

Blood Glucose Regulation in Patients with Type 1 Diabetes Using Model Predictive Control and Data Reconciliation

M. Oliveira, E. Moreno, G. da Silva, and O. Sotomayor

Abstract— The need to have mechanisms and technologies for the control of blood glucose levels is essential for people who have diabetes of any type. In this way, this paper presents the results obtained of blood glucose control using Model Predictive Control (MPC) and digital Proportional Integral (PI) control, which has been simulated with virtual patients. Initially, a model describing the dynamics of glucose metabolism in the human body was elaborated and, to make the simulation more real, it was considered the action of disturbances and noises. After modeling the system, the controllers were developed. Signal processing and data reconciliation was done using the Kalman Filter. With the objective of improving the performance of the controllers, the feedback of reconciled data technique was used and the performance of the MPC controller was improved by 83.9% based on the elaborated cost function.

Index Terms—Type 1 Diabetes, Glucose Regulation, Model Predictive Control, Digital PI Control, Kalman Filter, Data Reconciliation.

I. INTRODUÇÃO

GLOBALMENTE, estima-se que 422 milhões de adultos viviam com diabetes em 2014, em comparação com 108 milhões de pessoas em 1980. A porcentagem de diabetes quase dobrou desde 1980, passando de 4,7% para 8,5% na população adulta [1]. Isso reflete um aumento nos fatores de risco associados, como excesso de peso ou obesidade. Ao longo da última década, a porcentagem de pessoas com diabetes aumentou mais rapidamente em países de baixa e média renda do que em países de alta renda.

Os atuais tratamentos médicos sugerem que os pacientes diabéticos façam de três a quatro medições diárias da glicose no sangue e aplique um número equivalente de injeções subcutâneas de insulina [2,3]. Desta forma o controle de insulina fica por conta do paciente, o que muitas vezes é um problema, pois, os pacientes acabam esquecendo-se de fazer a medição e quando percebem já estão passando mal.

Uma alternativa é utilizar um dispositivo conhecido como bomba de infusão de insulina que vai liberar uma quantidade de insulina de acordo com a necessidade do paciente.

M. C. Oliveira, Instituto Federal de Sergipe (IFS), Sergipe, Brasil, (email: eng.mcanuto@gmail.com) E. D. Moreno, Universidade Federal de Sergipe (UFS), Sergipe, Brasil, (email: edwdavid@gmail.com).

G. M. A. da Silva, Unidade de Ensino Superior de Feira de Santana (UNEF), Bahia, Brasil, (email: gm_as@yahoo.com.br).

O. A. Z. Sotomayor, Universidade Federal de Sergipe (UFS), Sergipe, Brasil, (email: oazs2007@hotmail.com).

No entanto, as bombas de insulina, por si só, não fazem o controle automático através de um sistema por realimentação, *feedback*. Ainda mais, é preciso dispor de um monitoramento externo utilizando um glicosímetro. Assim, se necessário, podem ser injetadas doses extras de insulina além da programada na bomba [4].

Uma nova alternativa que está sendo muito estudada recentemente é um dispositivo com um sistema de controle automático da insulina, também conhecido como “pâncreas artificial”. Este sistema é estruturado através de uma malha fechada (com realimentação), incluindo um sensor de glicose para medir a concentração de glicose no sangue. Esta informação é enviada para o sistema de controle que calcula a quantidade necessária de insulina a ser aplicada para manter as taxas de glicose no sangue em níveis normais, sem a intervenção do paciente [3].

A Fig. 1 mostra o diagrama esquemático da regulação da glicose com um “pâncreas artificial”, em que o paciente não precisa aplicar a insulina, visto que isto é feito de forma completamente automática.

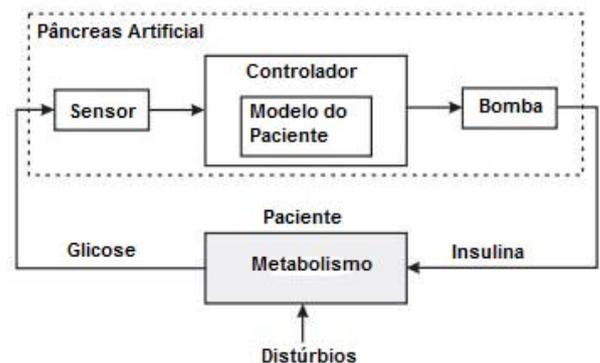


Fig. 1. Esquemático da regulação da glicose através do “pâncreas artificial” [5].

Para que o controlador possa funcionar com eficiência, é necessário um modelo matemático que represente de forma adequada a dinâmica glicose-insulina no paciente. Desta forma, no projeto do controlador por simulação, deve ser levado em consideração distúrbios e ruídos de medição para tornar o modelo mais realista possível.

A estratégia de controle preditivo *MPC* (Model Predictive Control) prediz a resposta futura do sistema, em cada intervalo de tempo, através de um modelo explícito do mesmo e de cálculos que utilizam a otimização quadrática.

Além disso, o controle preditivo é capaz de considerar restrições nas variáveis do sistema, tornando o controlador mais robusto, seguro e econômico. Como visto em [5, 6, 7, 8], aplicações do *MPC* para fazer a regulação da taxa de glicose no sangue já é algo factível.

Para que o controle preditivo funcione corretamente em um paciente real com diabetes, é necessário considerar os ruídos e os distúrbios que um sistema real pode proporcionar. Com isso, é necessário o uso de um estimador de dados. Entre as técnicas de estimação presentes na literatura, o Filtro de Kalman (*KF*) possui destaque devido ao fato de possuir uma estimação de natureza recursiva e de baixo custo computacional, o que proporciona uma rápida e eficiente estimação em tempo real.

O presente trabalho trata do desenvolvimento de um controlador *MPC* com reconciliação de dados para fazer o controle das taxas de glicose de um paciente virtual com diabetes tipo 1. O artigo está organizado em seis seções. Na seção 2 é apresentada a fundamentação teórica em paralelo com a revisão da literatura. A seção 3 consiste em apresentar os materiais e métodos utilizados no trabalho. Na seção 4 é realizada a análise dos resultados obtidos durante as simulações. Já, na seção 5, é feita a realimentação dos dados reconciliados e análise de desempenho do sistema e, por fim, na seção 6 são apresentadas as conclusões e ideias para trabalhos futuros.

II. FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA

Nesta seção será feita uma breve fundamentação teórica e revisão da literatura a respeito da diabetes, do modelo do metabolismo da glicose, do controle preditivo, da reconciliação de dados e do estimador Filtro de Kalman.

A. Diabetes

Diabetes Mellitus é uma doença crônica na qual o corpo não produz insulina ou não consegue empregar adequadamente a insulina que produz, causando elevação da taxa de glicose (hiperglicemia). A principal função da insulina, que é produzida no pâncreas, é controlar a quantidade de glicose no sangue. A falta de insulina ou um defeito na sua ação resulta, portanto, no acúmulo de glicose no sangue. Se esse quadro permanecer por muito tempo, poderá ocasionar sérios problemas de saúde e até a morte [9,10].

De acordo com [9, 10], existem três tipos de diabetes que ocorrem com maior frequência:

- i.* Diabetes tipo 1
- ii.* Diabetes tipo 2
- iii.* Diabetes gestacional

A diabetes tipo 1 (*i*) ocorre quando o sistema imunológico do indivíduo ataca as células beta, as quais são responsáveis pela produção da insulina no pâncreas, com isso, pouca ou nenhuma insulina é liberada no corpo. Resultando na elevação da taxa de glicose no sangue, em vez de ser utilizada como energia para o corpo. Cerca de 5% a 10% do total de pessoas com diabetes possuem este tipo que

geralmente ocorre na infância e na adolescência, mas pode ser diagnosticado em adultos também.

Outro tipo muito frequente de diabetes é o tipo 2 (*ii*) que é caracterizado quando o organismo não consegue usar adequadamente a insulina que produz, ou não produz insulina suficiente para controlar a taxa de glicemia. Este tipo de diabetes é mais comum e ocorre em 90% dos casos e se manifesta mais frequentemente em adultos, porém, crianças também podem apresentar.

A diabetes gestacional (*iii*) ocorre durante a gestação, normalmente por volta da vigésima quarta semana, devido às mudanças hormonais que a mulher passa durante o desenvolvimento do bebê. A placenta, por exemplo, é uma fonte importante de hormônios que reduzem a ação da insulina. O pâncreas, conseqüentemente, aumenta a produção de insulina para compensar este quadro. Em algumas mulheres, entretanto, o pâncreas não consegue compensar com o aumento de produção de insulina proporcional a necessidade da mulher e do bebê e, conseqüentemente, é desenvolvido um quadro de diabetes gestacional.

Na Tabela I são mostrados alguns dos sintomas, dos fatores de risco e das complicações que estão relacionados com os diferentes tipos de diabetes [1].

TABELA I
SINTOMAS, FATORES DE RISCO E COMPLICAÇÕES
DA DIABETES

Sintomas	Fatores de risco	Complicações
Sede anormal e boca seca	Obesidade	Doença cardiovascular
Vontade de urinar frequente	Dieta inadequada	Doença renal
Falta de energia	Falta de atividade física	Doença ocular
Fome constante	Idade avançada	Danos nos nervos
Perda de peso repentina	Histórico familiar de diabetes	
Feridas com cicatrizações lentas	Etnia	
Infecções recorrentes	Glicemia elevada durante a gravidez	
Visão embaçada		

A manutenção dos níveis de glicose no sangue, da pressão sanguínea e do colesterol pode ajudar a prevenir as complicações da diabetes. Por isso as pessoas diabéticas necessitam de um monitoramento regular da sua saúde por completo.

B. Modelo do Metabolismo da Glicose (Minimal Model)

Existem alguns modelos matemáticos que descrevem o metabolismo da glicose na corrente sanguínea propostos na literatura, como pode ser visto em [11]. Entre eles, o *minimal model* proposto por Bergman et al. (1981) [12] é o modelo

mais popular devido a sua simplicidade e reprodução da resposta fisiológica do sistema. O trabalho aqui apresentado utiliza o modelo de *Fisher* [13], o qual é uma versão modificada do *minimal model*. As equações que representam este modelo são:

$$\dot{G}(t) = -p_1 G(t) - X(t)[G(t) + G_B] + \frac{G_{meal}}{V} + D(t), \quad (1a)$$

$$\dot{X}(t) = -p_2 X(t) + p_3 I(t), \quad (1b)$$

$$\dot{I}(t) = -n[I(t) + I_b] + \frac{u(t)}{V}. \quad (1c)$$

A descrição dos parâmetros e das variáveis, assim como os valores de simulação dos mesmos utilizados neste trabalho são apresentados na Tabela II, de acordo com [7, 13, 14, 15].

TABELA II
PARÂMETROS E VARIÁVEIS DO MODELO

Parâmetro	Significado	Unidade
$G(t)$	Concentração de glicose	81,5 mg/dl
$I(t)$	Concentração de insulina	10,5 mU/l
$X(t)$	Proporção da insulina em um compartimento remoto	0,00546 mU/l
I_b	Insulina basal	4,5 mU/l
G_b	Glicose basal	4,5 mg/l
V	Distribuição do volume de insulina	12 l
G_{meal}	Glicose liberada pelo fígado	5,54 mg/dl
n	Taxa de desaparecimento de insulina endógena	$5/54 \text{ min}^{-1}$
p_1	Taxa de remoção da glicose do plasma para o fígado	0 min^{-1}
p_2	Taxa de desaparecimento de insulina no compartimento remoto	$0,025 \text{ min}^{-1}$
p_3	Taxa de aparecimento de insulina no compartimento remoto	0,000013 mU/l
$D(t)$	Distúrbio (ingestão de alimentos)	mg/(dl.min)
$u(t)$	Infusão de insulina exógena	16,5 mU/min

O distúrbio, $D(t)$, representa a taxa de glicose que entra na corrente sanguínea após a ingestão de alimentos. Para simular este distúrbio será utilizado o modelo visto em [11, 13, 16], o qual tem a seguinte representação:

$$D(t) = A \cdot e^{(-k \cdot t)}, \quad t \geq 0, \quad (2)$$

sendo A e k constantes.

C. Controle Preditivo (MPC)

O controle preditivo MPC se refere a uma classe de algoritmos de controle computacional que utiliza um modelo de processo para prever a resposta futura do sistema. Em cada intervalo de tempo, o controlador preditivo tende a otimizar a resposta futura do comportamento do sistema através dos cálculos de uma sequência de variáveis manipuladas. A princípio foi criado para atender as necessidades de controle de usinas e refinarias de petróleo,

porém, hoje em dia, a tecnologia de controle MPC já pode ser encontrada em várias aplicações, como nas áreas químicas, de processamento de comidas, automotivas, aplicações aeroespaciais e na área de engenharia biomédica [5, 17].

Uma das motivações mais importantes para utilizar o controlador preditivo é a habilidade que o mesmo tem para considerar restrições nas variáveis de estado e de controle. O controlador em questão pode controlar o sistema dentro de uma faixa limite e também consegue levar em consideração o *delay* que alguns sistemas podem apresentar para responder a uma entrada, o que torna mais interessante o seu uso no controle da taxa de glicose, visto que a dinâmica do metabolismo da glicose precisa de um pouco de tempo para começar a responder às aplicações de insulina [5].

A finalidade do MPC é encontrar o melhor ajuste da entrada do sistema $u(k)$, considerando as restrições, tal que a saída futura predita do sistema $\hat{y}(k+1)$ possa convergir para uma trajetória de referência do sistema $r(k+i|k)$ que leva para o *set point* do sistema $y_{sp}(k+i)$ o mais rápido possível. O controlador faz o melhor ajuste para a saída estimada dependendo do *set point* e da saída atual do sistema [5, 17]. Com relação aos distúrbios conhecidos a priori que afetam o sistema, o MPC pode compensar por antecipação os desvios que estes iriam causar na saída.

A otimização do MPC pode ser realizada através da minimização da função objetivo $J(k)$ em relação a Δu , levando em consideração o horizonte de controle (H_c) e o horizonte de predição (H_p). A função objetivo é geralmente apresentada como [5, 18]:

$$J(k) = \sum_{i=1}^{H_p} \|r(k+i|k) - \hat{y}(k+i|k)\|_{Q(i)}^2 + \sum_{i=0}^{H_c-1} \|\Delta \hat{u}(k+i|k)\|_{R(i)}^2,$$

em que $\Delta \hat{u}(k+i|k)$ é o incremento da variável manipulada no intervalo de tempo futuro, $k+i$, o qual é predito através do tempo atual, k . As variáveis $Q(i)$ e $R(i)$ são matrizes positivas definidas simétricas na forma quadrática, as quais podem ser em função do tempo. Os parâmetros de sintonia do controlador são os horizontes $H_p > H_c > 1$, as matrizes Q e R e a trajetória de referência r . Na Fig. 2 mostra-se o diagrama esquemático básico do controle MPC.

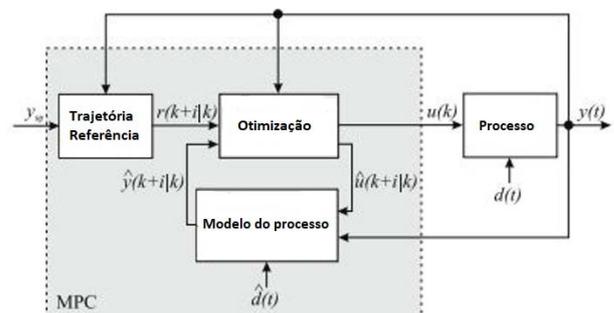


Fig. 2. Diagrama esquemático do controlador MPC. [5]

D. Reconciliação de Dados

O objetivo da reconciliação de dados é obter estimativas mais precisas para medições de variáveis do processo, utilizando a condição na qual estas se relacionam através de um modelo matemático. Desta forma o problema de reconciliação de dados é definido como um problema de minimização do erro quadrático entre as variáveis medidas e as do modelo, sujeitas as restrições, da seguinte forma [19, 20]:

$$\min_x S = \sum_{j=1}^P (\hat{y} - y)^T W^{-1} (\hat{y} - y)$$

sujeito a:

$$h(x, p, t) = 0$$

$$g(x, p, t) \leq 0$$

em que W é uma matriz de ponderação, diagonal definida positiva, \hat{y} o valor medido, y o valor real, h é um conjunto de equações de igualdade que corresponde ao modelo matemático do processo, g é um conjunto de equações de desigualdade representando limites operacionais e de validade, as quais as estimativas devem satisfazer. Estas equações relacionam as variáveis do modelo (x), dos parâmetros (p) e do tempo (t) [19, 20].

Somente é possível efetuar a reconciliação de dados com variáveis que contenham erros aleatórios ou estocásticos, pois quando existem erros grosseiros ou determinísticos, ocasionados possivelmente pela influência de falhas na medição ou falhas no próprio processo, os ajustes tornam-se expressivos e as medições reconciliadas podem não refletir a realidade desse processo. Portanto, primeiramente, deve-se efetuar o tratamento destes erros grosseiros para, em seguida, efetuar a reconciliação de dados propriamente dita. No presente trabalho serão considerados somente variáveis que contenham erros aleatórios [19, 20].

E. Estimador Filtro de Kalman (KF)

O Filtro de Kalman (KF), proposto por Kalman (1960), é um estimador ótimo para sistemas lineares da forma [20, 21]:

$$\begin{aligned} x_k &= A_{k-1}x_{k-1} + B_{k-1}u_{k-1} + w_{k-1} \\ y_k &= C_k x_k + v_k \end{aligned}$$

sendo que x é o vetor de variáveis de estado do sistema, A , B , e C são as matrizes do sistema com dimensões apropriadas, $w_{k-1} \sim N(0, Q_{k-1})$ e $v_k \sim N(0, R_k)$ são ruídos brancos com distribuição gaussiana descorrelacionados, u é a entrada do sistema e y é a saída do sistema.

O KF possui duas fases para realizar a estimação da variável desejada: predição e atualização. A fase de predição utiliza a estimativa do estado da iteração anterior para produzir uma estimativa do estado na iteração atual. Já, na fase de atualização, a medição da iteração atual e a covariância do erro são usadas para melhorar a medição e chegar a uma estimativa mais precisa do estado analisado. As equações que descrevem estas fases são apresentadas a seguir [22]:

i. Fase de Predição

$$\begin{aligned} \bar{x}_k &= A_{k-1}\hat{x}_{k-1} + B_{k-1}\bar{u}_{k-1} \\ \bar{P}_k &= A_{k-1}\hat{P}_{k-1}A_{k-1}^T + B_{k-1}P_{u,k-1}B_{k-1}^T + Q_{k-1} \end{aligned}$$

ii. Fase de Atualização

$$\begin{aligned} K_k &= \bar{P}_k C_k^T (R_k + C_k \bar{P}_k C_k^T)^{-1} \\ \hat{x}_k &= \bar{x}_k + K_k (y_k - C_k \bar{x}_k) \\ \hat{P}_k &= (I - K_k C_k) \bar{P}_k (I - K_k C_k)^T + K_k R_k K_k^T \end{aligned}$$

em que \bar{x}_k é a estimativa a priori de x , \hat{x}_k é a estimativa a posteriori de x , I é a matriz identidade, P é a matriz de covariância do erro de estimação, \bar{P}_k é a estimativa a priori de P , K é o ganho de Kalman, \hat{P} é a estimativa a posteriori de P , R é a matriz de covariância dos ruídos observados [20, 21, 22].

III. MATERIAL E MÉTODOS

O procedimento metodológico deste artigo consistiu em realizar um levantamento bibliográfico a fim de poder analisar o estado da arte do tema proposto a partir da literatura disponível. Com relação ao método da pesquisa, é utilizado o método explicativo o qual tem o objetivo de determinar os fatores que contribuem para a ocorrência dos fatos. Os resultados e simulações deste trabalho foram feitos através de um *software* de cálculo numérico em um computador com as seguintes configurações: processador i7, memória RAM de 8GB, HD de 1TB e placa de vídeo de 2GB.

A princípio foi selecionado o modelo fenomenológico que descrevesse a dinâmica do metabolismo da glicose no corpo humano. Entre os modelos disponíveis na literatura, foi utilizado o *minimal model* proposto por [12], devido a sua simplicidade e capacidade de representar a dinâmica do sistema. Nesse modelo foram adicionados distúrbios que simulam a ingestão de carboidratos (alimentação) e ruídos no sinal de medição da saída do sistema, para tornar o modelo mais realista possível. Após a escolha do modelo que vai representar o metabolismo da glicose no organismo do paciente, foi projetado nele um controlador proporcional-integrativo (PI) digital para servir de comparativo com o controlador preditivo (MPC), que será posteriormente projetado. Para efetuar a reconciliação dos dados ruidosos do sistema foi projetado um Filtro de Kalman. Os dados reconciliados da saída foram realimentados aos controladores, ao invés da saída real do sistema, com a finalidade de aprimorar o desempenho do controle. Para avaliar o uso dos dados reconciliados no controle, foi realizada uma análise de desempenho com base em uma função custo pré-determinada.

IV. RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados das simulações realizadas a fim de verificar a eficiência do controle proposto. Para isso, primeiramente, foi levantado

um modelo linear do sistema, na forma de função de transferência, que será usado no projeto dos controladores *PI* digital e *MPC*. Os desempenhos de ambos os controladores foram comparados primeiramente num cenário ideal, sem distúrbios ou ruídos, para, finalmente, comparar os desempenhos num caso mais realista, com distúrbios no metabolismo do paciente e ruídos na medição do nível de glicose.

A. Levantamento do Modelo Linear

Para obter a dinâmica do modelo do sistema linear, foi utilizada a técnica da curva de reação, abordada em [23, 24], visto que a resposta na saída de glicose do sistema (1) a uma variação em degrau equivalente a -10% do valor nominal da entrada de insulina $u(t)$ representada na Tabela II, na entrada de insulina, se assemelha a uma função de transferência de primeira ordem com tempo morto (FOPTD). Assim, a função de transferência FOPTD estimada do sistema é da forma:

$$G(s) = \frac{-8,747 \cdot e^{-47,37s}}{224,4s + 1} \quad (3)$$

A modo de comparação, as respostas do modelo linear, da Equação 3, e do sistema “real”, da Equação 1, são mostradas na Fig. 3.

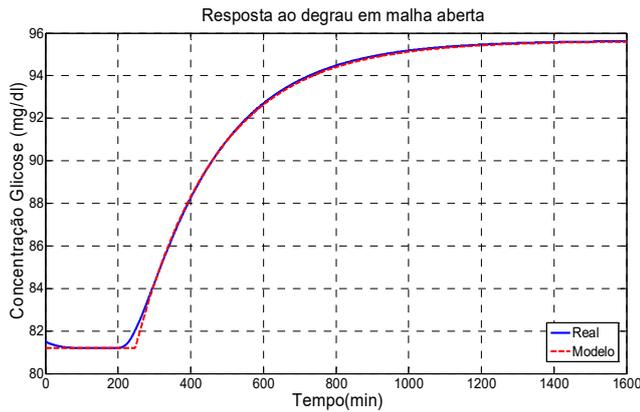


Fig. 3. Resposta do modelo linear obtido.

B. Controlador Proporcional e Integral (PI) Digital

Para sintonizar o controlador *PI* digital foi utilizada a regra proposta por *Ziegler-Nichols* [25], chamado também de método da curva de reação ou método em malha aberta, que aplica-se quando o sistema apresenta uma resposta ao degrau similar à forma da Equação 3.

A equação do controlador *PI* digital é dada por

$$u(k) = K_c \left[\left(1 + \frac{T}{\tau_i} \right) e(k) - e(k-1) \right] + u(k-1), \quad (4)$$

em que K_c é o ganho proporcional, τ_i é a constante de tempo integrativa, T é o período de amostragem, e é o sinal de erro e u é a saída do controlador. Os parâmetros da sintonia do controlador *PI*, ajustados de acordo com o método utilizado

em [25] e, após um ajuste fino visando ter o melhor desempenho, foram $K_c = -0,27$, $\tau_i = 157,9$ e $T = 5 \text{ min}$.

C. Controle Preditivo (MPC-QDMC)

Os parâmetros de sintonia do controlador preditivo, obtidos por tentativa e erro depois de realizar várias simulações, estão mostrados na Tabela III.

Parâmetro	Significado	Valor
T	Tempo de amostragem	5 min
N	Horizonte do modelo	200
p	Horizonte de predição	30
m	Horizonte de controle	2
$\Delta u_{\text{máx}}$	Limite máximo de incremento da entrada	16,5mU/min
u_{min}	Limite mínimo da entrada	0mU/min
$u_{\text{máx}}$	Limite máximo da entrada	80mU/min
Q	Ponderação da variável controlada	10
R	Fator de supressão de incremento da variável manipulada	1

D. Comparação dos Controladores Simulados

Nesta seção serão realizadas comparações de desempenho entre os controladores *PI* digital e *MPC* (*QDMC*), quando aplicados ao paciente virtual.

Primeiramente será feita uma comparação dos resultados sem considerar distúrbios e ruídos. Em seguida, a comparação será feita levando em consideração um distúrbio na concentração da glicose (alimentação). Finalmente, será adicionado uma perturbação estocástica na resposta do sistema, visando avaliar um cenário mais realista com ruídos de medição.

Na Fig. 4 é mostrada a comparação entre as respostas da variável controlada dos controladores projetados em um caso ideal.

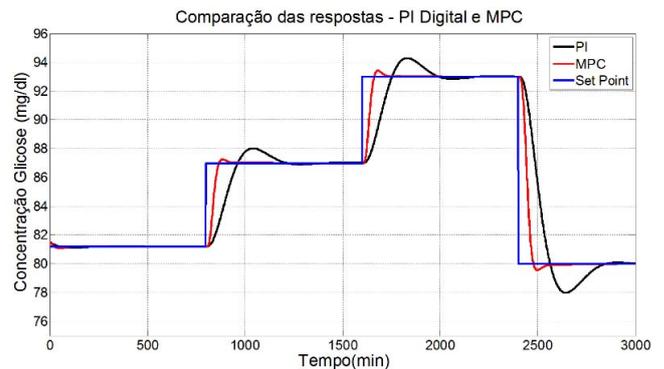


Fig. 4. Comparação das respostas dos controladores *PI* e *MPC* no caso ideal, a variações no *set point* da concentração de glicose.

Na Fig. 5 tem-se a comparação das variáveis manipuladas (ação de controle) dos controladores analisados

em um caso ideal de acordo com as mesmas entradas realizadas na Fig. 4.

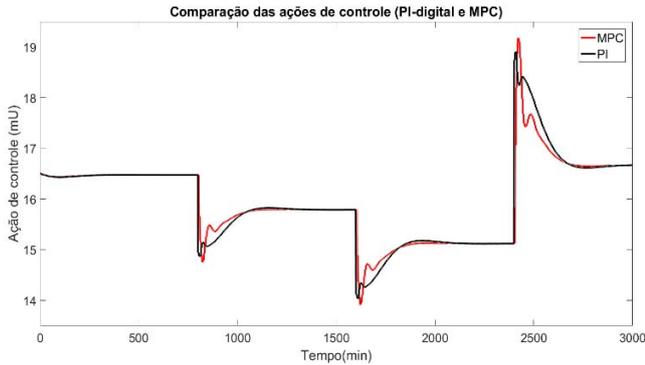


Fig. 5. Comparação das ações de controle do PI e MPC, no caso ideal, a variações no set point da concentração de glicose.

As respostas das ações de controle estão dentro do esperado, visto que quando o set point do nível de glicose aumenta, há uma menor injeção de insulina no sistema, ao passo que quando o set point diminui, há uma maior injeção de insulina para manter as taxas de glicose mais baixas.

Para tornar a simulação mais realista foram adicionados distúrbios e ruídos ao sistema. Como o intuito do modelo é controlar a concentração de glicose no sangue, será aplicado um distúrbio no sistema que modela a entrada de alimento no corpo humano. Para simular a ingestão de 100g de carboidratos puro em 200 minutos, foram considerados os parâmetros $A = 6,64$ e $k = 0,05$, de acordo com a Equação 2.

Na Fig. 6 é mostrada a resposta comparativa, com relação ao distúrbio aplicado, entre as variáveis controladas dos controladores analisados e um paciente virtual sem ações de controle.

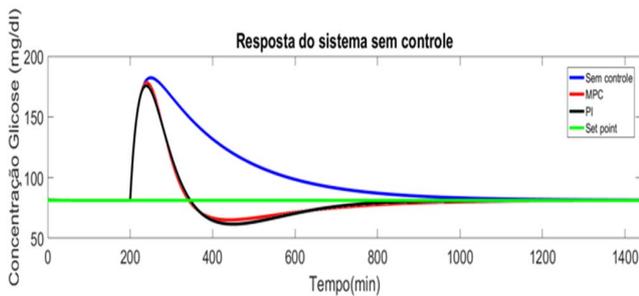


Fig. 6. Comparação das respostas dos controladores com relação ao distúrbio.

Na Fig. 7 é mostrada a comparação entre as ações de controle dos controladores projetados e um paciente virtual sem ação de controle quando há um distúrbio de alimentação.

Com a adição de um ruído branco da forma $v \sim N(0; 0,05)$ no sinal de saída de glicose e, utilizando o filtro de Kalman para fazer a reconciliação de dados, tem-se na Fig. 8, a resposta do controlador PI digital com a estimação da saída.

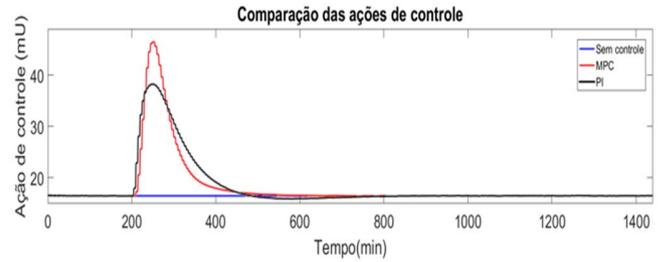


Fig. 7. Resposta comparativa das ações de controle com relação ao distúrbio aplicado.

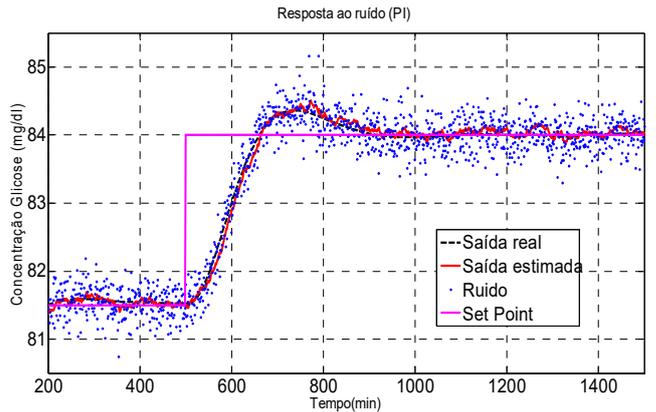


Fig. 8. Resposta do sistema com controle PI utilizando reconciliação de dados.

Na Fig. 9 é mostrada a resposta do controlador MPC com relação ao ruído branco v aplicado anteriormente.

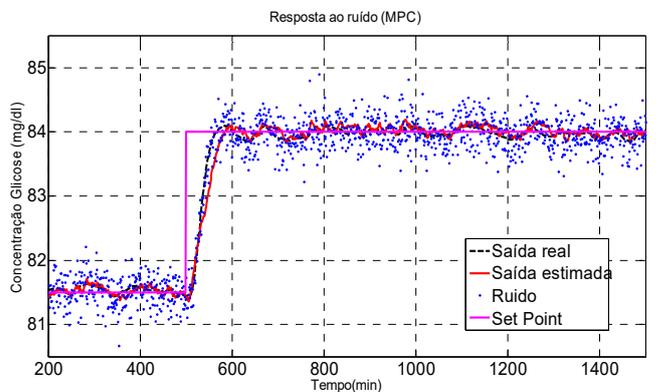


Fig. 9. Resposta do sistema com controle MPC utilizando reconciliação de dados.

V. REALIMENTAÇÃO DOS DADOS RECONCILIADOS E ANÁLISE DE DESEMPENHO

Para aprimorar o desempenho dos controladores, foram utilizados os dados reconciliados através do filtro de Kalman na realimentação do sistema. Desta forma, foi feita uma combinação entre o estimador, o controlador e o processo, como mostrado na Fig. 10.

Na Fig. 11 são mostradas as respostas dos controladores PI Digital e MPC com suas respectivas ações de controle utilizando a realimentação de dados do filtro de Kalman com

set point constante. A realimentação ocorreu no instante $t = 800 \text{ min}$.

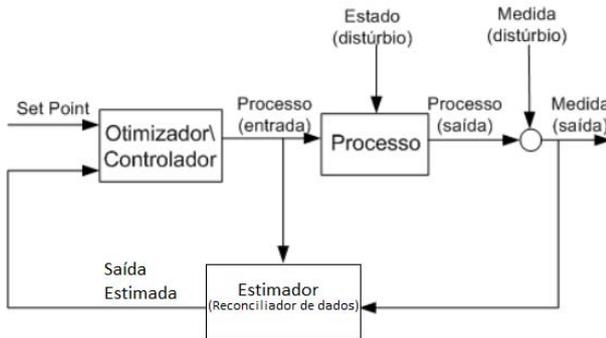


Fig. 10. Realimentação dos dados reconciliados no controlador. [20, 26].

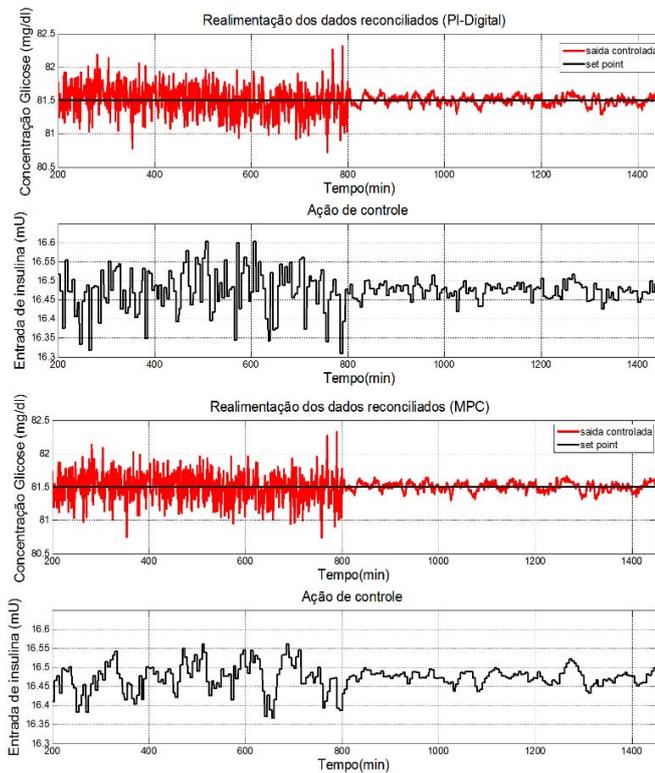


Fig. 11. Realimentação com os dados reconciliados do KF nos controladores PI e MPC com set point constante.

Como visto em [20], para avaliar o desempenho dos controladores utilizando os dados reconciliados, foi utilizado o índice J o qual leva em consideração o erro, e , entre a variável controlada e o set point e a variação da ação de controle, Δu , da seguinte forma:

$$J = \sum_{i=1}^N e^T(i) \cdot e(i) + \Delta u^T(i) \cdot \Delta u(i) \quad (5)$$

em que N é o tamanho da janela de avaliação.

O índice J descrito na Equação 5 se assemelha à função custo do desempenho do controlador MPC, que penaliza o

menor erro com a menor ação de controle. Assim, quanto menor for o valor deste índice, menor será o custo das ações de controle e maior será o desempenho deste [20].

Na Tabela IV são mostrados os valores da função custo dos controladores com o set point constante para uma janela $N=1500$ minutos.

TABELA IV
ANÁLISE DE DESEMPENHO

	PI Digital	MPC
Sem Reconciliação	88,94	85,51
Com Reconciliação	13,06	13,77
Taxa de Redução	85,32%	83,90%

Pode-se observar na Tabela IV que com a utilização da realimentação dos dados reconciliados nos controladores há uma redução significativa na função custo de desempenho em ambos os controladores.

VI. CONCLUSÕES

Neste trabalho foi levantado o modelo linear referente a dinâmica do metabolismo da glicose, o qual, de acordo com a resposta apresentada na Fig. 3, consegue modelar de forma aceitável a dinâmica simulada da insulina-glicose no organismo.

Para controlar o nível de glicose foram projetados os controladores PI digital e MPC, os quais conseguiram manter a saída do sistema no set point fornecido mesmo com a presença de distúrbio e ruídos.

No que diz respeito ao processamento de sinais, o filtro de Kalman projetado foi capaz de estimar a saída de modo bem aproximada da saída real do sistema, tornando os controladores mais robustos sob a presença de ruídos.

Com relação a análise de desempenho descrito através da Equação 5, tem-se que a redução da função custo J com a realimentação dos dados reconciliados é similar em ambos os controladores, porém o destaque é para o MPC que consegue uma resposta mais rápida que o controlador PI digital, como visto na Fig. 6.

Como trabalhos futuros, pretende-se implementar o controlador com um sistema embarcado para simular um pâncreas artificial e se aproximar de uma solução comercial. Além de investigar o desempenho do controlador com relação a imperfeições nos sensores e implementar uma nova entrada de variável controlada com infusão de soluções glicosadas para evitar quadros de hipoglicemia.

REFERÊNCIAS

- [1] World Health Organization, "Global Report on Diabetes". 2016.
- [2] DCCT – The Diabetes Control and Complications Trial Research Group, "The Effect of Intensive Treatment of Diabetes on The Development and Progression of Long-Term Complications in Insulin-Dependent" New England Journal of Medicine, pages 977-986. 1993.
- [3] A. Mourad, et al., "Blood Glucose Regulation in Diabetics Using H_∞ Control Techniques". European Journal of Advances in Engineering and Technology, 2(5): 1-6. 2015.

- [4] J. W. Minicucci, "Uso de Bomba de infusão Subcutânea de Insulina e suas Indicações". Universidade Estadual de Campinas (Unicamp). 2008.
- [5] K. Lunze, Singh, T., et al. "Blood Glucose Control algorithms for type 1 diabetic patients: A methodological review". Biomedical Signal Processing and Control. 2012.
- [6] R.S. Parker, F.J.I. Doyle, N.A. Peppas, "A model-based algorithm for blood glucose control in type I diabetic patients", IEEE Transactions on Biomedical Engineering 46. 148–157. 1999.
- [7] S.M. Lynch, B.W. Bequette, "Estimation-based model predictive control of blood glucose in type I diabetics: a simulation study", in: 27th IEEE Annual Northeast Bioengineering Conference, Storrs, Connecticut, pages 79–80. 2001.
- [8] K. C. Chui, et al. "Embedded Real-Time Model Predictive Control for Glucose Regulation". National University of Singapore, Singapore. 2012.
- [9] Sociedade Brasileira de Diabetes, "Diabetes". Disponível em: <<http://www.diabetes.org.br/para-o-publico/diabetes/o-que-e-diabetes>>. Acessado em 09/06/2016.
- [10] R. David, G. Leonor, et al. "IDF Diabetes Atlas: Global estimates of the prevalence of diabetes for 2011 and 2030". Diabetes research and clinical practice. 2011.
- [11] Qin, S. G., Badgwell, T. A. "A survey of industrial model predictive control technology". Control Engineering Practice, v. 11, pages 733–764. 2003.
- [12] R. N. Bergman, L. S. Phillips, C. Cobelli. "Physiologic evaluation of factors controlling glucose tolerance in man: measurement of insulin sensitivity and beta-cell glucose sensitivity from the response to intravenous glucose" J. Clin. Invest. 1456–1467. 1981.
- [13] Fisher M E. "A semiclosed-loop algorithm for the control of blood glucose levels in diabetics" IEEE Trans. Biomed. Eng. 38:57–61. 1991.
- [14] Goharimanesh M., Lashkaripour A., Shariatnia S., Akbari A. "Diabetic control using genetic fuzzy-PI controller" International Journal of Fuzzy Systems, Vol. 16. 2014.
- [15] Reddy V. T., Srinivasan K. "Multi model based controller design for type 1 diabetic patients." International Conference on Advances in Recent Technologies in Communication and Computing. 2009.
- [16] Friis-Jensen E. "Modeling and Simulation of Glucose-Insulin Metabolism", 2007.
- [17] N. P. Balakrishnan, G. P. Rangaiah, L. Samavedham. "Review and analysis of blood glucose (BG) models for type 1 diabetic patients". Ind. Eng. Chem. Res. 12041–12066. 2011.
- [18] J.M. Maciejowski, "Predictive Control with Constraints", 1st ed., Pearson Education, Prentice Hall, Harlow, England, 2001.
- [19] Farias A. C. "Avaliação de Estratégias para Reconciliação de Dados e Detecção de Erros Grosseiros". 2009.
- [20] Silva G.M.A. "Reconciliação dinâmica de dados baseada em estimadores em uma malha de controle MPC". Dissertação de mestrado. 2017.
- [21] Welch G., Bishop G. "An Introduction to the Kalman Filter". University of North Carolina at Chapel Hill, 2001.
- [22] Simon, D. "Optimal state estimation: Kalman, H ∞ and nonlinear approaches. Wiley-Interscience". 2006.
- [23] M. C. Oliveira. "Estratégias Convencionais de Controle de Processos". Trabalho de Conclusão de Curso, Universidade Federal de Sergipe. 2015.
- [24] Marcos Marcelino, "Introdução ao Controle de Processos Químicos – Aspectos Teóricos e Exemplos com GNU Octave", 2009.
- [25] Ziegler J. B., Nichols N. B. "Process lags in automatic control circuits", Transactions ASME 65, 433–444, 1943.
- [26] Tonel, G. "Avaliação dos estimadores EKF, CEKF e MHE para aplicações em linha em processos". 2008.



Matheus Canuto Oliveira Bacharel em Engenharia Eletrônica (2016) pela UFS (Universidade Federal de Sergipe), São Cristóvão, Sergipe, Brasil. Mestre em Engenharia Elétrica (2018) pelo Programa de Pós-Graduação em Engenharia Elétrica (PROEE) da Universidade Federal de Sergipe (UFS). Professor efetivo do Instituto Federal de Sergipe (IFS) na área de Eletrônica I – Automação e Controle. Tem experiência na área de Engenharia Eletrônica, com ênfase em controle de processos, modelagem e automação industrial.



Edward David Moreno Graduado em Engenharia Elétrica (1991) pela Universidade del Valle, Cali, Colômbia. Mestre (1994) e Doutor (1998) em Engenharia Elétrica pela USP (Universidade de São Paulo), São Paulo, SP, Brasil. Pós-Doutor (2000) pelo Programa de Pós-Graduação em Ciência da Computação (PPGCC) da Universidade Federal de São Carlos (UFSCAR), São Carlos, São Paulo, Brasil. Durante os anos de 1996 e 1997 atuou com pesquisador visitante na Universidade de Toronto, Canadá e na Universidade de Tecnologia Chalmers, Goteborg, Suécia. Desde 2009 é professor da Universidade Federal de Sergipe (UFS), Aracaju, Sergipe, Brasil. Prof. Edward é membro do Editorial Board de alguns journals internacionais: É também avaliador de cursos de Computação e Informática e Institucional do INEP/MEC. Tem participado no comitê de programa, em mais de 120 eventos internacionais. Já publicou 8 livros na área de projeto de sistemas digitais reconfiguráveis e segurança em hardware. Tem experiência na área de Ciência da Computação e Engenharia da Computação, com ênfase em Arquitetura de Sistemas de Computação, Sistemas Embarcados, Segurança em Hardware, Computação de Alto Desempenho, e Power-Aware Computing.



Guilherme Moura Afonso da Silva Bachelar em Engenharia Elétrica com habilitação em Eletrônica (2014) pela Universidade Federal de Sergipe (UFS). Mestrado em Engenharia Elétrica (2017) pelo Programa de Pós-Graduação em Engenharia Elétrica (PROEE) da Universidade Federal de Sergipe na área de controle de processos. Atualmente é professor titular e coordenador de engenharia elétrica da Unidade de Ensino Superior de Feira de Santana (UNEF) e da Faculdade Nobre de Feira de Santana (FAN). Tem experiência na área de controle de processos e análise de sinais biomédicos.

**Oscar Alberto Zanabria Sotomayor**

Possui graduação em Engenharia Eletrônica pela Universidad Ricardo Palma (1993), Lima-Perú, Mestrado em Engenharia Elétrica pela Universidade de São Paulo (1997) e Doutorado em Engenharia Química pela Universidade de São Paulo (2002). Tem dois Pós-doutorados em Engenharia Química pela Universidade de São Paulo (2006 e 2008, respectivamente). Atualmente é Professor Associado do Departamento de Engenharia Elétrica (DEL), Professor e Coordenador do Programa Multidisciplinar em Tecnologia de Petróleo, Gás Natural e Biocombustíveis (PRH-ANP 45) da Universidade Federal de Sergipe (UFS). Tem experiência na área de Automação & Controle, atuando principalmente nos seguintes temas: controle de processos, controle preditivo, detecção e diagnóstico de falhas, avaliação de desempenho e auditoria de controladores, identificação e otimização de sistemas, modelagem e simulação de processos, fusão e reconciliação de dados; com aplicações em processos químicos e petroquímicos, petróleo & gás, sistemas biológicos e sistemas estruturais.