنة وتقييم النمودجين عبر محاكاة عددية في ثلاثة سيناريوهات: الحالة الاسمية (ثلاث وجبات يوميًا)، اضطرابات وجبات عشوائية، وحالة انخفاض حساسية الأنسولين بنسبة 25%. تم قياس مؤشرات الأداء باستخدام مقاييس غلوكوزية رئيسية منها: المتوسط (Mean) لمستويات الغلوكوز [mg/dl]، معامل التباين (CV): لقياس تقلبات الغلوكوز، النسبة المئوية للوقت في نقص سكر الدم ($54 >$ و $70 >$ mg/dl)، النسبة المئوية للوقت في النطاقات المقبولة ($70-140$ و $70-180$ mg/dl)، النسبة المئوية للوقت في فرط سكر الدم ($180 <$ و $250 <$ mg/dl).

أثبتت الدراسة أن نمودج LSTM-MPC متعدد الخطوات يتفوق على النمودج التقليدي ARX-MPC من حيث دقة التنبؤ وأداء التحكم التنبؤي العام للبنكرياس الصناعي. ومع ذلك، أوصت الأعمال المستقبلية بالتركيز على تطوير نماذج أكثر دقة لتأثير الأنسولين على ديناميكيات الجلوكوز.

قدم Sonzogni وآخرون [7] 2023 خوارزمية التحكم التنبؤي بالنموذج (MPC) القائمة على CHoKI تقو بإدارة الأنسولين القاعدي بشكل آلي، بينما تبقى جرعات ما بعد الوجبة (bolus) يدوية في مرضى السكري من النوع الأول (T1D) الخوارزمية (CHoKI (Componentwise Hölder Kinky Inference) CHoKI-based MPC هي طريقة تعلم قائمة على البيانات (Data-driven) وهي طريقة رياضية غير معلمية، تُبنى على بيانات تجريبية، وتستخدم حدود رياضية (من استمرارية هولدر والتي تقول ان التغير في المخرجات متناسباً مع قوة (أس) معينة من التغير في المدخلات) لضمان استقرار التنبؤات، كما انها تستفيد من الإحصاءات لتقدير الخطأ وضبط النموذج. تم استخدام محاكي UVA/Padova المعتمد من FDA منظمة الغذاء والدواء، والذي يحاكي مرضى افتراضيين (بالغين، مراهقين، أطفال).

تم تصميم وحدة التحكم MPC بهدف الإبقاء على الجلوكوز ضمن النطاق المرغوب (70–180 mg/dL) بالإضافة الى أفق التنبؤ $N_p = 12$ (أي 60 دقيقة)، حيث أجريت محاكاة لثلاثة أيام، مع ثلاث وجبات يومياً (g40، g100، g60 كربوهيدرات) فكانت مستويات الجلوكوز بقيت معظم الوقت ضمن النطاق المرغوب (70–180 mg/dL)، وكما تم ملاحظة انخفاض واضح في أحداث نقص سكر الدم مقارنة بالعلاج التقليدي بالأنسولين القاعدي الثابت. كما جرى تحليل CVGA (Control Variability Grid Analysis) وتحليل TIR (Time In Range) من أجل تقييم أداء المتحكم، أثبتت الخوارزمية CHoKI-based MPC فعاليتها في تقليل أحداث نقص سكر الدم والحفاظ على المرضى ضمن النطاق المرغوب معظم الوقت.

أهمية البحث : إن نمذجة سلسلة التغيرات المتتابة لمستوى الجلوكوز تعد مصدراً غنياً بالمعلومات التي تحمل في طياتها التأثير التدريجي لنوع الطعام أو النشاط البدني أو النوم... الخ، وبالتالي يمكن استخدامه لبناء نموذج تنبؤي فعال دون الحاجة إلى إدخال المتغيرات الأخرى بشكل صريح، وهذا ما يتوافق مع الواقع الحقيقي حيث لا يستطيع المريض تحديد كمية الكربوهيدرات التي تناولها أو السرعات الحرارية التي تم حرقها أو غيرها، وبالتالي لا يمكن من الناحية الواقعية أن يقوم المريض بتلقين المتحكم بهذه المدخلات، وإنما يقع على عاتق المتحكم تقدير كل ذلك بنفسه وبشكل ذاتي لتقدير مستوى السكر المتوقع في الدم وتقدير جرعة الأنسولين المناسبة وهذا ما يهدف إليه هذا البحث.

وبالتالي فإن أهمية البحث تكمن في تطوير متحكم تنبؤي يعتمد على نماذج هجينة ARIMA، GARCH لتحسين دقة التنبؤ بالأنظمة الديناميكية المعقدة، مع دمجها ضمن إطار MPC لضبط الأداء والتحكم الأمثل. يقدم البحث تقييماً لأداء هذا النموذج مقارنة بتقنيات التعلم العميق والتعلم الآلة المستخدم في الدراسات السابقة وذلك لنفس قاعدة البيانات OhioT1DM القياسية، مما يعزز الجوانب العملية ويوفر حلاً دقيقاً للتحكم في نظم حساسة كالتحكم في مرض السكري، ويمهد الطريق لتطوير تقنيات تحكم أكثر كفاءة وموثوقية.

3- المتحكم القائم على النموذج التنبؤي MPC model predictive controller

هو إستراتيجية تحكم ظهرت في الستينات للتعامل مع الأنظمة الكبيرة والمعقدة متعددة المداخل والمخارج (MIMO). يعتمد أساساً على استخدام نموذج رياضي ديناميكي للنظام للتنبؤ بسلوكه المستقبلي. تعمل الخوارزمية بشكل متكرر على [8] :

1. التنبؤ: استخدام النموذج الحالي وبيانات النظام للتنبؤ بسلوك المخرجات على مدى أفق تنبؤ (Prediction Horizon) محدد.

2. التحسين: حساب سلسلة من إجراءات التحكم المستقبلية (على مدى أفق تحكم - Control Horizon) التي تقلل دالة تكلفة (Objective Function) لتعظيم أداء النظام مع مراعاة القيود المفروضة على المدخلات والمخرجات.

3. التطبيق: يتم تطبيق أول أمر تحكم فقط من التسلسل المحسوب على النظام الفعلي، ثم تُكرر العملية بأكملها في الخطوة الزمنية التالية، وهي تقنية تعرف بـ تحكم الأفق المتراجع (Receding Horizon Control).

إن جملة معادلات الحالة الخطية في الزمن المتقطع: [9]

$$x_{k+1} = Ax_k + Bu_k + Gw_k \quad (1)$$

$$y_k = Cx_k + \varepsilon_k \quad (2)$$

حيث إن: x_k هو شعاع الحالة الذي يتم التحكم بكل عنصر منه.

u_k الدخل في اللحظة الحالية.

w_k الضجيج الواقع على المتحولات الحالية.

y_k الخرج الحالي القابل للقياس.

ε_k ضجيج القياس.

4. تابع الكلفة قادراً على التعامل مع الأنظمة متعددة المداخل والمخارج، ولا بد من هذه الأوزان التي تُعطى ضمن تابع الكلفة بشكل مصفوفات لكل من الدخل W_u والخرج W_y تساعد في توضيح أولويات التحكم للتحكم التنبؤي.

$$J = \sum_{i=n_w}^{n_y} \|W_y(y_{k+i} - y_{k+i})\|_2^2 + \lambda \sum_{i=0}^{n_u-1} \|W_u(\Delta u_{k+i})\|_2^2 \quad (3)$$

حيث المصفوفتان W_y و W_u قطريتان موجبتان $W_y = 1$ و $W_u = 1$ يتم عادة تمثيل النظام بالشكل الواحد مما يجانس عملياً بين حلقات النظام

$y(k+i)$ المخرج المتوقع في الخطوة $k+i$

$r(k+i)$ الإشارة المرجعية (Reference Signal) في الخطوة $k+i$ القيمة المثالية التي يجب أن يتبعها المخرج.

$\Delta u(k+i)$ التغير في إشارة التحكم (Control Input Change)

$$\Delta u(k+i) = u(k+i) - u(k+i-1) \quad (4)$$

4- نماذج السلاسل الزمنية ARIMA و GARCH

تُعد السلاسل الزمنية سجلاً تاريخياً للملاحظات المرتبة زمنياً، ويهدف تحليلها إلى الكشف عن الأنماط السائدة للتنبؤ بالمستقبل، بناءً على فرضية أن الماضي يؤثر على الحاضر والمستقبل.

من أشهر هذه المنهجيات منهجية بوكس-جينكينز (Box-Jenkins)، والتي تعتمد على نماذج ARIMA للسلاسل المستقرة. تتبع هذه المنهجية خطوات تشمل: التحقق من استقرار السلسلة (عادةً باستخدام اختبار Dickey-Fuller المعزز (ADF)، وتحديد رتب النموذج، وتقدير معلماته، ثم تشخيصه واختبار ملاءمته، وأخيراً استخدامه للتنبؤ [10].

تعتمد نماذج ARIMA على مزيج من ثلاثة مكونات:

1. نموذج الانحدار الذاتي (AR(p)): حيث تعتمد القيمة الحالية على قيمها السابقة.

وذلك كما يلي:

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \alpha_t \quad (5)$$

حيث أن: Y_t : قيمة المتغير في الفترة (t) وهي القيمة المراد التنبؤ بها (المتغير التابع).

$\phi_1, \phi_2, \dots, \phi_p$: معاملات الانحدار.

α_t : حد الخطأ العشوائي (الضوضاء البيضاء) وهو حد لا يمكن نمذجته.

$Y_{t-1}, Y_{t-2}, Y_{t-p}$: قيم المتغير في الفترات السابقة حتى الفترة (p) وهو ما يسمى بالتأخر الزمني أو التباطؤ.

2. نموذج المتوسط المتحرك ((MA(q)): حيث تعتمد القيمة الحالية على أخطاء التنبؤ السابقة.

ويتم التعبير عنها من خلال العلاقة التالية:

$$Y_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \quad (6)$$

حيث أن: $\alpha_t, \alpha_{t-1}, \alpha_{t-q}$: الحدود العشوائية الحالية والسابقة والتي تشكل عملية ضجة البيضاء (الأخطاء).

$\theta_1, \theta_2, \dots, \theta_q$: معاملات نموذج الانحدار والتي يتم تقديرها من البيانات.

3. التكامل I (Integrated): هو عملية تحويل السلسلة الزمنية غير الثابتة إلى سلسلة ثابتة عبر أخذ فروق متتالية للقيم.

لتحقيق مرونة أكبر في نمذجة السلسلة الزمنية، من المفيد في بعض الأحيان تضمين نموذج الانحدار الذاتي (AR) ونموذج

المتوسط المتحرك (MA) في نموذج التنبؤ الأساسي، وهذا يعني أن يكون النموذج الناتج هو نموذج خليط بين نماذج الانحدار

الذاتي ونماذج المتوسطات المتحركة ARMA(p,q). ويمكن التعبير عن هذا النموذج من خلال العلاقة التالية:

$$Y_t = \{ \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} \} + \{ \alpha_t - \theta_1 \alpha_{t-1} - \dots - \theta_q \alpha_{t-q} \} \quad (7)$$

عادةً ما تتميز السلاسل الزمنية بتقلبات حادة في بياناتها، مما يؤدي إلى عدم استقرار التباين (Heteroskedasticity). إذ

تظهر لهذه السلاسل فترات تمتد فيها التقلبات بشكل واسع تتبعها فترات ذات تقلبات أقل أو شبه ثابتة، وقد يكون لها تأثير

واضح يشير إلى نمط ARCH. وبناءً عليه، تستدعي هذه الظاهرة استخدام نموذج يُعرف باسم "الانحدار الذاتي المشروط بعدم

تجانس التباين" الذي قدمه Engle، والذي يُشار إليه اختصارًا بـ (ARCH).

والممثلة في العلاقة التالية:

$$var(u_t) = \sigma^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-2}^2 + \dots + \alpha_p u_{t-p}^2 \quad (8)$$

حيث $var(u_t)$ تمثل تباين حد الخطأ (البواقي) في الفترة (t)، فإذا كان لا يوجد ارتباط ذاتي بين مربعات حدود الأخطاء

(تباين الخطأ) فإن فرضية العدم هي: $\{ H_0: \alpha_1 = \alpha_2 = \dots = \alpha_p = 0 \}$ فإذا تحقق ذلك فإن $\{ var(u_t) = \alpha_0 \}$

وبالتالي فإنه لا يوجد أثر لنموذج ARCH[11]

نموذج الانحدار الذاتي المشروط بعدم تجانس التباين المعمم، المعروف اختصاراً بـ (GARCH) يظهر أن تقلب المتغير

المدرّوس لا يعتمد فقط على مربعات الأخطاء للفترة السابقة كما هو الحال في نموذج ARCH، بل يستند أيضًا على تباين

المتغير في الفترة السابقة. وبما أنه من الممكن أن تكون مربعات الأخطاء والتباينات مرتبطة ببعضها عبر فترات زمنية متعددة،

فهو ما يتيح تعميم النموذج إلى نموذج GARCH (p,q).

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \quad (9)$$

5- بناء النموذج الهجين المقترح والمتحكم التنبؤي MPC القائم على النموذج واختباره

7-1 البيانات المستخدمة OhioT1DM :

تُعد مجموعتي بيانات OhioT1DM (Ohio_2018 و Ohio_2020) من مجموعات البيانات القياسية المتاحة للعامة والشائعة الاستخدام في أبحاث التنبؤ بمستوى الجلوكوز في الدم (BGL) لمرضى السكري من النوع الأول. تحتوي هاتان المجموعتان على بيانات غنية ومتنوعة تم جمعها من 12 متبرعاً (7 ذكور و 5 إناث) تتراوح أعمارهم بين 20 و 80 عاماً، كانوا يخضعون جميعاً للعلاج بمضخة الأنسولين، شملت فترة جمع البيانات ثمانية أسابيع لكل متبرع، وتم تخصيص آخر 10 أيام منها كمجموعة اختبار والباقي للتدريب. تضمنت البيانات المُجمعة: بيانات المستشعرات الحيوية أي قراءات مستمرة للجلوكوز (CGM) كل 5 دقائق، بيانات العلاج معلومات عن جرعات الأنسولين (Bolus)، وأيضاً أحداث معيشية وهي تقارير ذاتية عن تناول الكربوهيدرات (Carb) وأوقات الوجبات، بالإضافة إلى بيانات النشاط البدني وتم قياسها عبر أجهزة قابلة للارتداء، وشملت معدل ضربات القلب (HR) ومقدار التسارع (MA). تمت عملية جمع البيانات بطريقة تحافظ على الخصوصية، حيث تم إخفاء هوية المتبرعين تماماً. تمثل هاتان المجموعتان مصدراً قيماً بسبب شموليتها وتنوع الخصائص التي تتضمنها [12][13].

■ تحديد المدخلات المستخدمة من قاعدة البيانات OhioT1DM :

تتأثر مستويات سكر الدم في الجسم بشكل مباشر بروتين حياة المريض، بما في ذلك توقيت ونوع الطعام المتناول، النشاط البدني، النوم، والضغط النفسية. فعند تناول الكربوهيدرات، يقوم الجسم بتحويلها إلى جلوكوز يمتص في الدم، مما يؤدي إلى ارتفاع مستوى سكر الدم بشكل تدريجي. بالمقابل، يسهم النشاط البدني في خفض الجلوكوز تدريجياً عبر زيادة استهلاك الطاقة في الخلايا.

ومع ذلك، فإن تنظيم سكر الدم لا يعتمد على معرفة هذه المدخلات بشكل صريح، بل يتم داخلياً عبر آلية فسيولوجية دقيقة يقودها البنكرياس. ففي الجسم السليم، يراقب البنكرياس مستوى الجلوكوز بشكل مستمر، ويستجيب له مباشرة دون الحاجة إلى معرفة كمية الكربوهيدرات أو توقيت النشاط. عندما يرتفع الجلوكوز، تفرز خلايا بيتا في البنكرياس هرمون الإنسولين لتحفيز الخلايا على امتصاص الجلوكوز وخفض مستواه. وعندما ينخفض الجلوكوز، تفرز خلايا ألفا هرمون الغلوكاغون (Glucagon) لتحفيز الكبد على إطلاق الجلوكوز المخزن.

وبالتالي، فإن مستوى سكر الدم لا يمثل فقط حالة فسيولوجية لحظية، بل يحمل ضمنياً معلومات عن المدخلات السابقة التي أثّرت عليه، مثل تناول الكربوهيدرات أو ممارسة الرياضة. ومن هنا، فإن نمذجة سلسلة التغيرات المتتالية لمستوى الجلوكوز تُعد مصدراً غنياً للمعلومات التي تحمل في طياتها التأثير التدريجي لنوع الطعام أو النشاط البدني أو النوم... الخ، وبالتالي يمكن استخدامه لبناء نموذج تنبؤي فعال دون الحاجة إلى إدخال المتغيرات الأخرى بشكل صريح وبحسب الدراسة [4] التي أظهرت من خلال تحليل البيانات أن استخدام المتحول الواحد (بيانات الجلوكوز فقط) كان كافياً لإجراء عملية التنبؤ، وهذا ما يتوافق مع الواقع الحقيقي حيث لا يستطيع المريض تحديد كمية الكربوهيدرات التي تناولها أو السرعات الحرارية التي تم حرقها أو غيرها، وبالتالي لا يمكن من الناحية الواقعية أن يقوم المريض بتلقين المتحكم ويقع على عاتق المتحكم تقدير كل ذلك بنفسه لتقدير مستوى السكر المتوقع في الدم وهذا ما يهدف إليه هذا البحث.


الجدول رقم (1): يوضح بيانات المستخدمة من قاعدة البيانات Ohio [2].

	PID	BGL (training data)	BGL (testing data)
Ohio2018	559	10796	2514
	563	12124	2570
	570	10982	2745
	575	11866	2590
	588	12640	2791
	591	10847	2760
Ohio2020	540	11947	2896
	544	10623	2716
	552	9080	2364
	567	10858	2389
	584	12150	2665
	596	10877	2743

PID تشير الى رقم المريض

2-7 الية بناء النموذج التنبؤي والمتحكم MPC:

تم اعتماد قاعدة بيانات OhioT1DM، التي تحتوي على قياسات فعلية لمستوى سكر الدم لدى مرضى السكري من النوع الأول كما ذكرت في الشكل 1، وهي مُقسّمة مسبقاً إلى بيانات تدريب واختبار، مما يغني عن أي تقسيم إضافي. كما أن البيانات مرتبة زمنياً، وتشكل سلسلة زمنية جاهزة للنمذجة دون الحاجة إلى أي تحويل أو معالجة زمنية إضافية. المخطط التالي يبين بناء المتحكم MPC وآلية اختيار النموذجين:



الشكل رقم (1) : مخطط لآلية بناء المتحكم والنموذج الهجين المقترح

بدايةً، تم اختبار السلاسل الزمنية لمجموعة بيانات أوهايو الخاصة بجميع المرضى باستخدام اختبار ADF عبر البرنامج الإحصائي EVIEWS، وقد تبين أن جميع السلاسل مستقرة زمنياً. وبناءً على ذلك، فإن قيمة I في نموذج ARIMA تساوي صفر. سيتم بعد ذلك إيجاد وبناء النموذج الأمثل لكل مريض من خلال تحديد رتب التأخيرات الذاتية (AR) وعدد تأخيرات الضوضاء (MA) في نموذج ARIMA والتي تعطي أفضل أداء، بالإضافة إلى تحديد رتبة نماذج GARCH المرتبطة بتقلبات التباين، كما يتم تحديد عدد خطوات التنبؤ المطلوبة، ومستوى الثقة لحساب مجالات الثقة للتنبؤات، كما يلي.

أولاً تم تدريب نموذج ARIMA على بيانات التدريب لتقدير المعاملات المختلفة للنموذج وفق تراكيب AR و MA لتقييم مدى جودة النموذج ودقته في التنبؤ، بحيث يتم اختيار النموذج الأفضل عند التنبؤ على بيانات التدريب بناءً على الحصول على أقل قيمة RMSE (جذر متوسط مربع الخطأ)، وهذا لضمان قدرة النموذج على التعميم والتنبؤ بدقة على بيانات جديدة. وتم اختبار النموذج على بيانات جديدة (بيانات الاختبار) لم تستخدم أثناء التدريب.

بعد اختيار النموذج الأمثل من نماذج ARIMA، يتم اختبار وجود تقلبات في التباين باستخدام اختبار ARCH على بقايا النموذج (الفرق بين القيمة الحقيقية للقيمة الزمنية في السلسلة وقيمة التنبؤ التي أعطتها النموذج). وفي حال اكتشاف تأثير ARCH، يتم استخدام نموذج GARCH لنمذجة لتباين وبالتالي تحسين توقعات التباين. أي يتم بناء نموذج ARCH أو GARCH باستخدام بواقي نموذج ARIMA

من ثم يتم دمج نموذج GARCH بنموذج ARIMA الموجود، مع تجربة تراكيب مختلفة لرتب GARCH، واختيار النموذج الهجين الأمثل بنفس معيار RMSE للتنبؤ.

بناءً على النموذج الهجين النهائي، تم تنفيذ التنبؤ الديناميكي لبيانات الاختبار عبر نافذة متغيرة من بيانات الاختبار. يتم تحديث السلسلة الزمنية بالتنبؤات السابقة خطوة بخطوة، مما يسمح بالتنبؤ لعدد خطوات محدد من المستقبل وفق أفق 30 دقيقة وهي ما تعادل 6 خطوات وأيضاً وفق أفق 60 دقيقة أي 12 خطوة مع احتساب مجال الثقة (عبارة عن نطاق أو حدود دنيا وعليا لقيمة ما استناداً لخصائص العينة) حسب توزيع T أو التوزيع الطبيعي وذلك حسب حجم العينة المدروسة. تم قياس أداء النموذج من خلال RMSE لجميع خطوات التنبؤ وكذلك دقة المجال التنبؤي (مقدار وقوع القيم الحقيقية ضمن مجال الثقة).


الجدول رقم (2): يبين معادلات النموذج الأمثل وذلك لكل مريض من مرضى القاعدة البيانات OhioT1DM

2018/2020 وفقاً لعملية التدريب على بيانات الخاصة بكل مريض وذلك باستخدام برنامج Matlab:

رقم المريض PID	معادلة النموذج Arima/GArch	تفاصيل معادلة النموذج Arima/GArch
559	ARIMA(1,0,2)	$y_t = 1.7494 + 0.9895y_{t-1} + 0.2468\alpha_{t-2} + \alpha_t$
563	ARIMA(2,0,1)	$y_t = 2.7923 + 0.9813y_{t-2} + 0.9856\alpha_{t-1} + \alpha_t$
570	ARIMA(3,0,2)+ GARCH(2,2)	$y_t = 5.6040 + 0.9706y_{t-3} + 0.5155\alpha_{t-2} + \alpha_t$ $\sigma^2 = 9.7112 + 0.7833u_{t-1}^2 + 2.0000e - 12u_{t-2}^2 + 0.1056\sigma_{t-1}^2 + 0.1111\sigma_{t-2}^2$
575	ARIMA(1,0,2)	$y_t = 1.6194 + 0.9886y_{t-1} + 0.1906\alpha_{t-2} + \alpha_t$
588	ARIMA(2,0,1)	$y_t = 3.5101 + 0.9788y_{t-2} + 0.9944\alpha_{t-1} + \alpha_t$
591	ARIMA(5,0,2) + GARCH(2,2)	$y_t = 16.3680 + 0.8836y_{t-5} + 0.7148\alpha_{t-2} + \alpha_t$ $\sigma^2 = 9.7576 + 0.5195u_{t-1}^2 + 2.0000e - 12u_{t-2}^2 + 0.0116\sigma_{t-1}^2 + 0.4689\sigma_{t-2}^2$
540	ARIMA(3,0,2)	$y_t = 8.4487 + 0.9387y_{t-3} + 0.7088\alpha_{t-2} + \alpha_t$
544	ARIMA(5,0,2)	$y_t = 11.4101 + 0.9293y_{t-5} + 0.7571\alpha_{t-2} + \alpha_t$
552	ARIMA(5,0,2)	$y_t = 13.3780 + 0.9063y_{t-5} + 0.7333\alpha_{t-2} + \alpha_t$
567	ARIMA(5,0,2)	$y_t = 15.9582 + 0.8935y_{t-5} + 0.7324\alpha_{t-2} + \alpha_t$
584	ARIMA(5,0,1) + GARCH(0,0)	$y_t = 12.6725 + 0.9291y_{t-5} + 0.7618\alpha_{t-1} + \alpha_t$ $\sigma^2 = 308.9542$

596	ARIMA(4,0,1)	$y_t = 8.4529 + 0.9426y_{t-4} + 0.9885\alpha_{t-1} + \alpha_t$
-----	--------------	--

بعد اختيار النموذج الهجين الأمثل لكل مريض باستخدام ARIMA/GARCH، يتم دمجها ضمن إطار المتحكم التنبؤي (Model Predictive Control – MPC) لتحديد الجرعة المثلى للأنسولين بطريقة ديناميكية، تبدأ المنهجية بتحديد مستوى جلوكوز المستهدف (مثل 110 ملغ/دل)، إلى جانب تعيين الحدود العليا والدنيا للجرعات المسموح بها سريرياً وطبياً، وضبط معاملات تنظيمية مثل معامل الحساسية λ الذي يتحكم في تأثير التباين على القرار العلاجي ويختلف هذا العامل من مريض إلى آخر وقد تم أخذ قيمته بشكل عام 0.1 وبالإمكان تغيير قيمته تجريبياً حسب حساسية كل مريض لمادة الأنسولين، ويمكن توضيح شكل متحكم MPC المقترح بالمخطط الآتي:



الشكل رقم (2) : مخطط تفصيلي للمتحكم MPC المقترح

فيما يلي النتائج التالية باستخدام برنامج Matlab:

الجدول رقم (3): يبين نتائج التنبؤ للمتحكم MPC وفق النموذج الهجين لأفق تنبؤي 30 دقيقة أو بمعدل ست خطوات وذلك مقارنة مع طرق سابقة لدراسات مختلفة استخدمت نفس قاعدة البيانات ولنفس أفق التنبؤ وفق قيم RMSE لتقييم الأداء

PID	النموذج المقترح Arima/GArch	TML عام [4]2024	Lstm [2] عام 2023	Cnn [2] عام 2023	DRL learning [1] 2023
559	11.8023	20.56	19.718	20.499	19.372
563	10.5773	18.67	19.461	19.025	17.779
570	7.8639	17.24	16.639	19.838	15.803
575	11.0505	24.08	24.726	26.511	20.370
588	10.1868	21.28	17.877	21.879	15.024
591	10.2908	21.78	22.134	24.204	18.096
540	11.5502	29.07	21.328	26.596	19.254
544	8.6666	18.11	18.509	21.102	15.287
552	8.1690	17.01	16.769	19.262	14.499
567	11.5184	21.06	20.662	24.465	22.206
584	9.0934	21.88	21.734	23.648	24.306
596	9.6315	17.89	17.633	18.813	17.319
avg	10.0334	20.7192	19.7655	22.1535	18.2763

بالإضافة إلى مقارنة النموذج المقترح مع مجموعة طرق للتنبؤ في الدراسة [3] عام 2025 حيث اكتفت الدراسة السابقة بحساب المعدل لقيم RMSE لكل المرضى في مجموعة بيانات OhioT1DM لأفق تنبؤ 30 دقيقة.

الجدول رقم (4): مقارنة متوسط قيم RMSE لجميع المرضى للنموذج المقترح مع طرق أخرى في دراسة سابقة:

	النموذج المقترح	Linear regression	lightGBM	Xgboost	Catboost	Istm	Bi-Lstm
Rmse/avg	10.0334	15.44	14.73	14.98	14.77	13.65	14.48

نلاحظ من خلال الجدول السابقين (3) و(4) أن النموذج الهجين المقترح تفوق بوضوح في الأفق التنبؤي 30 دقيقة أي بمعدل 6 خطوات تنبؤ، وأظهر قدرة عالية على التنبؤ الدقيق، مما يجعله نموذجاً مناسباً في المتحكم التنبؤي للتنبؤ بمقدار جرعات الأنسولين اللازمة لكل مريض.

متابعة للمقارنة مع الدراسات السابقة تم بناء نتائج لأداء النموذج المقترح وذلك لأفق زمني 12 خطوة أي لمدة ساعة.

الجدول رقم (5): يبين نتائج التنبؤ للمتحكم MPC وفق النموذج الهجين لأفق تنبؤي 60 دقيقة أو بمعدل 12 خطوة وذلك مقارنة مع طرق سابقة لدراسات مختلفة استخدمت نفس قاعدة البيانات ولنفس أفق التنبؤ وفق قيم RMSE لتقييم الأداء

PID	النموذج المقترح	TML عام 2024 [4]	Lstm عام 2023 [2]	Cnn عام 2023 [2]
559	23.8853	35.69	32.588	31.522
563	18.2901	30.32	32.444	30.732
570	16.5291	29.50	28.869	30.219
575	21.7359	37.09	37.562	37.664
588	18.9554	31.43	30.833	33.501
591	18.4071	33.58	35.108	39.122
540	23.0022	44.81	40.895	42.054
544	17.0915	32.01	31.922	32.376
552	15.4604	29.76	30.051	32.486
567	21.1621	37.16	36.883	41.271
584	19.6846	36.77	40.812	37.576
596	16.2735	30.27	28.181	30.095
avg	19.2064	34.033	33.8457	34.8848

بالإضافة إلى مقارنة النموذج المقترح مع مجموعة طرق للتنبؤ في الدراسة [3] عام 2025 حيث اكتفت الدراسة السابقة بحساب المعدل لقيم RMSE لكل المرضى في مجموعة بيانات OhioT1DM لأفق تنبؤ 60 دقيقة.

الجدول رقم (6): مقارنة متوسط قيم RMSE لجميع المرضى للنموذج المقترح مع طرق أخرى في دراسة سابقة:

	النموذج المقترح	Linear regression	lightGBM	Xgboost	Catboost	Istm	Bi-Lstm
Rmse/avg	19.2064	24.41	23.40	23.59	23.37	45.46	21.73

نستنتج انه على الرغم أن الأفق الزمني الطويل يزيد من تعقيد التنبؤ، إلا أن النموذج المقترح أثبت قدرته على الحفاظ على دقة عالية، متفوقاً على نماذج التعلم العميق والتعلم الآلي، مما يجعله مناسباً لتطبيقات التحكم الاستباقي في إدارة مستوى سكر الدم.

كما في الشكل السابق (2) فإن توقعات الجلوكوز ناتجة عن نموذج Arima والتباين المتوقع الناتج عن نموذج GARCH تُستخدم كأساس لاتخاذ القرار بشأن جرعة الأنسولين، لذا واستناداً الى توقعات مستويات الجلوكوز المستقبلية والتباين المصاحب لها وذلك لكل نافذة زمنية، كما يُحسب أيضاً عرض مجال الثقة (الحدود العليا والدنيا) للتنبؤ. ففي حال كانت جميع التوقعات أقل من الهدف مع هامش أمان محدد، يتم إعطاء جرعة صفرية. أما إذا وُجدت مؤشرات لاحتمال ارتفاع الجلوكوز فتحسب الجرعة المثلى بناء على التوقعات، وفيما يلي التابع الأصلي لحساب الكلفة الذي يحدد المنطق الرياضي للقرار الذي يهدف إلى تقليل الفارق بين التنبؤ والهدف المرجعي، مع تقليل أثر التباين، وذلك ضمن حدود الجرعة المسموح بها كحدود طبية، بالمعادلة الآتية:

$$J(u) = \left(\sum_{i=1}^N (y_i - G)^2 + \lambda \cdot Var_i + \gamma \cdot IntervalWidth \right)$$

حيث:

y_i : التنبؤ بمستوى الجلوكوز في الخطوة

G : الهدف المرجعي للجلوكوز 110mg/dl

λ : معامل تنظيم (حساسية الانسولين) يحدد وزن التباين في القرار.

Var_i : التباين في التنبؤ الناتج عن GRCH

γ : معامل يحدد أهمية عرض مجال الثقة (قيمته 0.05 تعني أننا نعرض مجال ثقة 95%).

$IntervalWidth$: متوسط عرض مجال الثقة عبر الأفق محسوباً من الفرق بين الحد الأعلى والأدنى لكل نقطة تنبؤ.

ولأغراض الحل العددي باستخدام خوارزميات التحسين التربيعي عبر دالة حساب الأمثل quadprog، يُعاد صياغة هذا التابع في الشكل القياسي للبرمجة التربيعية:

$$\min_u \frac{1}{2} u^T H u + f^T u$$

حيث:

u : متجه الجرعات عبر الأفق التنبؤي.

H : مصفوفة تربيعية تمثل أوزان الانتظام والتحكم بحجم الجرعة لضبط الجرعة.

f : متجه خطي يُشتق من التنبؤات المستقبلية، الهدف المرجعي، التباين، وعرض مجال الثقة.

مع فرض قيود عملية على الجرعة

$$0 \leq u_i \leq 20, \forall i = 1, \dots, N$$

وتُستخدم الجرعة الناتجة كمتوسط عبر الأفق. بعدها، تُقارن الجرعة مع متوسط قيم الجلوكوز في النافذة الزمنية (6 خطوات و12 خطوة) لتحديد حالات الجرعات العالية وارتفاع الجلوكوز، ويُقيم منطق القرار بناءً على توافق الجرعة وحالة الجلوكوز. فيما يلي جداول تبين نتائج فعالية القرار السريري للمتحكم MPC من أجل حجم النافذة الزمنية (6 خطوات و12 خطوة)، وذلك من خلال معايير مثل الاسترجاع والدقة وعدد حالات الفشل في اتخاذ قرار بتخفيض الجرعة عندما يكون جلوز مرتفع [14]، وهي كما يلي:

- الدقة النوعية (Precision) تشير إلى نسبة تعبر عن مدى صحة التنبؤات الإيجابية أي حالة إعطاء جرعة عالية فعلاً عندما يكون الجلوكوز مرتفعاً.

$$\text{Precision} = \frac{TP}{TP + FP}$$

حيث: True Positive (TP): جرعة عالية مع جلوكوز مرتفع

True Negative (TN): جرعة منخفضة مع جلوكوز منخفض

False Positive (FP): جرعة عالية مع جلوكوز منخفض

- أما الاسترجاع (Recall) فهي كنسبة تقيس قدرة النظام على اكتشاف جميع حالات الجلوكوز المرتفع دون تفويت أي حالة، مما يقلل الأخطاء السلبية ويعتبر من أهم المؤشرات.

$$\text{Recall} = \frac{TP}{TP + FN}$$

حيث: False Negative (FN): جرعة منخفضة مع جلوكوز مرتفع

- مؤشر F1 يجمع بين الدقة النوعية والاسترجاع ليعطي مقياساً متوازناً لأداء النظام.

$$F1 = \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} * 2$$

- أما عدد مرات اتخاذ القرار يُحسب بقسمة عدد بيانات الاختبار لكل مريض على حجم النافذة الزمنية المستخدمة (6 أو 12 خطوة).

الجدول رقم (7): يبين نتائج تقييم قرار المتحكم MPC المحسن وفقاً للمعايير السابقة لأفق زمني 30 دقيقة أي 6 خطوات:

PID	عدد مرات اتخاذ القرار	الاسترجاع	مؤشر F1	FN
559	419	100%	94.08%	0
563	429	100%	96.80%	0
570	458	100%	99.30%	0
575	432	99.66%	93.38%	1
588	465	100%	97.25%	0
591	460	99.07%	90.30%	3
540	483	100%	94.06%	0
544	453	100%	93.67%	0
552	394	100%	88.24%	0
567	398	100%	92.19%	0
584	444	100%	94.00%	0
596	457	100%	92.39%	0

تشير نتائج الجدول إلى فعالية كبيرة في اتخاذ القرار السريري من قبل المتحكم MPC المحسن ضمن نافذة زمنية قدرها 30 دقيقة (6 خطوات)، حيث كانت نسبة الاسترجاع 100% في معظم الحالات، مما يدل على قدرة النظام على اكتشاف جميع حالات الجلوكوز المرتفع.

كما أن مؤشر F1 (يتجاوز 90% في جميع الحالات تقريباً) وهو ما يعكس توازناً جيداً بين الدقة النوعية والاسترجاع، ويعزز موثوقية النظام في اتخاذ قرارات الجرعة المناسبة، بينما أظهر FN في معظم المرضى صفراً وبالتالي لم يُسجل لديهم أي أخطاء سلبية، مما يعكس قدرة المتحكم MPC المحسن في اتخاذ قرارات دقيقة عند ارتفاع الجلوكوز. أما الحالات القليلة التي سُجلت فيها أخطاء (مثل المرضى PID575 و PID591)، فهي محدودة جداً مقارنة بعدد القرارات المتخذة، وسوف يتم تعديل هذه الأخطاء في التنبؤات المستقبلية والجرعات التالية، مما يعزز من موثوقية النظام واستجابته السريرية.

أما الجدول رقم (8): يبين نتائج تقييم قرار المتحكم MPC المحسن وفقاً للمعايير السابقة لأفق زمني 60 دقيقة أي 12

خطوة:

PID	عدد مرات اتخاذ القرار	الاسترجاع	مؤشر F1	FN
559	210	100%	93.82%	0
563	214	99.49%	98.25%	1
570	229	100%	98.14%	0
575	216	98.62%	89.66%	2
588	233	100%	96.35%	0
591	230	100%	87.85%	0
540	241	98.89%	90.36%	2
544	226	100%	93.51%	0
552	197	100%	86.67%	0
567	199	100%	91.25%	0
584	222	100%	93.37%	0
596	229	100%	91.25%	0

تُظهر نتائج الجدول أن المتحكم MPC المحسن حافظ على أداء ممتاز ضمن نافذة زمنية أطول (12 خطوة)، حيث كانت نسبة الاسترجاع 100% في معظم الحالات، بينما الحالات التي سُجلت فيها أخطاء سلبية محدودة، فهي لا تؤثر بشكل جوهري على موثوقية النظام، كما أنه سيتم تعديلها في التنبؤات المستقبلية والجرعات التالية، مما يعزز من دقة القرار السريري واستجابته الديناميكية.

6- النتائج والتوصيات:

أظهرت نتائج الدراسة أن النموذج الهجين المقترح ARIMA/GARCH، عند دمجها ضمن إطار تحكم تنبؤي MPC، حقق أداءً عالياً في التنبؤ بمستويات الجلوكوز لدى مرضى السكري من النوع الأول، وذلك على قاعدة بيانات OhioT1DM. تم تقييم النموذج وفق أفقين زمنيين (30 دقيقة و60 دقيقة)، باستخدام مؤشرات إحصائية (RMSE) وسريرية (F1، FN، Recall).
1- بلغ متوسط RMSE للنموذج المقترح 10.03 لأفق 30 دقيقة، و19.20 لأفق 60 دقيقة، وهو أقل من جميع النماذج المقارنة (Bi-LSTM، LSTM، DRL، TML، وغيرها).

2- سجل النموذج أداءً فريداً متميزاً في حالات متعددة، خاصة للمريض 570 الذي حقق $RMSE = 7.86$ (30 دقيقة) و16.52 (60 دقيقة).

3- سجل النظام نسبة استرجاع (Recall) بلغت 100% في معظم الحالات، مما يدل على قدرة عالية في اكتشاف حالات الجلوكوز المرتفع.

4- انخفض عدد الأخطاء السريرية من نوع FN بشكل ملحوظ، خاصة في الأفق القصير، مما يعزز موثوقية القرار العلاجي.


5- مؤشر F1 تراوح بين 88% و99%، مما يعكس توازناً جيداً بين الدقة النوعية والاسترجاع.


7- أظهر النموذج مرونة عالية في التعامل مع التباين وعدم اليقين، بفضل دمج نموذج (G)ARCH، حيث إنها غير موجودة في دراسات سابقة.


توصي الدراسة بما يلي:


1. اعتماد النموذج الهجين ARIMA/GARCH كخيار فعال لتنبؤ مستويات الجلوكوز في الأنظمة الطبية الحيوية، خاصة في التطبيقات التي تتطلب دقة عالية واستجابة سريعة.
2. إن دمج النموذج ضمن إطار MPC يتيح تحسين القرار العلاجي، وتقليل الأخطاء السريرية، مما يجعله مناسباً لتطبيقات الحيوية كالبنكرياس الاصطناعي.
3. استخدام الأفق القصير (30 دقيقة) في الحالات الحرجة أو غير المستقرة، حيث أظهر النموذج أداءً أعلى في هذا النطاق.
4. إجراء اختبارات سريرية مستقبلية للتحقق من فعالية النموذج في بيئة حية، وتقييم تأثيره على تحسين التحكم في مرض السكري.

ملحق 1 الجدول التالي يبين مخططات التنبؤات لأفق زمني 6خطوة وأفق زمني 12 خطوة وفق النموذج المقترح وذلك لكل مريض:









8- المراجع:

- [1] Domanski, P., Ray, A., Firouzi, F., Lafata, K., Chakrabarty, K., & Pflüger, D. (2023, July). Blood glucose prediction for type-1 diabetics using deep reinforcement learning. In *2023 IEEE International Conference on Digital Health (ICDH)* (pp. 339–347). IEEE.
- [2] Nemat, H., Khadem, H., Elliott, J., & Benaissa, M. (2023). Causality analysis in type 1 diabetes mellitus with application to blood glucose level prediction. *Computers in Biology and Medicine*, 153, 106535.
- [3] MUSA, T. O., ADJEVI, A., JACCOJWANG, D. O., ADELEYE, N., OPEYEMI, D. A., UZUN, S., ... & YAYLACI, S. (2025). Comparative Evaluation of Machine Learning and Deep Learning Models for Blood Glucose Prediction on the OhioT1DM Dataset.
- [4] Nemat, H., Khadem, H., Elliott, J., & Benaissa, M. (2024). Data-driven blood glucose level prediction in type 1 diabetes: a comprehensive comparative analysis. *Scientific reports*, 14(1), 21863.
- [5] Krishnamoorthy, U., Karthika, V., Mathumitha, M. K., Panchal, H., Jatti, V. K. S., & Kumar, A. (2024). Learned prediction of cholesterol and glucose using ARIMA and LSTM models—A comparison. *Results in Control and Optimization*, 14, 100362.
- [6] Aiello, E. M., Jaloli, M., & Cescon, M. (2023). Model Predictive Control (MPC) of an Artificial Pancreas with Data-Driven Learning of Multi-Step-Ahead Blood Glucose Predictors. *science direct ,Control Engineering Practice*, 144, 105810.
- [7] Sonzogni, B., Manzano, J. M., Polver, M., Previdi, F., & Ferramosca, A. (2023). CHoKI-based MPC for blood glucose regulation in artificial Pancreas. *IFAC-PapersOnLine*, 56(2), 9672–9677.
- [8] Qin, S. J., & Badgwell, T. A. (2003). A survey of industrial model predictive control technology. *Control engineering practice*, 11(7), 733–764.
- [9] S. Joe Qin, Thomas A. Badgwell, “A survey of industrial model

predictive control technology”, 2002.

[10]Box, G. E. P. & Jenkins, G. M. (1976), "Time Series Analysis Forecasting and Control", Revised Edition., Holden-Day, California.

[11] Gujarati, D., Porter, D., (2009), " BASIC ECONOMETRICS " 5th ed, McGraw-Hill/Irwin, New York, PP:791–796.

[12] C. Marling, R.C. Bunescu, The OhioT1DM dataset for blood glucose level prediction, in: 3rd International Workshop on Knowledge Discovery in Healthcare Data, 2675, 2018, pp. 60–63.

[13] C. Marling, R. Bunescu, The OhioT1DM dataset for blood glucose level prediction: Update 2020, in: 5th International Workshop on Knowledge Discovery in Healthcare Data, 2675, 2020, pp. 71–74.

[14] Sahid, M. A., Babar, M. U. H., & Uddin, M. P. (2024). Predictive modeling of multi-class diabetes mellitus using machine learning and filtering iraqi diabetes data dynamics. PloS one, 19(5), e0300785.