

OPTIMIZAREA MODELELOR DE PREDICȚIE A HIPOGLICEMIEI PRIN COMBINAREA ALGORITMILOR GENETICI ȘI LEVENBERG-MARQUARDT

Ghenadie USIC,

Universitatea de Stat din Moldova

Această lucrare investighează o metodă de anticipare a episoadelor de hipoglicemie la persoanele cu diabet de tip 1, folosind rețele neuronale artificiale (RNA). Hipoglicemia este o problemă semnificativă care apare adeseori în urma tratamentului intens cu insulină; episoadele nocturne sunt foarte periculoase din cauză că simptomele pot fi adeseori greșit interpretate sau ignorate în timpul somnului și pot evolua către convulsii sau comă chiar și deces. Studiul examinează date de monitorizare continuă a glicemiei pe o perioadă de 3 luni ale cinci persoane diagnosticate cu diabet de tip I. Prin analiza datelor istorice disponibile, metoda propusă antrenează un model de învățare profundă pentru a detecta șabloane care pot semnaliza anticipat riscul de hipoglicemie. De asemenea, cercetarea prezintă o abordare pentru îmbunătățirea sensibilității și specificității predicțiilor prin includerea algoritmilor genetici și Levenberg-Marquardt în procesul de antrenare. Această adaptare refinează precizia predictivă a modelului și îmbunătățește adaptarea dinamică la caracteristicile unice ale fiecărui pacient în parte pentru a îmbunătăți rapiditatea și fiabilitatea predicțiilor sale.

Cuvinte-cheie: *sisteme de avertizare timpurie pentru diabet, rețele neuronale, algoritmi bio-inspirați, computație evoluționară, inteligență artificială, monitorizare glicemică personalizată.*

OPTIMIZING HYPOGLYCEMIA PREDICTION MODELS BY COMBINATING GENETIC AND LEVENBERG-MARQUARDT ALGORITHMS

This paper investigates a method for anticipating hypoglycemic episodes in individuals with type 1 diabetes using artificial neural networks (ANNs). Hypoglycemia is a significant problem that often occurs as a result of intensive insulin treatment; nocturnal episodes are particularly dangerous because symptoms can often be misinterpreted or ignored during sleep and can progress to seizures, coma, or even death. The study examines continuous glucose monitoring (CGM) data over a 3-month period, insulin dose records, and food diaries of five individuals diagnosed with type 1 diabetes. By analyzing available historical data, the proposed method trains a deep learning model to detect patterns that can signal the risk of hypoglycemia in advance. Additionally, the research presents an approach to improve the sensitivity and specificity of predictions by incorporating genetic algorithms and Levenberg-Marquardt in the training process. This adaptation refines the predictive accuracy of the model and enhances dynamic adaptation to the unique characteristics of each individual patient to improve the speed and reliability of its predictions.

Keywords: *early warning systems for diabetes, neural networks, bio-inspired algorithms, evolutionary computation, artificial intelligence, personalized glycemetic monitoring.*

Introducere

Diabetul zaharat este o afecțiune metabolică cronică care se caracterizează prin producția insuficientă sau lipsa totală de insulină, ceea ce complică menținerea nivelurilor corecte de zahăr în sânge. Persoanele care au fost diagnosticate cu diabet zaharat trebuie să facă modificări semnificative în modurile lor de viață pentru a gestiona eficient nivelurile de glucoză în sânge. Conform Organizației Mondiale a Sănătății (OMS), diabetul zaharat este una dintre cele patru boli netransmisibile cu cea mai mare rată de mortalitate comparativ cu alte afecțiuni [1].

Hipoglicemia este definită ca fiind atunci când nivelul de glucoză în sânge scade la niveluri critice și reprezintă una dintre consecințele cele mai înfricoșătoare ale tratamentului cu insulină. Episoadele sunt considerate hipoglicemice când glicemia scade sub 60 mg/dl (3,33 mmol/l), iar cele severe, sub 50 mg/dl (2,8 mmol/l), necesită intervenție imediată [2].

O cercetare din 2004 a constatat că aproximativ o treime dintre cei care au participat (1076 de persoane) au experimentat hipoglicemie severă cu o incidență de 1,3 episoade/pacient pe an [3]. Hipoglicemia nocturnă este extrem de periculoasă deoarece somnul reduce semnificativ răspunsurile defensive ale corpului [4].

Intr-un studiu anterior subsemnatul sugera utilizarea unui model personalizat MISO (multi-input-single-output), care se bazează pe o rețea neuronală perceptron multistrat (MLP NN), ce integra o hartă autoorganizatoare (SOM) pentru a capta comportamentul metabolic al glucozei [5].

În domeniul cercetării medicale și biomedicale se folosesc des rețele neuronale artificiale (RNA) ca unelte puternice de clasificare; aceste rețele sunt recunoscute pentru abilitatea lor de modelare eficientă a relațiilor non-liniare dintre variabile. Printre metodele comune de antrenare se numără algoritmul Levenberg-Marquardt (LM), care utilizează informații de gradient de ordinul doi și Algoritmul Genetic (AG), o tehnică de optimizare inspirată din selecția naturală.

Această cercetare își propune să dezvolte o metodă de instruire a rețelelor neuronale pentru îmbunătățirea performanței algoritmului de clasificare prin explorarea unei abordări mixte care combină Algoritmul Genetic (AG) cu algoritmul lui Levenberg-Marquardt (LM), explorează beneficiile ambelor metode: AG este utilizat pentru identificarea constantă a zonelor în apropierea optimului global, în timp ce LM rafinează acest proces prin ajustarea rapidă a rețelelor.

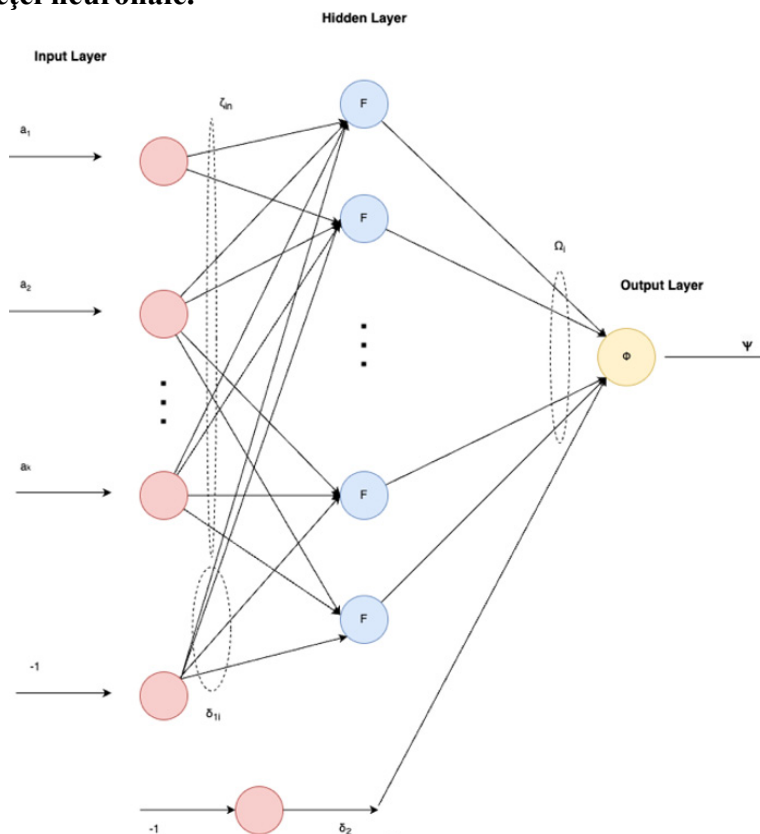
Metode și materiale aplicate

În cardul acestei cercetari a fost utilizat un set de date colectat de la 5 pacienți cu diabet zaharat de tip I prin intermediul unui sistem mobil de asistență, dezvoltat în studii anterioare [5].

Cu scopul de a dezvolta un sistem în timp real cu cerințe computaționale reduse, este proiectată o rețea neuronală feed-forward, formată din trei straturi care funcționează ca o unitate de clasificare în cadrul studiului. Structura rețelei este ilustrată în Fig. 1.

Stratul de intrare procesează caracteristicile derivate din măsurătorile glicemiei, în timp ce stratul de ieșire conține un singur nod care reprezintă rezultatul clasificării: stare hipoglicemică sau non-hipoglicemică. Ieșirea țintă este setată la valoarea 1 pentru stările hipoglicemice și -1 pentru condițiile non-hipoglicemice.

Fig. 1. Structura rețelei neuronale.



Din Fig. 1 relația de input-output a rețelei neuronale propuse poate fi scrisă ca:

$$\Psi = \sum_{i=1}^M \mu_i \operatorname{tansig} \left[\sum_{n=1}^K (\zeta_{in} a_n - \sigma_{1i}) \right] - \sigma_2$$

Unde μ_i este ponderea legăturii dintre al-lea nod ascuns și n-a intrare, ζ_{in} este ponderea legăturii dintre i- al-lea nod ascuns și ieșirea. a_n sunt părținiri pentru stratul de intrare și stratul ascuns. σ_{1i} este numărul de noduri ascunse, σ_2 este numărul de intrări, tansig este funcția de transfer sigmoid tangentă hiperbolică a stratului ascuns.

În dezvoltarea unei rețele neuronale, alegerea algoritmului de antrenament este esențială pentru obținerea performanței optime de clasificare. Această lucrare prezintă un proces de antrenament în doi pași care valorifică punctele forte ale algoritmilor genetici (GA) și ale metodei Levenberg-Marquardt (LM). Funcția de eroare utilizată pentru antrenament este eroarea medie pătratică (MSE) dintre ieșirea rețelei și ținta corespunzătoare. Numărul de noduri ascunse este determinat printr-o abordare de încercare și eroare pentru a identifica configurația care dă cele mai bune rezultate de clasificare.

GA este folosit pentru a optimiza parametrii rețelei neuronale prin explorarea întregului spațiu de căutare, ghidând antrenamentul către optimul global. Inițial, este generată o populație de cromozomi (indivizi), fiecare cromozom reprezentând un set de parametri pentru rețeaua neuronală sub forma \mathbf{p} . Lungimea fiecărui cromozom corespunde numărului total de parametri din rețea. În timpul evoluției, fiecare cromozom este evaluat folosind o funcție de fitness, care este definită după cum urmează [6]:

$$F(\text{chromosome}) = 1 / (1 + \text{MSE})$$

În fiecare iterație (sau generație) a procesului de antrenare, populația suferă actualizări prin selecție, încrucișare și mutație. În timpul selecției, cromozomii sunt aleși pe baza valorilor lor de fitness pentru a participa la reproducere. Cromozomii selectați sunt apoi supuși la două operații genetice: încrucișarea, care combină informații de la părinți, și mutația, care introduce variații în descendenți. Noii descendenți sunt evaluați de funcția de fitness, iar cei mai slabi cromozomi din populație sunt înlocuiți. Acest proces continuă până când se îndeplinește o condiție de terminare [6]. Cel mai bun cromozom din populația finală este utilizat pentru a inițializa parametrii rețelei neuronale pentru pasul următor, unde se aplică algoritmul Levenberg-Marquardt (LM).


Pentru a aborda limitările GA, cum ar fi reglarea fină inefficientă și convergența lentă, algoritmul LM este folosit pentru optimizare locală, utilizând setul de parametri furnizat de GA. Algoritmul LM estimează derivata a doua direcțională a funcției de performanță (MSE) pentru a ghida antrenamentul către un optim local. Pentru a preveni supraajustarea și a menține generalizarea, eroarea pe un set de validare este monitorizată în timpul antrenamentului. Dacă eroarea de validare crește pentru un număr predefinit de iterații, antrenamentul este oprit, iar parametrii din acel punct sunt adoptați ca ponderile și bias-urile finale ale rețelei neuronale [7].

După determinarea parametrilor finali, se trasează o curbă Receiver Operating Characteristic (ROC) pentru setul de antrenare. Curba ROC ilustrează compromisul dintre rata de adevărat pozitiv (sensibilitatea) și rata de fals pozitiv (1-specificitatea) pentru diferite praguri ale clasificatorului. În contextul detectării hipoglicemiei, sensibilitatea - capacitatea de a identifica corect episoadele hipoglicemice - are prioritate față de specificitate [8]. Astfel, pe baza curbei ROC, pragul de ieșire este selectat pentru a obține o sensibilitate de clasificare de 80%. Această abordare asigură o sensibilitate ridicată, menținând în același timp o specificitate rezonabilă, în concordanță cu metodologia utilizată de Rickels et al. în evaluarea sistemelor de monitorizare continuă a glicemiei pentru evitarea hipoglicemiei [8].

Resultate obținute și discuții

Profilurile actuale ale BGL de la cinci pacienți cu diabet zaharat de tip I care au fost colectate în timpul studiului sunt prezentate în Fig. 2. Pragul BGL pentru a distinge între hipoglicemie și non-hipoglicemie este stabilit la 3,3 mmol/l.

Fig. 2. Profilurile nivelului de glucoză din sânge ale pacienților.



O rețea neuronală este dezvoltată cu 2 noduri de intrare (1 caracteristică x 2 canale), M noduri ascunse și 1 nod de ieșire. M variază de la 1 la 18 pentru a-l selecta pe cel care oferă cele mai bune performanțe. Ca rezultat, este recunoscut că pentru aplicația noastră cu 2 noduri de intrare și 1 nod de ieșire, $S = 7$ dă cele mai bune rezultate de clasificare. Următoarele rezultate corespund unei rețele neuronale de 7 noduri ascunse.

Pentru instruirea bazată pe GA, setul de date a fost împărțit într-un set de antrenament și un set de testare. Setul de antrenament a constat din date de la 3 pacienți, denumiți pacienți A, B și C. Setul de testare a fost format din date de la 2 pacienți suplimentari, D și E.

Următorii parametri și operatori au fost utilizați pentru formarea rețelelor neuronale bazate pe GA:

Tabel 1. Parametri pentru formarea rețelor neuronale bazate pe GA.

Parametru	Valoarea
Metoda de selecție	Clasament geometric normalizat
Operator crossover	Blend Crossover
Operator de mutație	Mutație neuniformă
Lungimea cromozomului	63
Generații maxime	5000
Dimensiunea populației	70
Interval de parametri	$[-3, 3]$ for

Rezultatele clasificării sunt prezentate în Tabelul 2.

Tabel 2. Rezultatele clasificării.

Metoda de antrenament	Sensibilitatea antrenamentului	Specificitatea antrenamentului	Sensibilitatea testării	Specificitatea testării
LM	74%	48%	61%	41%
GA	74%	36%	73%	39%
GA+LM	74%	52%	63%	57%

Concluzii

Această lucrare detaliază o abordare care combină algoritmi genetici (GA) și optimizarea Levenberg-Marquard (LM) pentru a îmbunătăți performanța în clasificarea unui algoritm de detectare a hipoglicemiei. Prin folosirea potențialului de căutare global al GA împreună cu avantajele căutării locale ale LM în procesul de antrenament al rețelelor neurale, rezultate arată o creștere a performanței clasificatorului, obținând până la 74% sensibilitate și 52% specificitate pe setul de antrenament și 63% sensibilitate și 57% specificitate pe setul de testare.

Având în vedere aceste rezultate, cercetările suplimentare sunt necesare pentru a explora algoritmi mai avansați și alte metode de a îmbunătăți și mai mult performanța sistemului. În prezent, unul dintre limitările studiului reprezintă cantitatea redusă de date disponibile.

Prin această metodologie propusă, se urmărește să avanseze în dezvoltarea sistem în timp real, capabil să monitorizeze starea pacienților, oferind alerte atât pacienților, cât și îngrijitorilor acestora atunci când se detectează hipoglicemie nocturnă în timpul somnului.

Referințe:

1. WORLD HEALTH ORGANIZATION. *Global status report on noncommunicable diseases*, 2014, 280 p. ISBN 9789241564854.
2. CRYER P. E. *Hypoglycaemia: the limiting factor in the glycaemic management of Type I and Type II diabetes*. *Diabetologia*, 2002 Jul 45(7), p. 937-948.
3. U. PEDERSEN-BJERGAARD, S. PRAMMING, S. R. HELLER, T. M. WALLACE, Å. K. RASMUSSEN, H. V. JØRGENSEN, D. R. MATTHEWS, P. HOUGAARD, AND B. THORSTEINSSON, *Severe hypoglycaemia in 1076 adult patients with type 1 diabetes: influence of risk markers and selection*, *Diabetes / Metabolism Research and Reviews*, vol. 20, 2004, p. 479-486.
4. DCCT RESEARCH GROUP, *Epidemiology of severe hypoglycemia in the diabetes control and complication trial*, *Am. J. Med.*, 90, 1991, p. 450-459.
5. G. USIC, *Personalized glucose prediction model for patients with type I diabetes*, *Proceedings of IV International Scientific and Technical Conference 'Computer and Information Systems and Technologies'*, CSI-TIC-2021, 2021, p. 9-10.
6. D. J. MONTANA and L. DAVIS, *Training Feed-Forward Neural Networks Using Genetic Algorithms*, *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, 1989, p. 762-767.
7. M. T. HAGAN and M. B. MENHAJ, *Training feedforward networks with the Marquardt algorithm*, *Neural Networks, IEEE Transactions on*, vol. 5, 1994, p. 989-99.
8. RICKELS MR, PELECKIS AJ, DALTON-BAKES C, NAJI JR, RANNA, NGUYEN HL, O'BRIEN S, CHEN S, LEE I, *Continuous Glucose Monitoring for Hypoglycemia Avoidance and Glucose Counterregulation in Long-Standing Type 1 Diabetes*, *J Clin Endocrinol Metab*, 2018, 105-114.

Date despre autor:

Ghenadie USIC, doctorand, Universitatea de Stat din Moldova.

ORCID: 0009-0003-8423-0443

E-mail: ghenavl@gmail.com

Prezentate la 30.09.2024