

## پیش‌بینی نوسانات سطح قند خون در بیماران مبتلا به دیابت نوع 1 با استفاده از شبکه‌های عصبی خودبازگشتی المن (یادداشت پژوهشی)

سعید راحتی قوجانی<sup>(1)</sup> سید احسان تهامی<sup>(2)\*</sup>

(1) استادیار، گروه مهندسی پزشکی، دانشگاه آزاد اسلامی واحد مشهد

(2) کارشناس ارشد، باشگاه پژوهشگران جوان، دانشگاه آزاد اسلامی واحد  
مشهد

تاریخ ثبت اولیه: 85/7/25، تاریخ دریافت نسخه اصلاح شده: 86/4/13، تاریخ  
پذیرش: 86/6/25

**چکیده** یکی از عوارض خطرناک بیماری دیابت نوع یک افزایش و یا کاهش ناگهانی سطح غلظت قند خون می‌باشد که باعث بروز خطراتی چون اغما و بیهوشی خواهد شد. بنابراین استفاده از روشی مناسب به منظور پیش‌بینی و در نهایت پیش‌گیری از این عوارض گام مهمی در جهت کنترل بهینه بیماری محسوب می‌شود. به همین منظور در این مقاله سعی شده است تا به کمک شبکه‌های عصبی خودبازگشتی نوسانات سطح غلظت قند خون بیماران مبتلا به دیابت نوع 1 پیش‌بینی شود. داده‌های پزشکی مورد استفاده در این مقاله مربوط به 3 بیمار زن ایرانی مبتلا به دیابت نوع یک است که شامل الگوهای چون نوع و دز انسولین تزریقی، فاصله زمانی بین ساعات ثبت سطح غلظت قند خون و نیز سطح غلظت قند خون در ابتدای بازه زمانی می‌باشد. در پایان تحقیق با توجه به نتایج به دست آمده مشخص شد که شبکه‌های عصبی خودبازگشتی با کاهش قابل ملاحظه‌ای در خطای پیش‌بینی نسبت به دیگر روش‌های متداول، می‌توانند به عنوان مدلی مناسب به منظور پیش‌بینی نوسانات سطح غلظت قند خون در بیماران مبتلا به دیابت نوع یک تلقی گردد.

**واژه‌های کلیدی** دیابت، پیش‌بینی نوسانات سطح غلظت قند خون، شبکه عصبی خودبازگشتی، شبکه عصبی پرسپترون.

\*عهده دار مکاتبات

**1- مقدمه**

بیماری دیابت از جمله بیماری‌های شایع و بسیار خطرناک دنیای معاصر است که سالانه خسارات مادی و معنوی بسیار زیادی را متوجه جوامع و کشورها می‌سازد. در حال حاضر در ایران 2 تا 3 میلیون نفر به این بیماری مبتلا می‌باشند که نیمی از آنها حتی از ابتلاء خود آگاهی ندارند. این بیماری را می‌توان به دو نوع تقسیم نمود: نوع 1 یا نوع وابسته به انسولین (IDDM) که در این نوع لوزالمعده شخص مبتلا به دیابت قادر به ترشح انسولین نمی‌باشد و نوع 2 یا نوع غیر وابسته به انسولین (NIDDM) که در آن لوزالمعده شخص مبتلا به دیابت قادر به تولید و ترشح انسولین می‌باشد اما میزان جذب آن در بافت‌های بدن بسیار پایین است. مشکل عمده ای که در حال حاضر در رابطه با این بیماری مخرب و خطرناک و به خصوص در نوع 1 آن وجود دارد افزایش (Hyper Glycemia) و یا کاهش (Hypo Glycemia) بیش از حد و ناگهانی سطح قند خون است که از جمله عوارض بسیار خطرناک آن محسوب می‌گردد و می‌تواند حتی به بیهوشی و اغماء بیمار منتهی گردد. همچنین مشکل دیگری که در بیماران دیابتی وجود دارد تنظیم دز انسولین تزریقی بدون دانستن پاسخ سطح قند خون

بدن به تزریق این مقدار انسولین می‌باشد. در بسیاری مواقع همین عدم اطلاع از میزان تزریق انسولین خود باعث بوحود آمدن مشکلاتی حاد و در برخی مواقع حتی غیر قابل جبران می‌گردد.

به همین منظور استفاده از روش‌هایی که بتوان از آن طریق ضمن کاهش تعداد اندازه‌گیری‌های قند خون و جلوگیری از اثرات متعاقب ناشی از این اندازه‌گیری‌ها به نوعی وقوع عوارض خطرناک احتمالی یاد شده را پیش‌بینی نمایند، می‌تواند مهمترین گام به منظور تشخیص، کنترل و حتی درمان مناسب این عوارض تلقی گردد.

تا کنون روش‌های متفاوتی برای رسیدن به این مهم مورد استفاده قرار گرفته‌اند که از آن جمله می‌توان به مدل‌های ریاضی و مینیمال [1-6] که عمدتاً به منظور تعیین حساسیت بدن بیمار در پاسخ به گلوکز تزریقی و نیز پیش‌بینی کوتاه مدت سطح قند و انسولین موجود در بدن مورد استفاده قرار گرفته‌اند، مدل‌های مبتنی بر رویکردهای احتمالاتی [7] که مشابه با مدل‌های ریاضی به منظور مدلسازی سیستم متابولیکی بدن مورد استفاده قرار گرفته‌اند و سیستم‌های خبره [8-13] که به منظور پیش‌بینی وضعیت سطح قند خون بیمار در آینده استفاده شده‌اند، اشاره نمود.

ازجمله مشکلاتی که در

کل داده‌های ثبت شده برای این تحقیق مربوط به 3 بیمار زن مبتلا به دیابت نوع 1 در سنین بین 17 تا 26 سال در شهرستان مشهد می‌باشد. که در این مقاله فقط از داده‌های مربوط به بیمار 26 ساله استفاده شده است. به منظور ثبت این داده‌ها، دفترچه‌های مخصوصی با مشورت و راهنمایی پزشک معالج، در اختیار بیماران قرار گرفت و پس از اتمام دوره ثبت و با تأیید پزشک معالج، داده‌های مورد نظر جمع‌آوری و استفاده شد. پارامترها (ویژگی‌های مورد نیاز لحاظ شده در دفترچه‌های ثبت داده‌ها عبارتند از:

- سطح غلظت قند خون در ابتدای بازه زمانی (mg/dlit)
- دز انسولین کوتاه اثر تزریقی به بدن (unit)
- دز انسولین طولانی اثر تزریقی به بدن (unit)
- سطح استرس (unit)
- سطح فعالیت بدنی (unit)
- کربوهیدرات مصرفی (gr)
- زمان میان ابتدا و انتهای بازه زمانی (hour)
- مدت زمان ثبت مورد استفاده در این تحقیق 135 روز می‌باشد. از این تعداد 75% تعداد داده‌های ثبت شده برای هر نفر به منظور آموزش شبکه

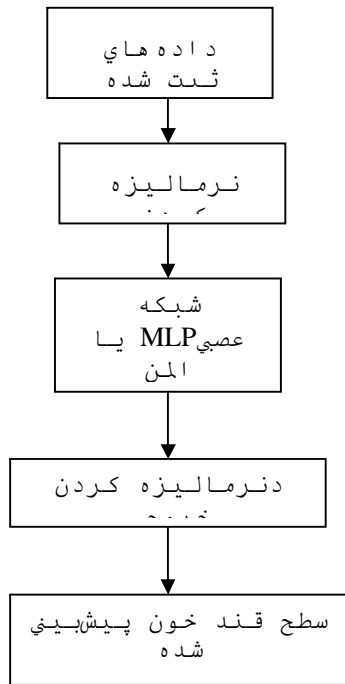
مدلهای یاد شده به چشم می‌خورد عدم وجود اطلاعات کافی و کامل است که بتوان از آن طریق به مدلی مشابه مدل واقعی دست یافت، زیر مدلهای اگرچه ممکن است کاملاً صحیح عمل نمایند اما زمانی که با یکدیگر ترکیب می‌گردند خطا در خروجی مدل افزایش خواهد یافت. همچنین به این موارد می‌توان تعداد کم ویژگی‌ها و پارامترهای تأثیرگذار بر نوسانات سطح قند خون مورد استفاده در مدل‌های مبتنی بر هوش مصنوعی را نیز افزود که این خود باعث ایجاد خطاهایی در پیش‌بینی سطح قند خون بدن خواهد شد.

با توجه به ماهیت دینامیکی نوسانات سطح قند خون و نیز ساختار دینامیکی شبکه‌های عصبی بازگشتی، در این مقاله از شبکه عصبی بازگشتی ال‌من به منظور مدل‌سازی و پیش‌بینی نوسانات سطح قند خون استفاده شده است. ضمن اینکه به منظور نشان دادن تطبیق پذیری بهتر شبکه عصبی ال‌من نسبت به شبکه عصبی پرسپترون چندلایه در فرآیند پیش‌بینی سطح قند خون، مقایسه‌هایی نیز میان این دو نوع شبکه عصبی صورت گرفت.

## 2- داده و روش

### 2-1- داده‌های مورد استفاده

پیش‌بینی صورت پذیرد بلوک  
دیگرام سیستم مورد استفاده  
در این مقاله در شکل (1) آورده  
شده است.



بلوک دیگرام سیستم طراحی شده  
پیش‌بینی نوسانات سطح غلظت قند خون در  
فرد مبتلا به دیابت نوع 1.

عصبی و 25% به منظور آزمایش آن  
مورد استفاده قرار می‌گیرند.  
گفتنی است که میزان  
فعالیت بدنی و نیز میزان سطح  
استرس با انتخاب یکی از اعداد  
1 تا 4 که به ترتیب بیان  
کننده وضعیت معمولی (1)، کم  
(2)، متوسط (3) و زیاد (4)  
می‌باشد توسط هر شخص و با  
توجه به وضعیت جسمانی و  
شرایط روحی و روانی مختص به  
خود او و به صورت کیفی تعیین  
شده و سپس در زیر ساعت مشخص  
شده در جداول ثبت نوشته می-  
شود. نمونه‌ای از داده‌های ثبت  
شده در جدول 1 قابل مشاهده  
می‌باشد.  
جدول 1 نمونه‌ای از مجموعه داده

قند خون بعدی	زمان	کربوهیدرات	سطح فعالیت بدنی	سطح استرس	انسولین طولانی اثر	انسولین کوتاه اثر	قند خون پیش‌بینی شده
220	8	3	2	0	8	10	180
65	9	6	0	1	5	9	250

### 2-2- روش مورد استفاده. در

این روش ابتدا داده‌ها مورد  
پردازش اولیه قرار می‌گیرند تا  
بتوانند به منظور کاربرد در  
شبکه عصبی مورد استفاده قرار  
گیرند. به این منظور ابتدا  
داده‌ها نرمالسازی گردیده‌اند  
در مرحله بعدی داده‌های  
نرمالسازی شده به شبکه‌های  
عصبی داده می‌شوند و سرانجام  
خروجی شبکه عصبی د نرمالیزه می-  
شود تا در نهایت فرآیند

2-3- نرمالسازی داده‌ها  
در مرحله نرمالسازی، داده-  
های موجود برای هر ویژگی،  
مطابق با رابطه (1) نرمالسازی  
می‌شوند:

$$X_i = \frac{x_i - m}{\sigma_x} \quad (1)$$

که در این رابطه  $X_i$  داده  
نرمال شده،  $m$  میانگین کل  
داده‌های مربوط به هر ویژگی  
و  $\sigma_x$  انحراف معیار کل داده‌های  
مربوط به هر ویژگی می‌باشد.

توجه به الگوریتم یاد شده (الگوریتم پس انتشار خطا) و به صورت خودکار در طی مراحل تکرار الگوریتم و با استفاده از رابطه (2) بهبود می‌یابند،

$$X_{k+1} = X_k - a_k g_k \quad (2)$$

به عبارتی دیگر مقدار وزن  $x$  در هر لحظه برابر است با مقدار وزن در لحظه قبل بعلاوه تابع گرادیان خطا  $g_k$  در هر مرحله که در نرخ یادگیری  $a_k$  ضرب شده است و این رابطه آنقدر تکرار می‌شود تا در نهایت بردار وزن‌ها به مقدار بهینه خود برسد که به ازای آن مقدار، معیار خطا که در اینجا از معیار متوسط مربعات خطا (Mean Esquare Error) رابطه (3) استفاده شده است، به کمترین مقدار خود برسد (در این رابطه  $t(k)$  خروجی مورد انتظار،  $a(k)$  خروجی واقعی شبکه و  $N$  تعداد تکرارها می‌باشد).

$$MSE = \frac{1}{N} \sum_{k=1}^N (t(k) - a(k))^2 \quad (3)$$

لازم است به این نکته نیز اشاره شود که در ابتدای شروع به کار الگوریتم، مقادیری به عنوان مقادیر اولیه وزن‌ها و به صورت کاملاً تصادفی انتخاب می‌شوند و سپس این مقادیر در طول اجرای الگوریتم بهبود می‌یابند. پارامترها و مشخصات شبکه عصبی پرسپترون مورد استفاده در این مقاله در

## 2-4- شبکه‌های عصبی پرسپترون چند لایه

شبکه‌های عصبی چند لایه‌ی پرسپترون به دلیل قابلیت‌های با ارزش پردازش موازی و یادگیری، عمدتاً به منظور حل مسائل پیچیده مورد استفاده قرار می‌گیرند. فرآیند یادگیری در این شبکه‌ها از طریق الگوریتم‌های یادگیری خاصی صورت می‌گیرد که با تنظیم وزن‌های موجود در ارتباطات بین نورون‌ها، اقدام به آموزش شبکه می‌کنند.

یکی از شبکه‌های عصبی مورد استفاده در این مقاله، شبکه عصبی پرسپترون سه لایه است. معیار یادگیری شبکه عصبی پرسپترون چند لایه مورد استفاده، بر مبنای تابع پس انتشار خطا (Back Propagation) خواهد بود. لازم به ذکر است که شبکه عصبی یاد شده در محیط نرم افزار مطلب (MATLAB) شبیه‌سازی و اجرا شده است.

توابع محرک نورون‌های هر لایه از شبکه عصبی به نوعی به منظور تعیین میزان حد و آستانه خروجی نورون به کار می‌روند که در الگوریتم مورد استفاده در این مقاله از تابع (pure line) در لایه خروجی و از تابع (tansig) آن در لایه میانی شبکه عصبی استفاده شده است. همچنین وزن‌ها در این شبکه عصبی با


داده ها خواهند داشت؛ همچون محل زندگی بیمار (شهر، کشور و منطقه جغرافیایی)، آب و هوا، نژاد و ... وابسته می‌باشند، لذا شبکه عصبی پیش‌بین باید برای هر فرد از طریق داده‌هایی که توسط خود او جمع‌آوری می‌گردد آموزش ببیند و نمی‌توان یک سیستم آموزش دیده را برای چند فرد مختلف مورد استفاده قرار داد. نتایج به دست آمده از شبکه عصبی پرسپترون یاد شده را در دو قسمت آموزش و آزمایش شبکه برای یکی از بیماران می‌توان در شکل (2) مشاهده نمود.

جدول (2) قابل مشاهده می‌باشد.

جدول 2 مشخصات ساختار شبکه عصبی پرسپترون

7	تعداد ورودی
[5 1]	ساختار شبکه عصبی
'tansig' 'pure line'	نرخ یادگیری
0.01	تعداد تکرارها
300	خطای نهایی
0.1	


از دیگر نکاتی که لازم است به آن اشاره شود این است که اصولاً از آنجا که داده‌های ثبت شده در این مقاله به شرایط فیزیولوژیکی بیمار همچون قد، وزن، وجود و یا عدم وجود بیماری دیگر در بیمار، جنسیت و حتی عواملی غیر فیزیولوژیکی که تأثیراتی غیر مستقیم در نوع




(ا)




(ب)




(ج)



(د)



(ه)



(و)

شکل 2 (الف) نمودار سری زمانی مربوط به داده‌های واقعی مرحله آموزش شبکه عصبی MLP با علامت دایره و مقادیر پیش‌بینی شده با علامت مربع می‌باشد که نمودار خطای

پیش‌بینی (ب) و تابع پراکندگی (پ) مرحله آموزش نیز به ترتیب در زیر آن مشخص گردیده است. (ت) شامل نمودار سری زمانی مربوط به داده‌های واقعی مرحله آزمایش شبکه عصبی MLP با علامت دایره و مقادیر پیش‌بینی شده با علامت مربع می‌باشد که نمودار خطی پیش‌بینی (ج) و تابع پراکندگی (د) مرحله آزمایش نیز به ترتیب در زیر آن مشخص گردیده است.

جدول 3 شبکه عصبی پرسپترون چند لایه با تعداد نورون‌های لایه مخفی ثابت و برابر 5

تعداد تکرارها	RMSE		MAE	
	آموزش شبکه	آزمایش شبکه	آموزش شبکه	آزمایش شبکه
300	19.6288	28.5423	7.2100	6.5184
100	35.4706	38.6462	26.5816	15.2530
50	48.5209	56.2561	1.3145	0.9959

شبکه‌های عصبی خود بازگشتی که معروفترین نوع آنها شبکه‌های عصبی المن (Elman) می‌باشند، بیشتر به منظور مدل کردن پدیده‌هایی به کار می‌روند که وقوع آنها به میزان زیادی وابسته به شرایطی است که در گذشته اتفاق افتاده‌اند. این شبکه‌ها با بهره‌گیری از خاصیت دینامیکی خود توانسته‌اند توصیفی مطلوب بین پیچیدگی و قابلیت ارائه دهند.

این شبکه‌ها شامل یک شبکه عصبی پرسپترون چند لایه می‌باشند که در آن خروجی لایه مخفی دوباره توسط حلقه‌های فیدبک به ورودی لایه مخفی شبکه اعمال می‌شود تا از این طریق مقدار خروجی در هر (k)  $MAE = \frac{1}{N} \sum_{k=1}^n |h(k) - t(k)|$  مقادیر تأثیرگذار قبلی وابسته گردد. شبکه عصبی خودبازگشتی المن مورد استفاده در این مقاله از نظر تعداد نورون‌ها، تعداد لایه‌ها و نوع

در نهایت مقادیر میانگین قدر مطلق خطا (Error Root Mean Square) و نیز جذر میانگین مربعات خطا (Absolute Error Mean) برای دو حالت آموزش و آزمایش شبکه عصبی به ترتیب با استفاده از روابط (4) و (5) محاسبه شده است که نتایج آن برای شبکه عصبی پرسپترون سه لایه با پنج نورون در لایه مخفی و به ازای تعداد تکرارهای مختلف در جدول (3) و نیز، با تعداد تکرارهای ثابت 100 و به ازای تعداد نورون‌های مختلف در جدول (4) قابل مشاهده می‌باشد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (t(k) - a(k))^2} \quad (4)$$

$$MAE = \frac{1}{N} \sum_{k=1}^n |h(k) - t(k)| \quad (5)$$

## 2-5- شبکه‌های عصبی خود بازگشتی

تأخیر،  $X_i$  الگوهای ورودی،  $IW_{ij}$  وزنه‌های ضرب شده در ورودی شبکه عصبی،  $a_j(k)$  خروجی لایه مخفی،  $V_j$  وزنه‌های ضرب شده در خروجی لایه مخفی و BGL بیانگر سطح قند خون بیمار می‌باشد. نتایج حاصل از شبکه عصبی خودبازگشتی لمن را در نمودارهای شکل (4) می‌توان مشاهده نمود. همچنین مقادیر میانگین قدر مطلق خطا و نیز جذر میانگین مربعات خطا برای دو حالت آموزش و آزمایش شبکه عصبی پرسپترون سه لایه با پنج نورون در لایه مخفی و به ازای تعداد تکرارهای مختلف در جدول (5) و نیز، با تعداد تکرارهای ثابت 100 و به ازای تعداد نورون‌های مختلف در جدول (6) قابل مشاهده می‌باشد. لازم به ذکر است که بلوکهای D موجود در شکل (3) مشخص کننده تأخیر می‌باشند.

توابع تحریک مورد استفاده در هر لایه و روش آموزش شبکه و نیز، معیار به روز شدن وزن‌ها درست مشابه شبکه عصبی پرسپترون سه لایه ذکر شده قبلی می‌باشد، با این تفاوت که فقط خروجی لایه مخفی با ضرب یک تأخیر در وزن‌هایی مشخص به ورودی لایه مخفی اعمال می‌گردد که در نهایت خروجی‌های لایه مخفی شبکه به همراه خروجی کل شبکه به ترتیب با استفاده از روابط (6) و (7) محاسبه می‌گردد. نمونه‌ای از شبکه عصبی خودبازگشتی لمن مورد استفاده در این مقاله در شکل 3 قابل مشاهده می‌باشد.

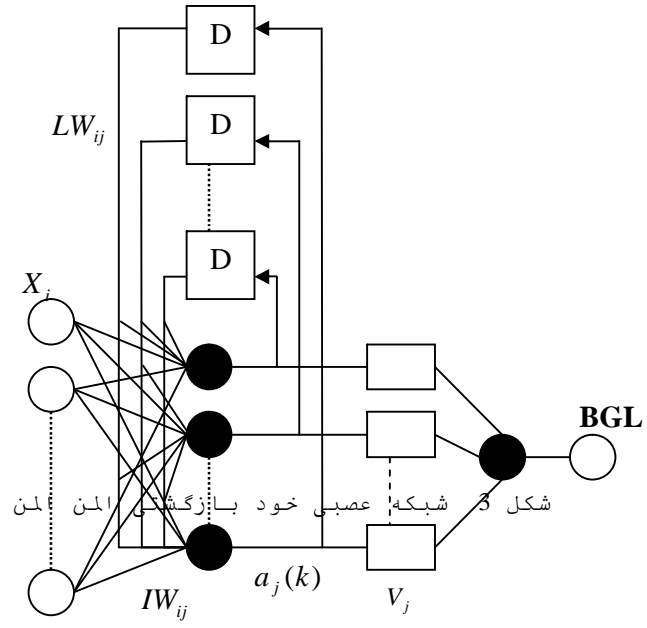
$$a_j(k) = \text{tansig}(X_i \cdot IW_{ij} + a_j(k-1) \cdot LW_{ij}) \quad (6)$$

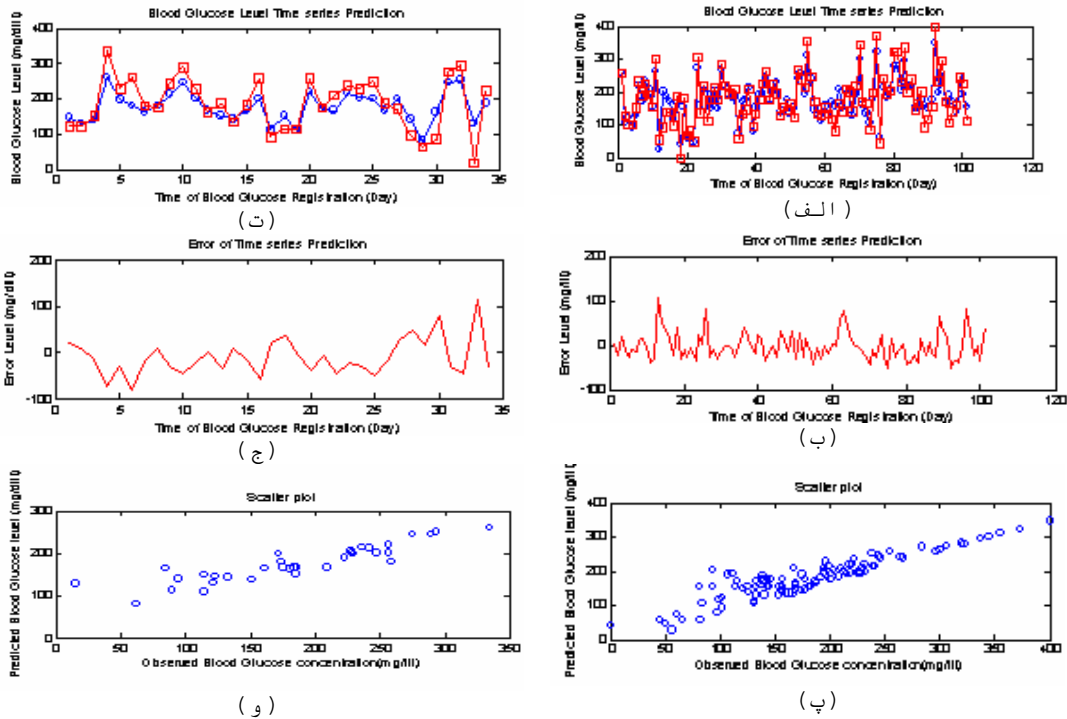
$$BGL = \text{pureline}(a_j(k) \cdot V_j) \quad (7)$$

در این روابط، پارامتر  $LW_{ij}$  وزنه‌های ضرب شده در خروجی

جدول 4 شبکه عصبی پرسپترون چند لایه با تعداد تکرارها ثابت و برابر 100

تعداد نورونها	RMSE		MAE	
	آموزش شبکه	آزمایش شبکه	آموزش شبکه	آزمایش شبکه
5	19.6288	28.5423	7.2100	6.5184
10	24.1051	29.0781	2.8541	9.4720
20	23.7823	105.4930	0.00703	36.7031





شکل 4 (الف) شامل نمودار سری زمانی مربوط به داده‌های واقعی مرحله آموزش شبکه عصبی المن با علامت دایره و مقادیر پیش‌بینی شده با علامت مربع می‌باشد که نمودار خطی پیش‌بینی (ب) و تابع پراکندگی (پ) مرحله آموزش نیز به ترتیب در زیر آن مشخص گردیده است. (ت) شامل نمودار سری زمانی مربوط به داده‌های واقعی مرحله آزمایش شبکه عصبی المن با علامت دایره و مقادیر پیش‌بینی شده با علامت مربع می‌باشد که نمودار خطی پیش‌بینی (ج) و تابع پراکندگی (د) مرحله آزمایش نیز به ترتیب در زیر آن مشخص گردیده است.

جدول 5 شبکه عصبی خودبازگشتی المن با تعداد نورون‌های لایه مخفی ثابت و برابر 5

تعداد تکرارها	RMSE		MAE	
	آموزش شبکه	آزمایش شبکه	آموزش شبکه	آزمایش شبکه
300	11.9628	23.8176	7.2100	6.4306
100	17.3967	20.6092	8.7221	11.2092
50	47.8827	53.1617	1.2918	0.7828

جدول 6 شبکه عصبی خودبازگشتی المن با عداد تکرارها ثابت و برابر 100

تعداد نوروها	RMSE		MAE	
	آموزش شبکه	آزمایش شبکه	آموزش شبکه	آزمایش شبکه
5	19.0513	20.6137	0.3479	5.1124
10	23.0549	25.2545	4.6827	6.7647
20	47.2376	52.6834	0.0379	0.2492

خودبازگشتی به میزان بسیار مطلوبی محقق می‌گردد.

**جدول 7** تعداد نوروها لایه مخفی ثابت و برابر 5 است (برای 300 تکرار)

شبکه عصی	RMSE قسمت آزمایش شبکه عصی	MAE قسمت آزمایش شبکه عصی
MLP	28.5423	6.5184
لین	23.8176	6.4306

جدول 8: تعداد تکرارها ثابت و برابر 100 است (برای 5 نورو)

شبکه عصی	RMSE قسمت آزمایش شبکه عصی	MAE قسمت آزمایش شبکه عصی
MLP	28.5423	6.5184
لین	20.6137	5.1134

#### 4- نتیجه‌گیری و پیشنهاد

از جمله مشکلات حائز اهمیت بیماران دیابتی به ویژه در نوع 1 آن، نوسانات بسیار زیاد و ناگهانی سطح غلظت قند خون می‌باشد که این خود باعث بروز عارضه‌های بسیار خطرناکی چون اغما و بیهوشی خواهد گردید؛ به همین منظور طراحی و استفاده از روش‌هایی در جهت کنترل مناسب سطح غلظت قند خون

### 3- مقایسه نتایج

با خلاصه کردن جداول (3)، (4)، (5) و (6) در دو جدول 7 و 8 (با استخراج بهترین نتایج از هر یک از جداول قبلی) و در نهایت مقایسه این دو جدول با هم می‌توان به این نتیجه دست یافت که اصولاً شبکه‌های عصی خودبازگشتی لین می‌توانند از عملکرد بسیار مطلوب‌تری نسبت به شبکه‌های عصی پرسپترون چندلایه در فرآیند پیش‌بینی نوسانات سطح غلظت قند خون برخوردار باشند که این نتیجه نیز کاملاً منطبق بر عملکرد واقعی مکانیزم سیستم تنظیم قند خون در بدن می‌باشد چرا که در سیستم متابولیسم گلوکز در بدن وضعیت در هر لحظه به شدت وابسته به پارامترهایی نظیر میزان انسولین تزریقی، فعالیت بدنی، غذای مصرفی و... می‌باشد که در گذشته به وقوع پیوسته‌اند و این ویژگی نیز به دلیل وجود تأخیرهای ذکر شده در شبکه‌های عصی

کاهش هزینه طراحی و نیز، کاهش زمان پاسخ شبکه به ورودی می‌باشد. البته به نظر می‌رسد که بهره‌گیری از خاصیت خودبازگشتی و دینامیکی شبکه عصبی المن که تطبیق‌پذیری بیشتری با ماهیت دینامیکی نوسانات سطح قند خون دارد، نقش مهمی را در میزان خطا و تعداد لایه‌ها و نورون‌های مورد استفاده در این تحقیق نسبت به سایر تحقیقات مشابه از خود ایفا می‌کند. هرچند که تعداد بیشتر داده‌های مورد استفاده در تحقیقات مشابه قبلی نسبت به این تحقیق از جمله نکات مثبت آن تحقیقات محسوب می‌شود. از دیگر مزیت‌های مهم شبکه‌های عصبی مورد استفاده در این تحقیق نسبت

و به نوعی پیشگیری از وقوع این عوارض، بسیار ضروری می‌باشد.

در این تحقیق کوشش شد تا اولاً از ویژگی دینامیکی شبکه عصبی خود بازگشتی استفاده شده و مدلی با استفاده از این شبکه به منظور مدل‌سازی و پیش‌بینی رفتار دینامیکی نوسانات سطح قند خون ارائه شود و ثانیاً به منظور نشان دادن تطبیق پذیری بهتر شبکه عصبی خود بازگشتی المن نسبت به شبکه عصبی پرسپترون چندلایه در فرآیند پیش‌بینی سطح قند خون، مقایسه‌هایی نیز میان این دو نوع شبکه عصبی صورت گیرد.

در پایان تحقیق مشخص شد که شبکه‌های عصبی خود بازگشتی از نظر میزان صحت در کل فرآیند پیش‌بینی نوسانات سطح غلظت قند خون دقیقتر از شبکه‌های عصبی پرسپترون چند لایه عمل می‌نمایند. همچنین، مقایسه نتایج به دست آمده از شبکه عصبی خودبازگشتی مورد استفاده در این تحقیق با نتایج به دست آمده از تحقیقات مشابه قبلی نظیر شبکه‌های عصبی پیش‌بین [8]، [12]، [15] نشان دهنده کاهش محسوس تعداد لایه‌ها و تعداد نرون‌های بکار رفته و نیز بهبود میزان کارایی در این تحقیق می‌باشد که این خود باعث

خون، میزان صحت را تا حد زیادی بهبود بخشد ضمن اینکه بهینه ساختن ساختار شبکه‌های عصبی با استفاده از روش‌های هوشمند دیگر نظیر الگوریتم‌های ژنتیک و الگوریتم‌های فازی نیز به عنوان راه‌کارهای مطلوب دیگری برای رسیدن به این مهم پیشنهاد می‌گردد.

در انتها باید گفت که از جمله کاربردهای این تحقیق می‌توان به استفاده از الگوریتم طراحی شده در تلفن‌های همراه، ساعت‌های مچی، پرتال‌های پزشکی و نیز پمپ‌های تزریق انسولین و حتی ساخت پانکرآس مصنوعی به منظور کمک به بیماران دیابتی اشاره نمود.

به مدل‌های ریاضی و دیفرانسیلی [5] و نیز مدل‌های تکه‌ای (compartmental) و [7 و 6] می‌توان به مواردی همچون افزایش قابل ملاحظه تعداد پارامترهای مؤثر بر نوسانات سطح قند خون و نیز مدت زمان بیشتر پیش‌بینی سطح قند خون اشاره نمود. اما نکته‌ای که باید به آن اشاره شود این است که با توجه به اینکه هنوز میزان صحت تا رسیدن به حد ایده‌آل آن فاصله دارد لذا به نظر می‌رسد که می‌توان از طریق شناخت و استخراج تعداد ویژگی‌های پزشکی بیشتر و جدیدتر تأثیرگذار بر روند نوسانات غلظت قند خون و نیز، کاهش فاصله‌های زمانی بین اندازه‌گیری‌های سطح غلظت قند

## مراجع

1. B. Larijani, F. Zahedi, S. Aghakhani, "Epidemiology of Diabetes Mellitus in Iran", Shiraz E-Medical Journal, Vol. 4, No. 4, (2003).
2. M.H. Kroll, "Biological variation of glucose and insulin includes a deterministic chaotic component", BioSystems 189–201, (1999).
3. A. De Gaetano, O. Arino, "Mathematical modelling of the intravenous glucose tolerance test", J. Math. Biol. 40, 136–168, (2000).
4. R.N. Bergman, "Pathogenesis and prediction of diabetes mellitus: Lessons from integrative physiology, in: Irving L. Schwartz Lecture, Mount Sinai J. Medicine 60, 280–290, (2002).
5. D.L. Bennett, S.A. Gourley, "Asymptotic properties of a delay differential equation model for the interaction of glucose with plasma and interstitial insulin", Appl. Math. Comput. 151, pp. 189–207, (2004)

6. J. Li, Y. Kuang, C. Mason, "Modelling the glucose-insulin regulatory system and ultradian insulin secretory oscillations with two time delays", submitted for publication.
7. M.S. Leaning and M.A. Boroujerdi, "A system for compartmental modelling and simulation", *Comput. methods programs biomed.*, Vol.35, (1991).
8. Tresp V., Moody J., and Delong W.-R., "Neural modelling of physiological processes", *Computational Learning Theory and Natural Learning Systems*, Vol. 2, S. Hanson et al., eds., MIT Press, (1994).
9. A. Drozdov, H. Khanina, "A model for ultradian oscillations of insulin and glucose", *Math. Comput. Modelling* Vol. 22, pp. 23–38, (1995)
10. E. Salzsieder, G. Albrecht, U. Fischer, A. Rutscher and U. Thierbach, "Computer-aided systems in the management of type I diabetes: the application of a model-based strategy", *Comput. Methods programs biomed.*, Vol. 32, (1990).
11. O.K. Hejlesen, S. Andreassen, R. Hovorka and D.A. Cavan, "Dias-the diabetic advisory system: an outline of the system and the evaluation results obtained so far", *Computer methods and programs in biomedicine*, Vol. 54, (1997).
12. K. Prank, C.J. Äurgens, A. MÄuhlen and G. Brabant, "Predictive Neural Networks for Learning the Time Course of Blood Glucose Levels from the Complex Interaction of Counter regulatory Hormones", *Neural Computation* Vol. 10, pp. 941-953, (1998).
13. G. Gogou, N. Maglaveras, B.V. Ambrosiadou, D. Goulis and C. Pappasl, "A Neural Network Approach in Diabetes Management by Insulin Administration", *Journal of Medical Systems*, Vol. 25, No. 2, (2001).
14. T. Katayama, T. Sato, K. Minato, "A blood glucose prediction system by chaos approach", *Proceedings of the 26th Annual International Conference of the IEEE EMBS San Francisco, CA, USA* September 1-5, (2004).
15. R.A. Zitar ,A. Al-Jabali, "Towards Neural Network Model for Insulin/Glucose in Diabetics-II", *Informatica* 29, 227–232, (2005).