

# الگوریتمهای جدید بر اساس اتوماتای یادگیر برای یافتن پارامترهای ویولت

محمد رفیع خوارزمی

دانشکده صنعت الکترونیک - دانشگاه شیراز

محمد رضا میبدی

استاد دانشکده مهندسی کامپیوتر - دانشگاه صنعتی امیرکبیر

(تاریخ دریافت ۱۹/۱۲/۸۱، تاریخ دریافت روایت اصلاح شده ۱۱/۱۱/۸۲، تاریخ تصویب ۲۹/۱/۸۳)

## چکیده

ویولتها قادر هستند که یکتابع را در دقتها مختلف تقریب بزنند. این خاصیت آنها را برای مدل سازی و تقریب سیستمهای غیر خطی مناسب ساخته است. برای بدست آوردن یک تقریب مناسب محاسبه پارامترهای توابع پایه ویولت از اهمیت زیادی برخوردار است. برای محاسبه پارامترهای توابع پایه ویولت روش‌های متعددی از جمله روش‌های شبکه‌های عصبی (ویونت) بکار برده شده است. در این مقاله روش جدیدی بر اساس اتوماتای یادگیر برای محاسبه پارامترهای ویولت ارائه گردیده است. روش پیشنهادی از قدرت تصمیم‌گیری و جستجوی اتوماتای یادگیر استفاده کرده و در هر مرحله با اضافه کردن ویولت جدید به تقریب قبلی و حذف ویولتهایی که به کاهش خطای کمکی نمی‌کنند سعی در کاهش خطای کمکی نماید. روش‌های پیشنهادی برخلاف روش یادگیری<sup>1</sup> که نیاز به محاسبات بسیار بالائی (از جمله معکوس کردن یک ماتریس با ابعاد بالا برای تعداد زیاد نمونه‌ها) از محاسبات کمتر و بسیار ساده تری برخوردار است. همچنین برخلاف برخی روش‌های بر پایه شبکه‌های عصبی که دارای ساختار ثابتی هستند دارای ساختاری پویا می‌باشد یعنی تعداد توابع پایه از قبل مشخص نمی‌گردد بلکه در هین فرایند تقریب تعیین می‌شود. روش پیشنهادی برروی مسائل متنوعی آزمایش شده است و نتایج بسیار خوبی بدست آمده است.

**واژه‌های کلیدی:** ویولت، اتوماتای یادگیر، الگوریتمهای یادگیری، شبکه‌های عصبی

## مقدمه

می‌توان با آنها تقریب زد<sup>[۴][۳][۲]</sup>. در سالهای اخیر کارهای متعددی در ارتباط با تلفیق شبکه‌های عصبی و بسط ویولت انجام شده است. زانگ و بنونسیت<sup>[۴]</sup> یک شبکه<sup>(۱+۱/۲)</sup> لایه‌ای با الگوریتم آموزش انتشار خطای عقب برای تعیین پارامترهای ویولت پیشنهاد کرده‌اند. بخشی و استفانوپولس<sup>[۵]</sup> شبکه‌ای به نام ویونت پیشنهاد نمودند که در آن از الگوریتم انتشار خطای عقب برای آموزش آن استفاده می‌شود. برای تخمین ضرائب ویولت توسط شبکه‌های ویونت، آموزش دقیق شبکه معمولاً با مشکل مواجه می‌شود و یا اینکه خطای از حد معینی کمتر نمی‌شود. در روش یادگیری<sup>2</sup> خطای بدست آمده حداقل خواهد بود<sup>[۶]</sup> اما محاسبات زیاد از جمله محاسبه معکوس یک ماتریس با ابعاد بزرگ از مشکلات آن می‌باشد.

در این مقاله روشی مبتنی بر اتوماتای یادگیر برای تعیین پارامترهای ویولت بمنظور تقریب توابع پیشنهاد می‌گردد. یکی از مزیتهای روش‌های پیشنهادی تعیین تعداد توابع پایه

نمایش یک تابع به صورت بسط یک سری توابع پایه نقش مهمی در پردازش سیگنال، مدل سازی و تقریب توابع دارد. به عنوان مثال از بسط فوریه در دستگاه مثلثاتی برای پردازش سیگنال در حوزه فرکانس ویا از شبکه‌های عصبی به عنوان ابزاری برای مدل سازی و تقریب سیستم‌های غیر خطی بر اساس داده‌های ورودی-خروجی استفاده شده است. اما ضرائب فوریه بیشتر خواص فرکانسی سیگنال را بیان می‌کنند. بنابراین بسط یک تابع بر اساس یک سری توابع پایه که به خوبی در بعد زمان و فرکانس مرکز شده باشند بسیار مفید خواهد بود. بسط توابع با توجه به تئوری ویولت، که یک تابع را به صورت مجموعه‌ای از توابع پایه در وضوحهای مختلف نشان می‌دهد این نیاز را برآورده می‌سازد<sup>[۱]</sup>. کارهای گزارش شده نشان میدهد که توابع پایه ای وجود دارد که هر تابع قابل اندازه گیری روی محور حقیقی R را

$$F_0(x) = \sum_k a_{0,k} \phi_{0,k}(x)$$

$\phi_{m,k}(x)$  را تابع مقیاس کننده می نامند و به صورت زیر تعریف می شود.

$$m, k \in \mathbb{Z} \quad \phi_{m,k}(x) = 2^{-m/2} \psi(2^{-m}x - k) \quad (3)$$

بنابر این خواهیم داشت

$$F_0(x) = \sum_k a_{0,k} \phi_{0,k}(x)$$

$$F_{-1}(x) = F_0(x) + \sum_k d_{0,k} \psi_{0,k}(x)$$

$$F_{m-1}(x) = F_m(x) + \sum_k d_{m,k} \psi_{m,k}(x)$$

و این عمل تا زمانی که یک تقریب مناسب بدست آید ادامه می یابد. تابع هار<sup>۲</sup> یکی از این توابع پایه می باشد که به صورت زیر بیان می شود

$$\psi(x) = \begin{cases} 1 & 0 \leq x < 0.5 \\ -1 & 0.5 \leq x < 1 \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$$\phi(x) = \begin{cases} 1 & 0 \leq x < 1 \\ 0 & \text{otherwise} \end{cases}$$

معادله (۱) را میتوان در قالب شبکه های عصبی نشان داد. این شبکه ها که ویونت نامیده میشوند توسط بخشی و استفانوبولس در سال ۹۳ معرفی گردید [۹][۵]. آنها ویونتها را به صورت یک شبکه عصبی چند دقتی سلسله مراتبی با یک لایه مخفی که تابع فعالیت نرونها آنها تابع پایه متعامد میباشند در نظر گرفتند. البته می توان به جای ویولتهای متعامد یکه از نمونه های دیگر ویولتها نیز استفاده کرد. برای طراحی کامل شبکه های ویونت باید نوع تابع بکار رفته، تعداد گره ها یعنی تعداد ویولتها و یک

به صورت پویا می باشد. بدین معنی که تعداد توابع پایه از قبل مشخص نمی باشد بلکه همزمان با فرایند تقریب مشخص می شود. در این روشها در هر مرحله با اضافه کردن و یا کم کردن یک ویولت سعی در کاهش خطای میشود. نتایج شبیه سازیها با روشهای پیشنهادی نشان می دهد که با تعداد توابع پایه کمتری میتوان به نتایج مشابه روشهای موجود دست یافت.

قسمتهای بعدی مقاله بصورت زیر سازماندهی شده اند. خلاصه ای از تئوری ویولت در بخش ۲ و مروری بر اتماتاهای یادگیر در بخش ۳ آمده است. در بخش ۴ الگوریتم های یادگیری ویولت را مرور خواهیم کرد. الگوریتمهای پیشنهادی در قسمت ۵ و نتایج شبیه سازی بر روی چند مساله نمونه در قسمت ۶ آمده است. در انتهای مقاله نتایج را مورد بررسی قرار خواهیم داد.

## اصول ویولت<sup>۱</sup>

تئوری ویولت ابتدا توسط مورلت و گروسمان در زمینه پردازش سیگنال مطرح شد [۷]. سپس تقریب چند دقیق توسط مالات ارائه شد و دو بیشیز خانواده وسیعی از ویولتهای مختلف را ارائه نمود [۲][۸]. بر اساس این تئوری تمام تابع حقیقی ( $F(X) \in L^2(\mathbb{R})$ ) می تواند به صورت یک ترکیب خطی از یک سری توابع پایه متعامد ویولت به فرم  $\psi_{m,k}(x)$  بیان شوند.

$$F(x) = \sum_{m=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} d_{m,k} \psi_{m,k}(x) \quad (1)$$

$$m, k \in \mathbb{Z} \quad \psi_{m,k}(x) = 2^{-m/2} \psi(2^{-m}x - k)$$

که در آن  $2^{-m}$  و  $k$  به ترتیب ضرائب انتقال و تأخیر و  $2^{-m/2}$  ضریب نرمالیز کردن انرژی می باشند. معادله (۱) نشان می دهد که مجموعه ای از ویولتها با تأخیر و انتقال یک تابع ویولت مادر ( $\psi_{m,k}(x)$ ) بدست می آید. اکنون اگر از تقریب  $m=0$  شروع کنیم معادله (۱) را می توان به صورت زیر نشان داد.

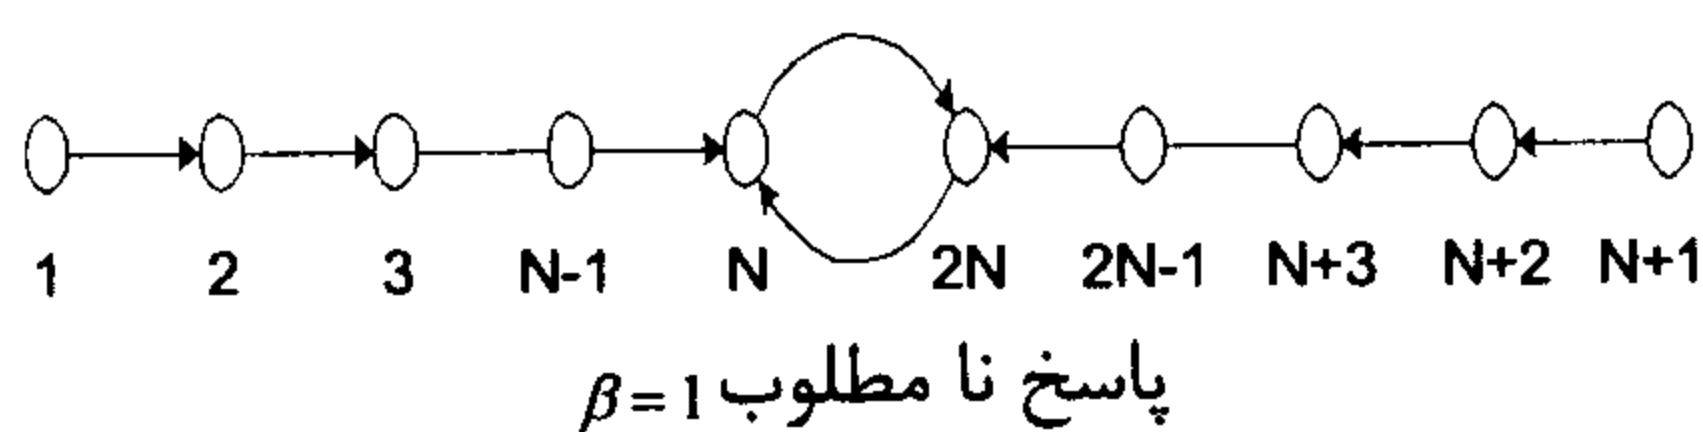
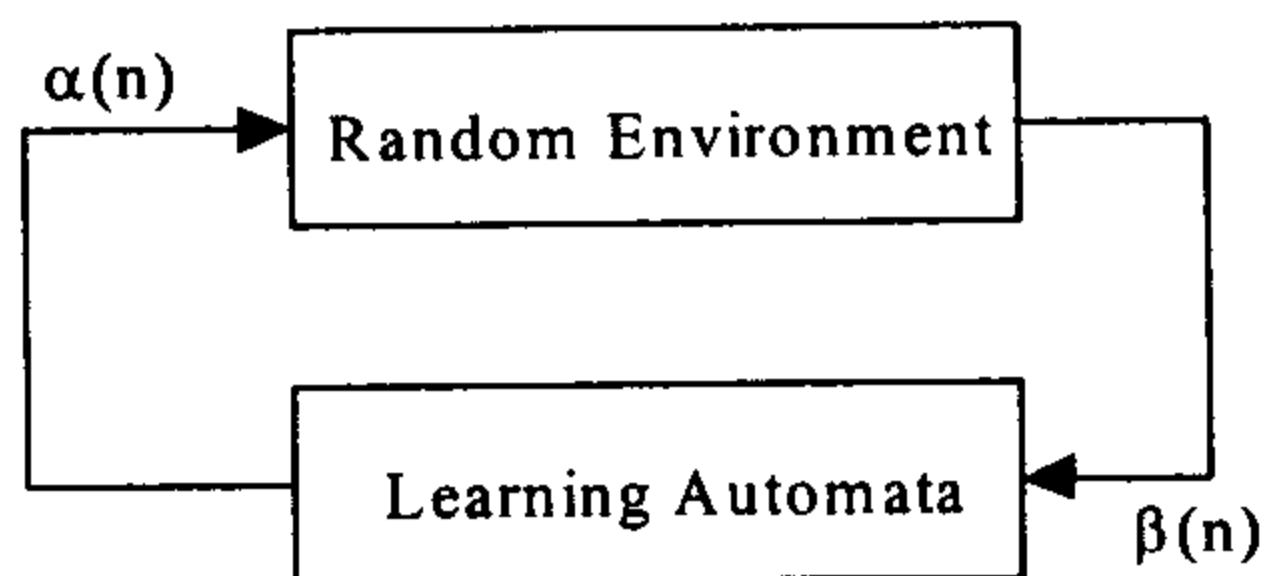
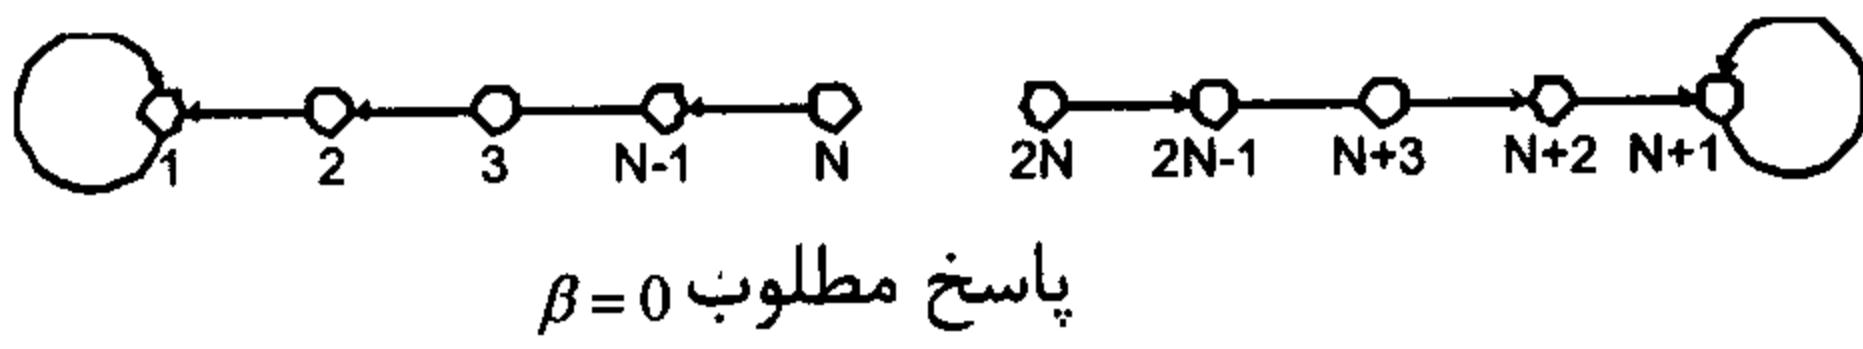
$$F(x) = F_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{+\infty} d_{m,k} \psi_{m,k}(x) \quad (2)$$

الگوریتم یادگیری برای بدست آوردن ثابت‌های  $a$  و  $d$  را مشخص کرد [۹].

اتوماتای یادگیر

اتوماتای یادگیر: اтомاتای یادگیر یک مدل انتزاعی است که تعداد محدودی عمل را می‌تواند انجام دهد. هر عمل انتخاب شده توسط محیطی احتمالی ارزیابی شده و پاسخی به اтомاتای یادگیر داده می‌شود. اтомاتای یادگیر از این پاسخ استفاده نموده و عمل خود را برای مرحله بعد انتخاب می‌کند [۱۲][۱۱][۱۰]. شکل (۱) ارتباط بین اтомاتای یادگیر و محیط را نشان می‌دهد.

اتوماتای  $L_{2N,2}$ : این اтомاتا تعداد پاداش‌ها و جریمه‌های در یافت شده برای هر عمل را نگهداری کرده و تنها زمانی که تعداد جریمه‌ها بیشتر از تعداد پاداش‌ها می‌گردد، عمل دیگر را انتخاب می‌کند. نمودار تغییر وضعیت این اutomata مطابق شکل (۲) می‌باشد.



شکل ۲: نمودار تغییر وضعیت اوتوماتان  $L_{2N,2}$ .

اتوماتای یادگیر با ساختار متغیر<sup>۱</sup>: اтомاتای یادگیر با ساختار متغیر توسط ۴ تائی  $\{\alpha, \beta, p, T\}$  نشان داده می‌شود که در آن  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$  مجموعه عمل‌های اوتوماتا،  $\beta = \{\beta_1, \beta_2, \dots, \beta_m\}$  مجموعه ورودیهای اوتوماتا،  $p = \{p_1, p_2, \dots, p_r\}$  بردار احتمال انتخاب هر یک از عملها و  $T = \prod[\alpha(n), \beta(n), p(n)]$  الگوریتم یادگیری می‌باشد. در این نوع از اوتوماتاها، اگر عمل  $i$  در مرحله  $n$  ام انتخاب شود و پاسخ مطلوب از محیط دریافت نماید، احتمال  $p_i(n)$  افزایش یافته و سایر احتمالها کاهش می‌یابند. و برای پاسخ نامطلوب احتمال  $p_i(n)$  کاهش یافته و سایر احتمالها افزایش می‌یابند. در هر حال، تغییرات به گونه‌ای صورت می‌گیرد تا حاصل جمع  $p_i(n)$  ها همواره ثابت و مساوی یک باقی بماند. الگوریتم زیر یک نمونه از الگوریتمهای یادگیری خطی در اوتوماتای

محیط را می‌توان توسط سه تایی  $E = \{\alpha, \beta, C\}$  نشان داد که در آن  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$  مجموعه ورودیها،  $C = \{c_1, c_2, \dots, c_s\}$  مجموعه خروجیها و  $\beta = \{\beta_1, \beta_2, \dots, \beta_m\}$  مجموعه احتمالهای جریمه می‌باشد. هر گاه  $\beta$  مجموعه دو عضوی باشد، محیط از نوع  $P$  می‌باشد. در چنین محیطی  $\beta_1 = 1$  به عنوان جریمه و  $\beta_2 = 0$  به عنوان پاداش در نظر گرفته می‌شود. در محیط از نوع  $Q$ ،  $\beta(n)$  می‌تواند به طور گسسته یک مقدار از مقادیر محدود در فاصله  $[0, 1]$  و در محیط از نوع  $S$ ،  $\beta(n)$  متفاوت تصادفی در فاصله  $[0, 1]$  است.

$C_i$  احتمال اینکه عمل  $i$  نتیجه نامطلوب<sup>۴</sup> داشته باشد می‌باشد. در محیط ایستا<sup>۵</sup> مقادیر  $C_i$  بدون تغییر می‌مانند، حال آنکه در محیط غیر ایستا<sup>۶</sup> این مقادیر در طی زمان تغییر می‌کنند. اтомاتای یادگیر به دو گروه با ساختار ثابت و با ساختار متغیر تقسیم می‌گردد.

اتوماتای یادگیر با ساختار ثابت<sup>۷</sup>:

اتوماتای یادگیر با ساختار ثابت توسط ۵ تائی

$$f(x, n+1) = \begin{cases} a[f(x, n) + \beta H(x, r)] & \text{if } x \in X \\ 0 & \text{otherwise} \end{cases}$$

$$H(x, r) = \lambda \exp\left(-\frac{(x-r)^2}{2\delta^2}\right)$$

که در آن  $\alpha$  به گونه ای انتخاب می شود تا رابطه  $\int_{x_{\min}}^{x_{\max}} f(x, n) dx = 1$  برقرار شود.

همسایگی متقارن گوسی شکل و  $\lambda$  و  $\delta$  پارامترهای تعیین کننده ارتفاع و عرض تابع همسایگی می باشند. برای اطلاعات بیشتر درباره اتماتاهای یادگیر می توان به [۱۳] [۱۱] [۱۲] مراجعه نمود.

### الگوریتمهای یادگیری ویونت

معادله (۲) ساختار کلی شبکه ویونت را بیان کرده و نشان می دهد که چگونه هر ویولت در فرایند تقریب مشارکت دارد. همچنان نشان می دهد که تابع مقیاس کننده فقط در مرحله اول تقریب برای ایجاد  $F_0$  بکار می رود. بعد از ایجاد  $F_0$  تقریب بهتر با اضافه کردن ویولت با همان دقت یعنی  $m=0$  انجام می گیرد و  $F_0$  را تولید  $m=-1$  می کند. اضافه کردن ویولتهای با دقت بالاتر مثل  $m=1$  باعث تقریب بهتر یعنی  $F_1$  می شود. این فرایند ادامه می یابد تا تابع اصلی ایجاد شود. اکنون به بررسی روش‌های محاسبه ضرائب شبکه یعنی  $a_{m,k}$  و  $d_{m,k}$  می پردازیم.

نزول در امتداد گرادیان<sup>۱۳</sup>: یادگیری در روش نزول در امتداد گرادیان شبیه یادگیری انتشار خطأ به عقب در شبکه های عصبی می باشد. الگوریتم بر اساس شبکه های عصبی می نمایش غیر متعامد و پیوسته معادله (۳) می باشد عمل می کند که در آن  $\bar{f}$  مقدار میانگین تابع  $F(x)$  با توجه به نمونه های ورودی خروجی و  $w_i, t_i, s_i$  پارامترهای ویولت می باشند. این الگوریتم از روش جستجو در امتداد گرادیان برای حداقل نمودن یک تابع هزینه  $J$  استفاده می کند. اگر  $\Theta$  بردار متغیرهایی باشد که میخواهیم محاسبه کنیم در مرحله یادگیری گرادیان  $J$  نسبت به پارامترهای مختلف محاسبه شده و مقادیر بردار  $\Theta$  در جهت عکس گرادیان تابع هزینه تغییر می کند. توضیحات بیشتر در مورد چگونگی

با ساختار ثابت است [۱۴].

الف- پاسخ مطلوب

$$p_i(n+1) = p_i(n) + a[1 - p_i(n)]$$

$$p_j(n+1) = (1-a)p_j(n) \quad j \neq i \quad \forall j$$

ب- پاسخ نامطلوب

$$p_i(n+1) = (1-b)p_i(n)$$

$$p_j(n+1) = \frac{b}{r-1} + (1-b)p_j(n) \quad j \neq i \quad \forall j$$

در روابط فوق،  $a$  پارامتر پاداش و  $b$  پارامتر جریمه می باشد. با توجه به مقادیر  $a$  و  $b$  سه حالت زیر را می توان در نظر گرفت. زمانیکه  $a$  و  $b$  با هم برابر باشند، الگوریتم را  $L_{RP}^{10}$  می نامیم. زمانیکه  $b$  از  $a$  خیلی کوچکتر باشد، الگوریتم را  $L_{REP}^{11}$  می نامیم و زمانیکه  $b$  مساوی صفر باشد، الگوریتم را  $L_{RI}^{12}$  می نامیم.

اتوماتای یادگیر با اقدام پیوسته: این اتماتا دارای یک اقدام است اما این اقدام در هر مرحله از تکرار می تواند مقادیر مختلف را اختیار کند [۱۵]. ( به بیان دیگر این اتماتا میتوانند دارای بینهایت اقدام باشد). این اقدام به صورت یک متغیر تصادفی پیوسته ،  $X$  ، که مقادیر خود را در فاصله  $[x_{\min}, x_{\max}]$  اختیار میکند در نظر گرفته می شود. بنابراین تابع توزیع احتمال گسسته در هر مرحله از تکرار  $n$  با تابع چگالی احتمال  $f(x, n)$  جایگزین میشود که رابطه زیر در مورد آن برقرار است.

$$\int_{-\infty}^{\infty} f(x, n) dx = \int_x f(x, n) dx = 1 \quad f(x, n) \geq 0 \quad \forall n, \forall x$$

تابع توزیع اولیه(مرحله صفر) را تابع یکنواخت به صورت

$$f(x, 0) = \frac{1}{x_{\max} - x_{\min}} \quad \text{در نظر می گیریم. سپس در هر مرحله تکرار یک عدد تصادفی}(n) Z در فاصله  $[0, 1]$  ایجاد$$

کرده و اقدام  $x(n)$  به صورتی انتخاب می شود تا

$$\int_{x_{\min}}^{x(n)} f(x, n) dx = z(n) \quad \text{بر قرارشود. آنگاه اقدام } x(n) \text{ بر}$$

روی محیط اعمال می شود. نتیجه اقدام ممکن است به صورت موفقیت یا شکست یا یک تابع ارزیابی به صورت  $\beta(n)$  بیان شود. اکنون با توجه به مقدار  $\beta(n)$  چگالی احتمال  $f(x, n)$  به صورت زیر تصحیح می شود.

برابر  $(F(X) - F_m(X))$  می باشد که می توانیم آن را به فرم ماتریسی به صورت  $\bar{F}(X) = AC$  نشان دهیم و در آن  $A$  ماتریس مقادیر توابع ویولت و  $C$  ماتریس ضرائب می باشد. بوسیله روش حداقل مربعات ضرائب  $C$  از رابطه زیر محاسبه می شوند

$$C = ((A^T A)^{-1}) A^T \bar{F} = A^+ \bar{F}$$

اگر ویولتها را متعامد یکه انتخاب کنیم  $A^T A$  یک ماتریس واحد خواهد بود و رابطه فوق به شکل نهایی  $C = A^T \bar{F}$  تبدیل خواهد شد. برای اطلاعات بستر در باره روش‌های فوق به [۶] مراجعه شود.

### تخمین ضرائب ویولت اتوماتای یادگیر

در این قسمت ۳ الگوریتم مبتنی بر اتوماتاهای یادگیر برای تخمین ضرائب ویولت معرفی می شود. این الگوریتم ها به جای استفاده از یک ساختار ثابت، از یک ساختار پویا بر خوردار است و بهمین دلیل نیازی به دانستن تعداد ویولت ها از قبل نمیباشد. همچنین برخلاف روش یادگیری L2 که محاسبات زیاد و بدست آوردن معکوس یک ماتریس با ابعاد بالا برای تعداد زیاد نمونه ها لازمه آن است از محاسبات کمتر و بسیار ساده تری برخوردار است. الگوریتمهای پیشنهادی همانطور که در قسمت شبیه سازی نشان داده شده است نتایج نزدیک به حداقل خطرا را تولید میکند. این الگوریتمها برای تقریب از یک مقدار اولیه برای ضریب شروع می کنند و سپس مقدار بهینه برای این ضریب را در اطراف مقدار اولیه جستجو می کنند. مقدار اولیه ضرائب را می توان با استفاده از ضرب داخلی مقادیر تابع و مقادیر ویولتهای پایه در نقاط خاص، و یا با استفاده از روش پیشنهاد شده در مرجع [۴] محاسبه کرد. اکنون به شرح الگوریتمهای پیشنهادی می پردازیم.

**الگوریتم ۱:** اولین الگوریتم، مبتنی بر اتوماتای یادگیر با ساختار متغیر از نوع  $L_{RP}$  میباشد. در این الگوریتم به هر ضریب یک اتوماتای یادگیر تخصیص داده میشود که وظیفه پیدا کردن مقدار بهینه برای ان ضریب را بعهده دارد. هر اتوماتا دارای  $N$  اقدام متفاوت می باشد و احتمال  $p_i = 1/N$  انتخاب هر کدام از آنها در ابتدا مساوی و برابر

عملکرد الگوریتم در مرجع [۴] آمده است.

**ضرب داخلی مستقیم**<sup>۱۴</sup>: در این روش در هر مرحله تابع  $F(x)$  با استفاده از یک سری توابع متعامد پایه جدید تقریب زده می شود. در اولین مرحله که دقت  $m = 0$  نامیده می شود تابع  $F(x)$  به صورت  $F_0(x) = \sum_k a_{0,k} \phi_{0,k}(x)$  تقریب زده می شود. در

مراحل بعدی هر تقریب جدید تقریب قبلی را بهبود می بخشد. به عنوان مثال در یک تقریب دلخواه  $m$  تابع تقریب به صورت زیر خواهد بود.

$$F_{m-1}(x) = F_m(x) + \sum_k d_{m,k} \psi_{m,k}(x)$$

در این حالت ضرائب هر کدام از این بسط، تصویر عمود تابع اصلی  $F(x)$  بر روی توابع پایه خواهد بود [۶]. بنابراین می توان نوشت :

$$a_{m,k} = \langle \phi_{m,k}(x), F(x) \rangle ,$$

$$d_{m,k} = \langle \psi_{m,k}(x), F(x) \rangle$$

در این روش توابع پایه ویولت باید متعامد یکه باشند. همچنین باید تعداد نمونه های کافی از ورودی در دسترس باشد.

**روش یادگیری L2:** در این روش با استفاده از خواص توابع ویولت ضرائب به شکلی محاسبه می شوند تا مجموع مربعات خطای تقریب حداقل شود. فرض می کنیم که بردارهای ورودی و خروجی نمونه های گستته از یک تابع

$$X = [x_1, x_2, \dots, x_n]^T$$

و  $F = [f(x_1), f(x_2), \dots, f(x_n)]^T$  باشند. با توجه به اینکه بردارهای پایه مقیاس کننده و ویولت شبیه هم می باشند برای سادگی آنها را با  $\theta(x)$  نشان می دهیم و ضرائب  $a$  و  $d$  را با  $c$  جایگزین می کنیم. آنگاه در هر سطح از تقریب مسئله تقریب را می توان با رابطه

$$\bar{F}(x) = \sum_{k=1}^K c_k \theta_k(x)$$

تعداد توابع پایه می باشد. اولین تقریب یعنی  $F_0$  با استفاده از تابع مقیاس کننده بدست می آید و تقریب جدید به کمک تقریب قبلی به شکل زیر محاسبه میشود.

$$F_{m-1}(x) = F_m + \sum_k c_{m,k} \psi_{m,k}$$

که  $F_m$  تقریب قبلی و  $F_{m-1}$  تقریب جدید است. پس می توانیم بگوییم میزان تغییرات در هر تقریب

۳- تابع توزیع احتمال یکنواخت  $f_i(k_i, n)$  برای  $k_i$  در تکرار  $n$  را تعریف کن

۴- تابع توزیع احتمال  $f_i(k_i, n)$  برای مقادیر  $i=1..m$  در محدوده تعیین شده مقدار اولیه دهی کن

۵- مراحل زیر را تکرار کن تا اینکه خطا به حد معینی برسد.

یک عدد تصادفی بین صفر و یک  $(n)$   $z_i$  را با استفاده از یک تولید کننده اعداد تصادفی انتخاب کن

تا  $k_i \in A(n)$  :

$$\int_{x_i \min}^{k_i(n)} f(x, n) dx = z_i(n) \text{ شود}$$

: اقدام را بر روی سیستم اعمال کن

:  $\beta(n)$  را محاسبه کن

: تابع توزیع احتمال  $f_i(k_i, n)$  را به هنگام کن

### نتایج شبیه سازی

در این قسمت عملکرد الگوریتمهای پیشنهادی برای چند مثال نمونه مورد بررسی و با الگوریتمهای موجود مقایسه میگردد.

**مثال اول:** در این مثال یک سیستم دیگ واکنشی پیوسته (CSTR)<sup>۱۵</sup> که در آن یک واکنش شیمیایی گرمایی برگشت پذیر در دمای ثابت انجام میگیرد را مدل سازی می کنیم. واکنش انجام گرفته نسبت به غلظت مواد ورودی از درجه یک بوده که توسط معادله زیر بیان میشود.

$$Rate = -k_0 C V e^{-\frac{E}{RT}}$$

که در آن  $V$  حجم دیگ،  $k_0$  ضریب واکنش،  $C$  غلظت مواد ورودی،  $E/R$  مقدار ثابت،  $T$  دمای واکنش و  $Rate$  میزان واکنش انجام شده می باشد. در این مثال غلظت مواد ورودی را ثابت در نظر گرفته و دما را که میزان جریان آب است به عنوان ورودی فرض می کنیم. ورودی از یکصد نقطه که به صورت یکنواخت در فاصله [۰، ۱۵۰] ایجاد شده تشکیل شده است. نیمی از ورودی ها که به صورت یک در میان انتخاب شده اند برای آموزش و نیمی دیگر برای آزمایش شبکه بکار برده شده اند. ورودی و خروجی اولیه در شکل (۳) نمایش داده شده است.

می باشد. هر اقدام مقادیر خود را در فاصله  $\{k_{\min}, k_{\max}\}$  اختیار میکند. بر اساس اقدام انتخاب شده یک مقدار پابت در ضریب ویولت ضرب می شود. اگر مقدار اقدام انتخاب شده توسط اتماتا در یک مرحله  $k_c$  باشد ضریب ویولت استفاده شده توسط الگوریتم برای مرحله بعد  $k_c$  برابر ضریب در مرحله فعلی خواهد بود. در هر مرحله از الگوریتم هر یک از اتماتاها یکی از اقدامهای خود را انتخاب میکنند و با توجه به مقدار انتخاب شده توسط اتماتا مقدار ضریب ویولت مورد نظر برای مرحله بعد محاسبه میشود. با استفاده از ضرایب تعیین شده توسط اتماتاها مقدار جدید تابع  $F_i(x) = \sum_j c_{i,j} \theta_{i,j}(x)$

خطای تغییر به صورت  $e = F(x) - F_1(x)$  محاسبه می گردد. اگر خطای بدست آمده از خطای مرحله قبل کمتر باشد اقدام انتخاب شده پاداش می گیرد و در غیر اینصورت جریمه می شود. بر اساس نتیجه اقدام هر اتماتا، بردار احتمالات انتخابهای ان اتمانا تصحیح می شود.

**الگوریتم ۲:** این الگوریتم، مبتنی بر اتماتای یادگیر با ساختار ثابت از نوع  $L_{2N,2}$  میباشد. در این الگوریتم نیز همانند الگوریتم ابرای هر ضریب ویولت یک اتماتا تخصیص داده میشود ولی مقادیر اقدامهای هر اتماتا مقادیر متفاوت افزایش یا کاهش به ضریب ویولت در نظر گرفته میشود. هر اتماتا دارای  $K$  اقدام هر یک با عمق حافظه  $N$  می باشد. بر اساس اقدام انتخاب شده یک مقدار معین به ضریب ویولت افزوده و یا کاسته می شود. در صورتی که این افزایش یا کاهش باعث بهبود خطا شود این عمل تکرار می شود و در غیر اینصورت بر اساس تعداد دفعات پاسخ ناموفق اقدام تغییر کرده و میزان افزودن و یا کاستن ضریب تغییر میکند.

**الگوریتم ۳:** این الگوریتم، مبتنی بر اتماتای یادگیر با اقدام پیوسته میباشد. در این الگوریتم به ازای هر ضریب یک اتماتا با ساختار پیوسته در نظر گرفته میشود. الگوریتم یادگیری به صورت زیر بیان می شود.

۱- دفعات تکرار  $(n)$  را برابر صفر قرار بده

۲- مجموعه اقدامها را برای  $m$  پارامتر ویولت به صورت  $A(n) = \{k_1(n), k_2(n), \dots, k_m(n)\}$  انتخاب کن

جدول ۲ : مقادیر متوسط خطای برای الگوریتم ۲ .

الگوریتم	دقت تقریب	-۲	-۱	.
الگوریتم ۲ با عمق ۱	۰.۰۳۵۰	۰.۰۴۵۸	۰.۰۹۷۳	
الگوریتم ۲ با عمق ۲	۰.۰۱۲۱	۰.۰۲۴۵۱	۰.۰۸۵۲	
الگوریتم ۲ با عمق ۳	۰.۰۲۲۲	۰.۰۳۶۵	۰.۰۹۴۸۵	
الگوریتم ۲ با عمق ۴	۰.۰۲۶۹	۰.۰۳۷۸	۰.۰۹۵۸۶	
L2 روش یادگیری	۰.۰۰۰۸	۰.۰۰۸۵۹	۰.۰۷۲۶	

شبیه سازی برای الگوریتم ۲ : در این قسمت اقدامها را برابر مقادیر ثابت افزایش یا کاهش به ضریب در نظر گرفتیم . هر اتوماتا دارای هشت اقدام متفاوت است که این اقدامها عبارتند از : [۰.۰۵ - ۰.۱۲ - ۰.۳ - ۰.۰۵ - ۰.۱۲ - ۰.۰۰۲ - ۰.۰۰۸] . میانگین مربع خطای نتایج شبیه سازی شده به ازای مقادیر مختلف عمق در جدول (۲) نشان داده شده است . نتایج جدول (۲) نشان می دهد که الگوریتم ۲ که در ان از اتوماتای با ساختار ثابت استفاده شده است نتایج بهتری را تولید می نماید . این موضوع بدلیل این است که این اتوماتای از تجربیات گذشته خود برای تصمیم گیری های آینده استفاده می کند . کمترین خطای برای عمق ۲ بدست آمده است . افزایش عمق به بیش از ۲ تاثیر چندانی روی دقت نداشته است . نتایج شبیه سازی با روش یادگیری L2 نیز در جدول (۲) آمده است .

مثال دوم: در این مثال یک تابع تفاضلی با ورودی سینوسی که در زیر آمده است تقریب زده میشود .

$$y_p(k+1) = f[y_p(k), y_p(k-1)] + u(k)$$

$$f[y_p(p), y_p(k-1)] =$$

$$(y_p(k)y_p(k-1)[y_p(k) + 25]) / (1 + y_p^2(k) + y_p^2(k-1))$$

$$u(k) = \sin(2\pi k / 25)$$

ورودی از یکصد نقطه که به صورت یکنواخت در فاصله [۰، ۱۰۰] ایجاد شده تشکیل شده است . ورودی و خروجی اولیه در شکل (۵) نمایش داده شده است . شبیه سازی هم بوسیله اتوماتای یادگیر با ساختار متغیر و هم بوسیله اتوماتای یادگیر با ساختار ثابت با شرایط مثال قبل انجام شده است . میانگین مربع خطای متوسط پس از ۱۵ بار اجرا و به ازای مقادیر مختلف a و b در جدول (۳) و میانگین مربع خطای به ازای مقادیر مختلف عمق در جدول

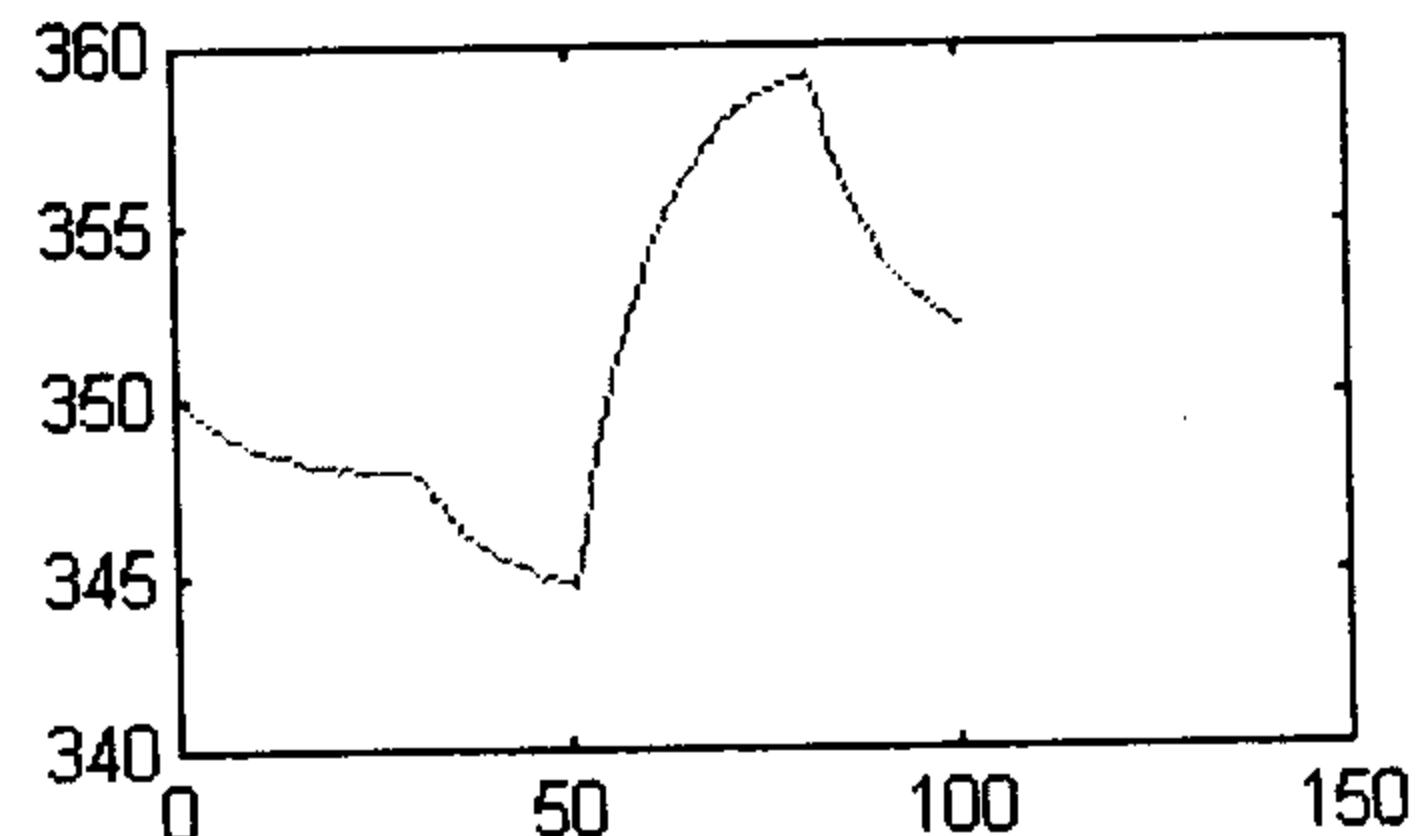
شبیه سازی برای الگوریتم ۱ : اتوماتا دارای یکصد اقدام متفاوت در فاصله [۰، ۲۰] با طول گام ۰.۲ می باشد احتمال انتخاب هر کدام از این اقدامها در ابتدا مساوی و برابر ۱/۰ می باشد . مقدار خطای متوسط پس از ۱۵ بار اجرا و به ازای مقادیر مختلف a و b در جدول (۱) و یک نمونه از تقریب در شکل (۴) نشان داده شده است . با توجه به مقادیر بدست آمده در جدول (۱) کمترین میانگین مربع خطای برای اتوماتای متغیر با مقادیر  $a = 0.5, b = 0.5$  حاصل شده است .

INPUT



(a)

OUTPUT



(b)

شکل ۳ :

(a) ورودی CSTR (b) خروجی CSTR

جدول ۱ : مقادیر متوسط خطای الگوریتم ۱ به ازای مقادیر مختلف a و b .

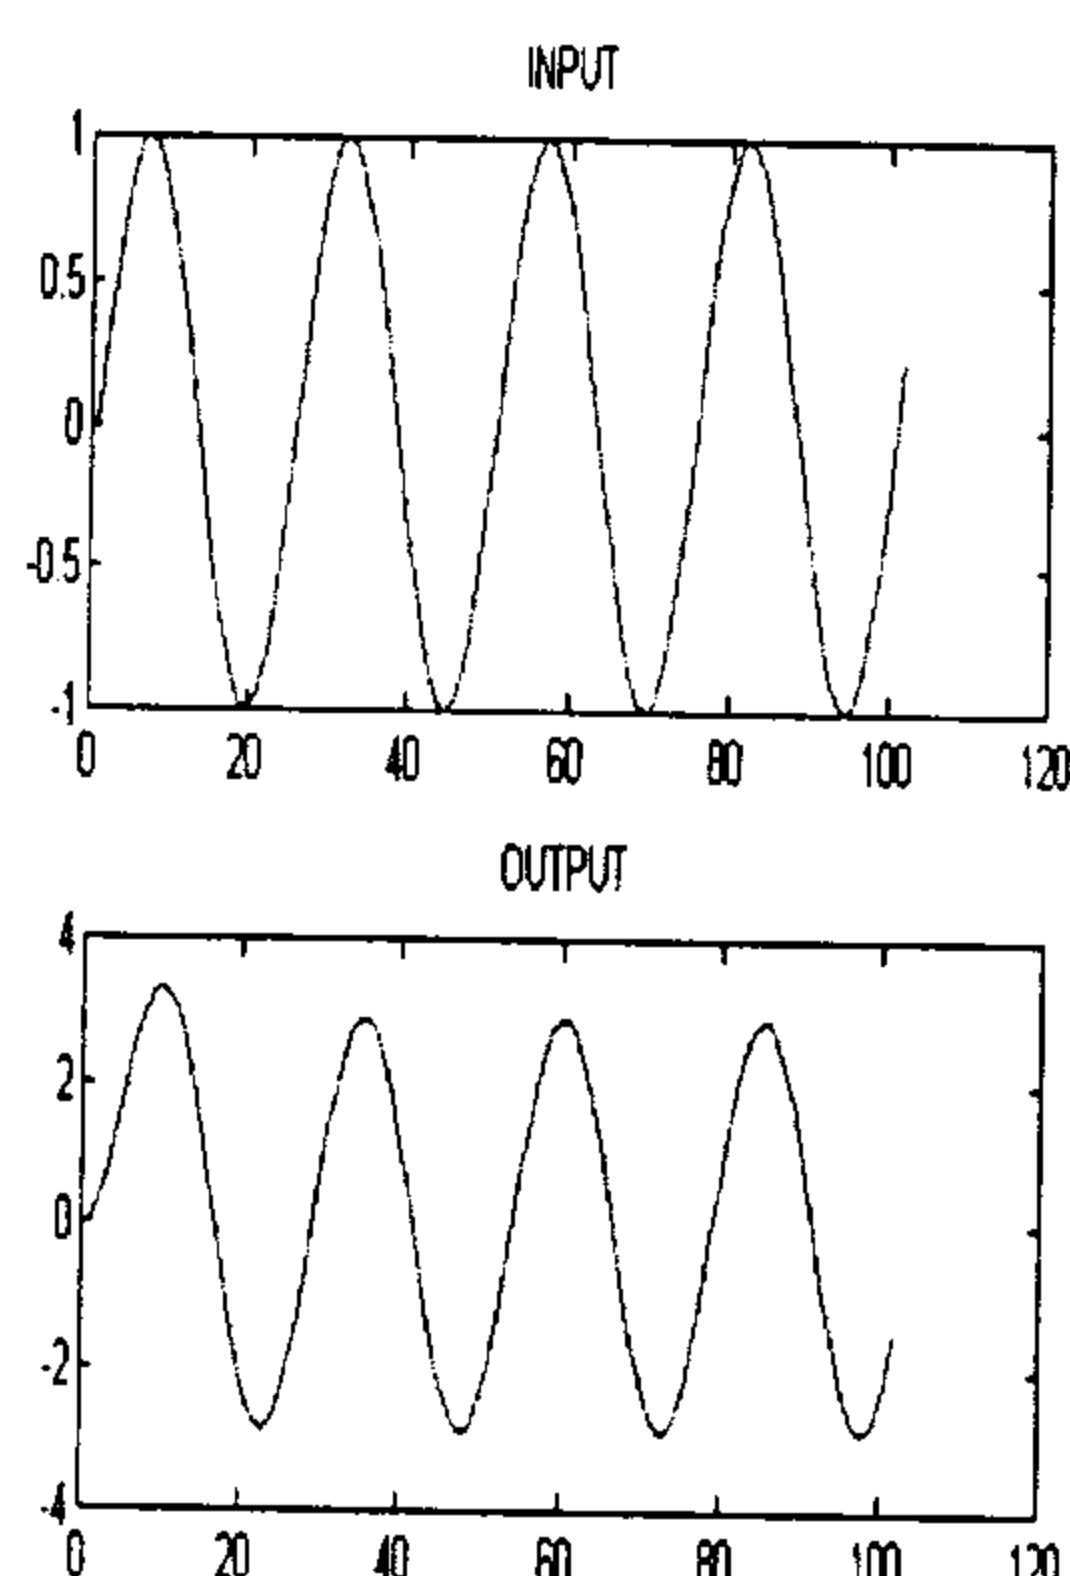
پارامتر	دقت تقریب	-۲	-۱	.
$a = 0.9, b = 0.1$	۰.۰۷۷۱	۰.۰۸۴۵۱	۰.۰۹۸۱۱	
$a = 0.8, b = 0.$	۰.۰۳۷۴۴	۰.۰۶۲۵۵	۰.۱۴۷۱	
$a = 0.7, b = 0.9$	۰.۰۳۱۰۱	۰.۰۷۴۱	۰.۱۳۳۵	
$a = 0.7, b = 0.1$	۰.۰۴۱۳	۰.۰۷۱۲	۰.۱۸۵	
$a = 0.5, b = 0.5$	۰.۰۱۹۵	۰.۰۵۲۵	۰.۱۰۶۵	

جدول ۳: مقادیر متوسط خطای اتوماتای متغیر به ازای مقدار ثابت  $a$  و مقادیر مختلف  $b$ .

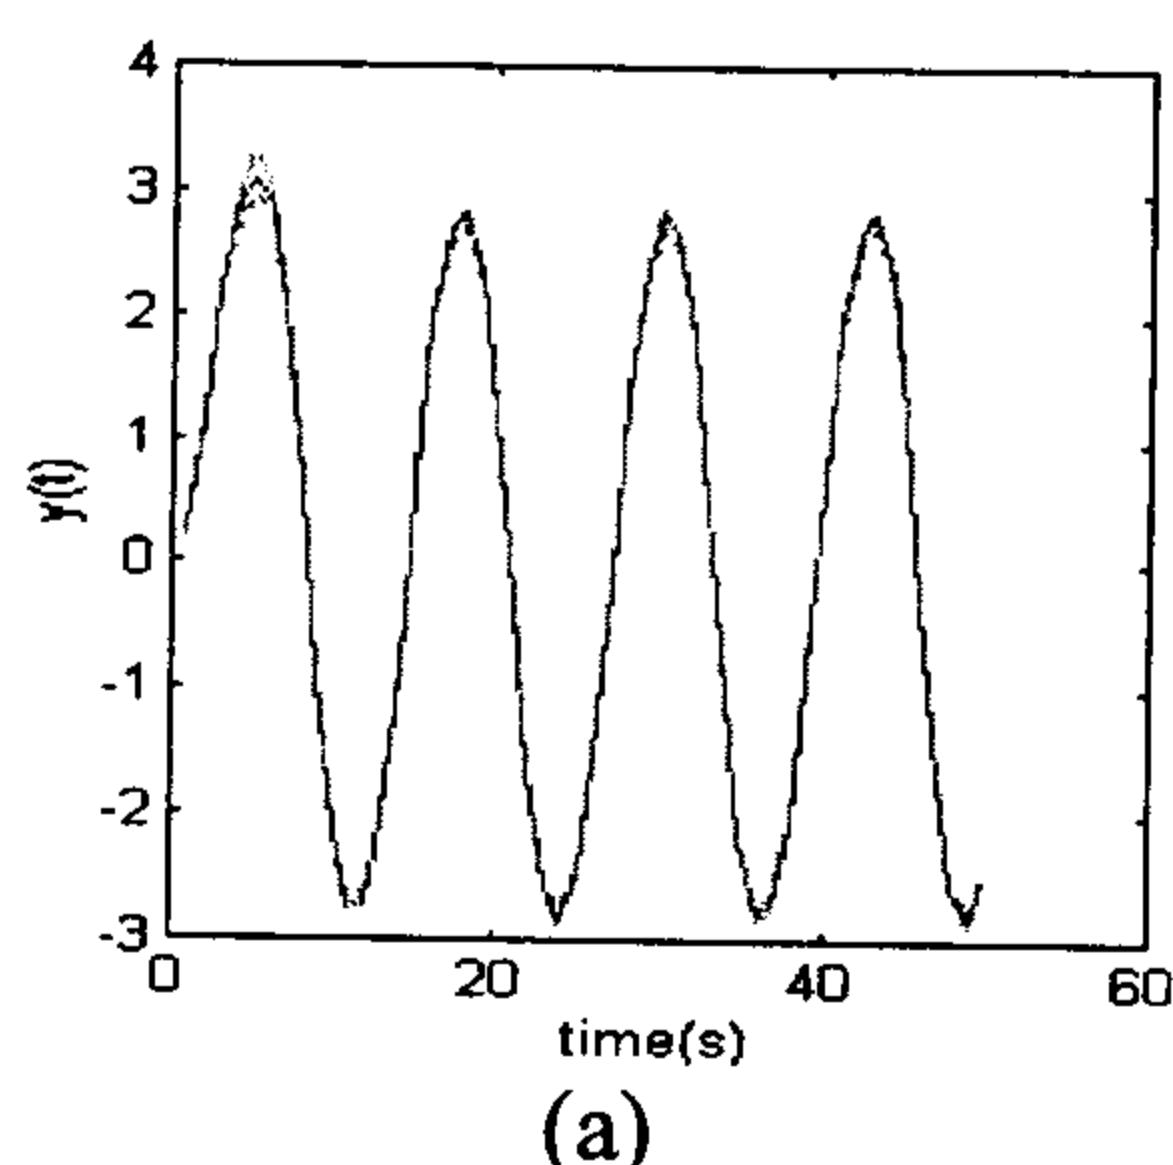
پارامتر	-۱	-۲	دقت تقریب
۰.۰۹۲۱	۰.۰۸۳۲	۰.۰۶۵۷	$a = ۰.۸, b = ۰.۱$
۰.۲۱۴۳	۰.۰۹۸۴۵	۰.۰۸۷۴	$a = ۰.۸, b = ۰.۲$
۰.۱۸۵۴	۰.۰۶۷۲۲	۰.۰۵۳۴	$a = ۰.۸, b = ۰.۳$
۰.۱۷۴۵	۰.۰۵۴۷۱	۰.۰۴۹۸	$a = ۰.۸, b = ۰.۴$
۰.۶۴۸۵	۰.۰۵۶۳	۰.۰۴۷۲	$a = ۰.۸, b = ۰.۶$
۰.۱۴۳۵	۰.۰۳۲۴	۰.۰۲۱۶	$a = ۰.۸, b = ۰.۸$

جدول ۴: مقادیر متوسط خطای الگوریتم‌های ۲ و ۳.

الگوریتم	-۱	-۲	دقت تقریب
الگوریتم ۳	۰.۱۹۲۲	۰.۱۶۴۴	۰.۰۹۸۴۱
الگوریتم ۲ با عمق ۱	۰.۱۰۲۲	۰.۰۶۷۳۸	۰.۰۲۷۸۳
الگوریتم ۲ با عمق ۲	۰.۰۶۷۸	۰.۰۲۶۶۹	۰.۰۱۴۷
الگوریتم ۲ با عمق ۳	۰.۰۸۷۲۲	۰.۰۴۷۳	۰.۰۲۹۸۸
الگوریتم ۲ با عمق ۴	۰.۱۰۰۳۴	۰.۰۵۶۴۳	۰.۰۳۲۹
روش یادگیری L2	۰.۰۹۸۴	۰.۰۰۰۲۳۴	۰.۰۰۰۱۱

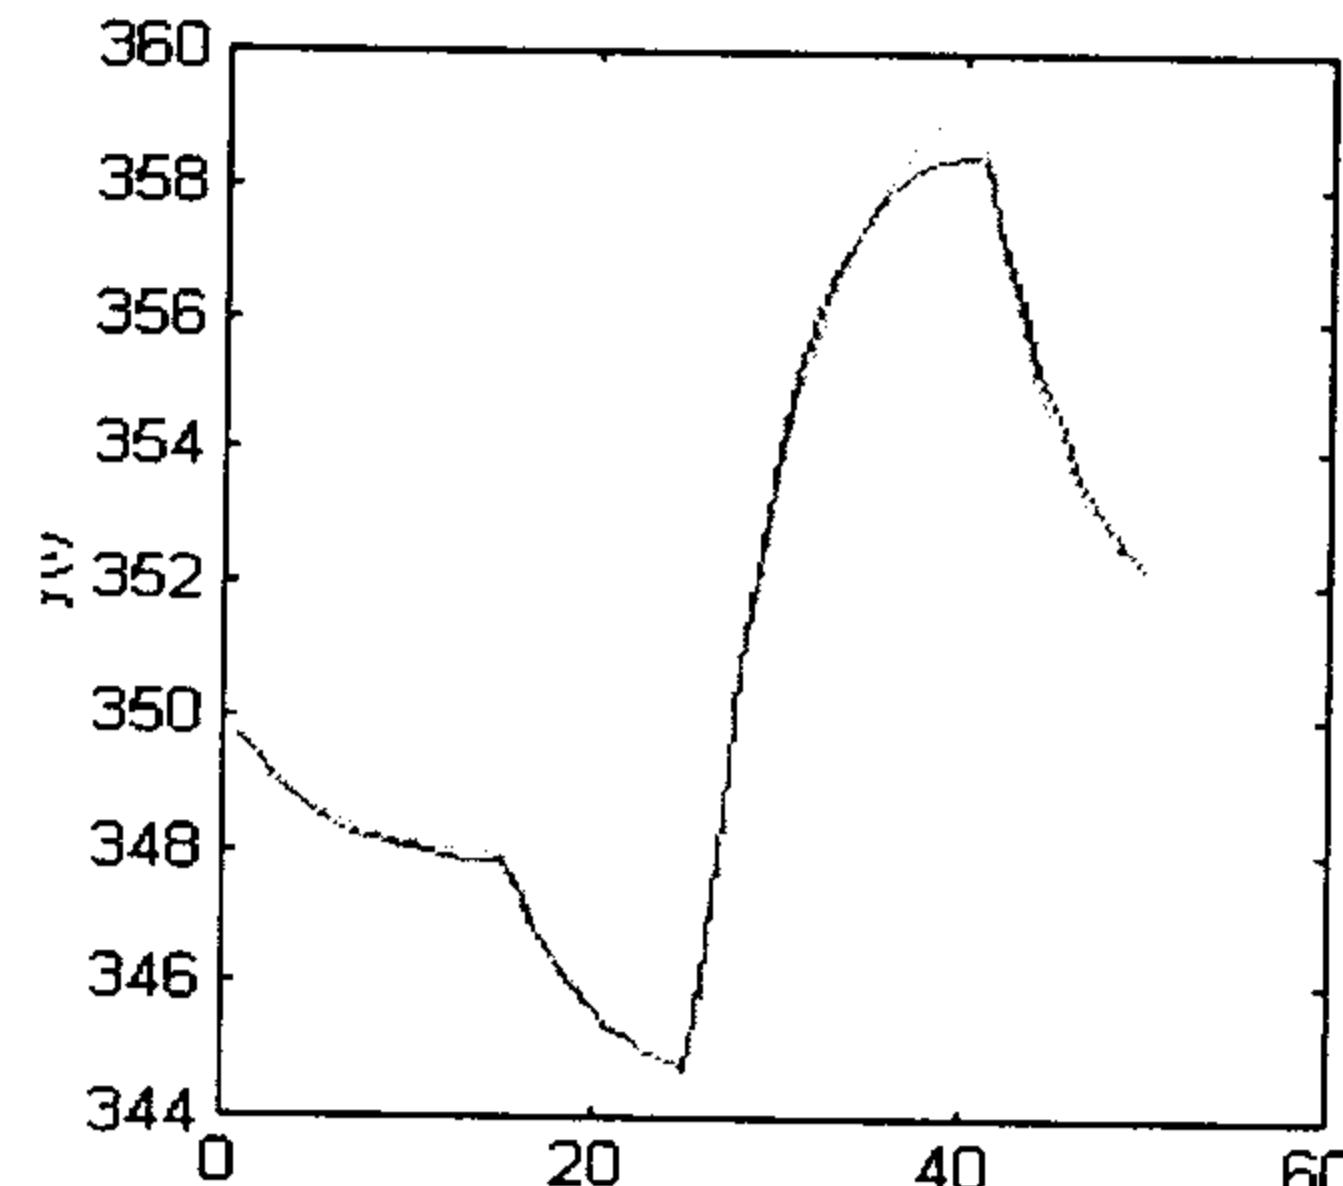


شکل ۵: ورودی خروجی تابع تفاضلی.

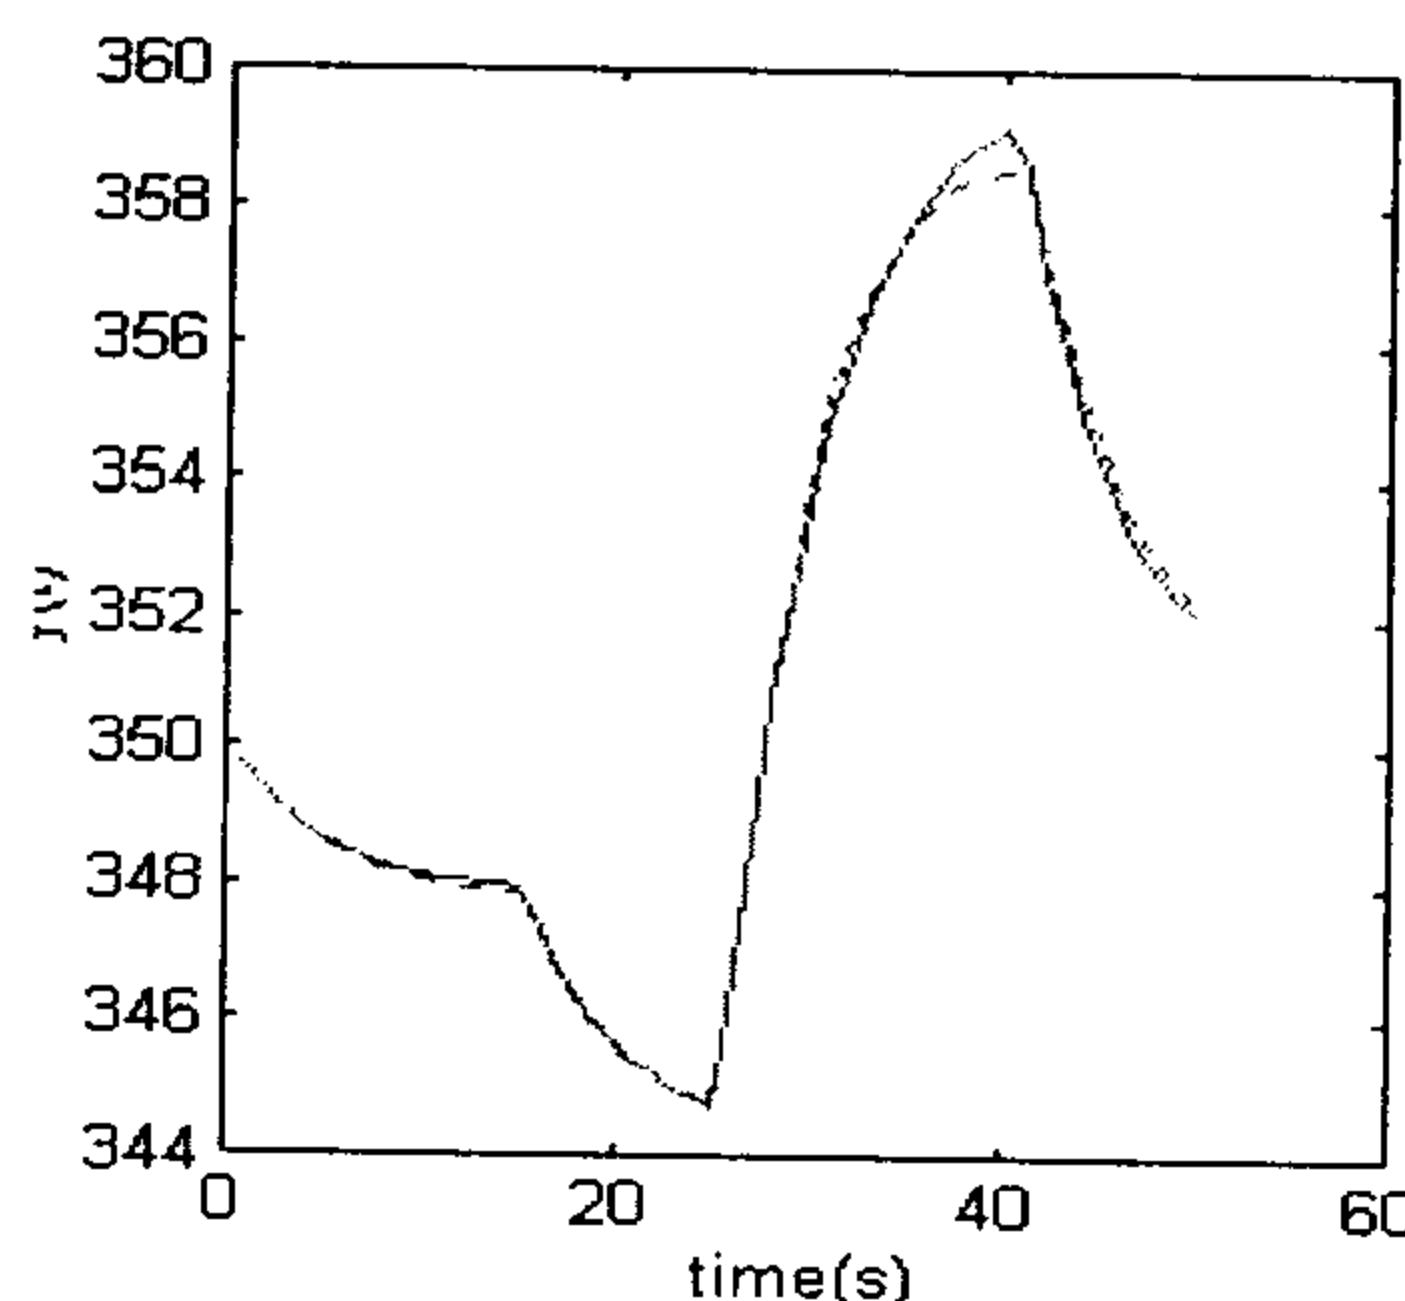


(a)

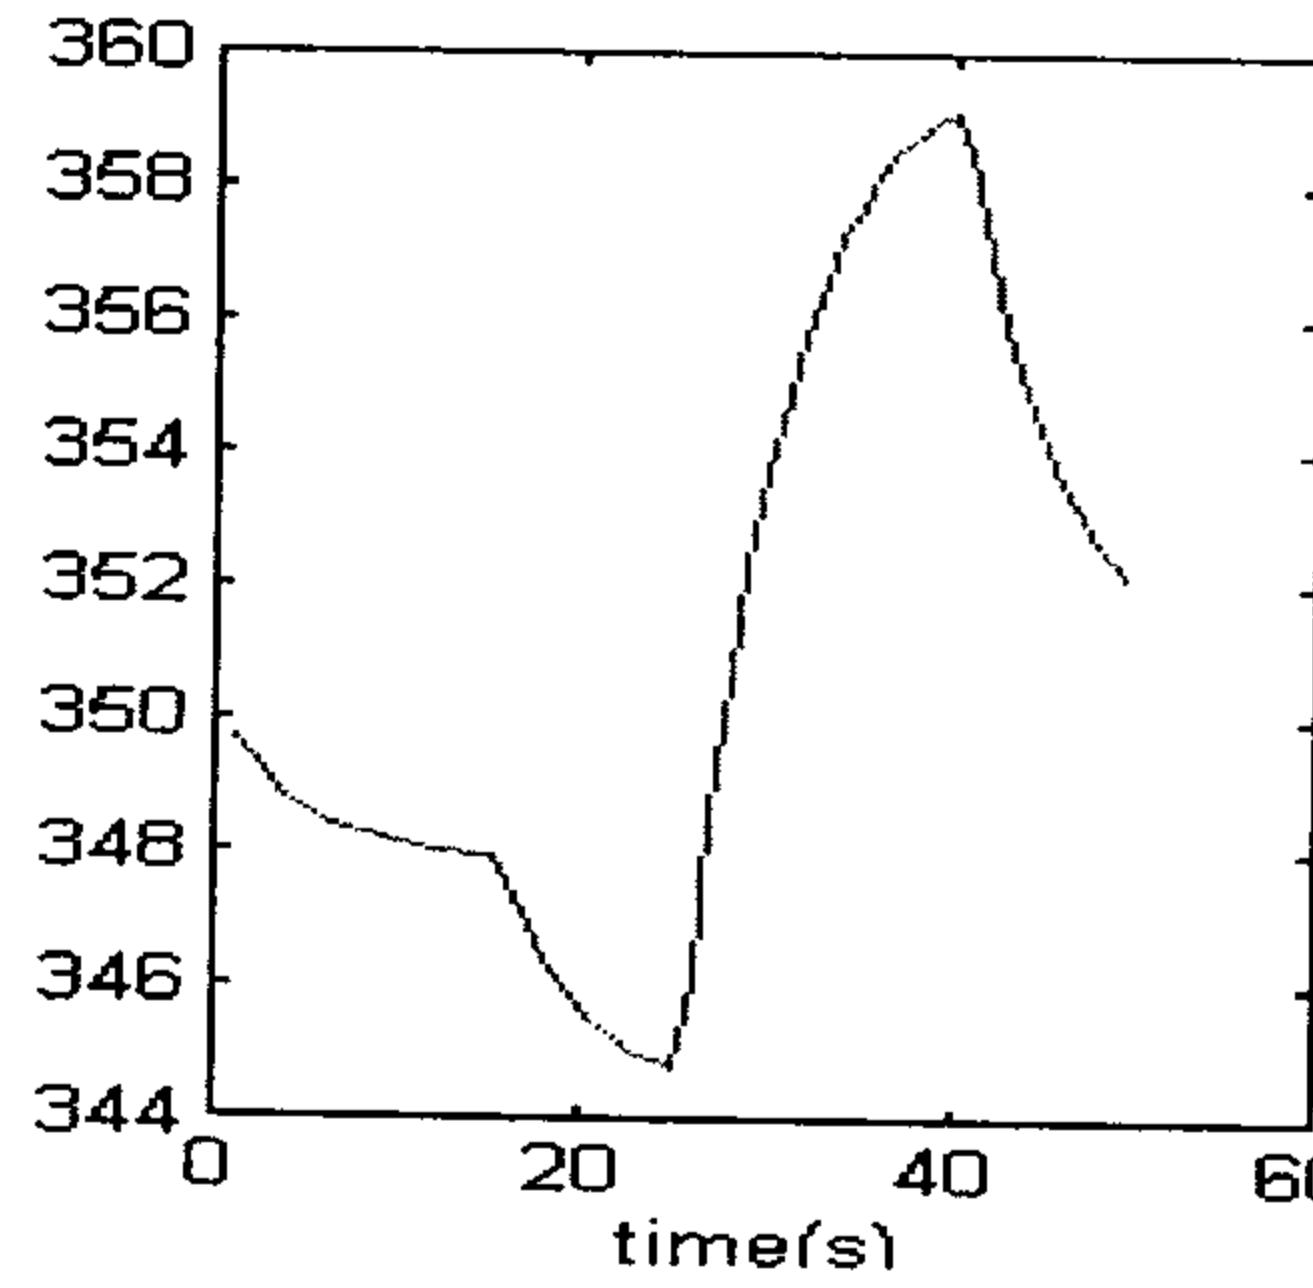
(۴) و یک نمونه از تقریب در شکل (۶) نشان داده شده است.



(a)



(b)



(c)

شکل ۶:

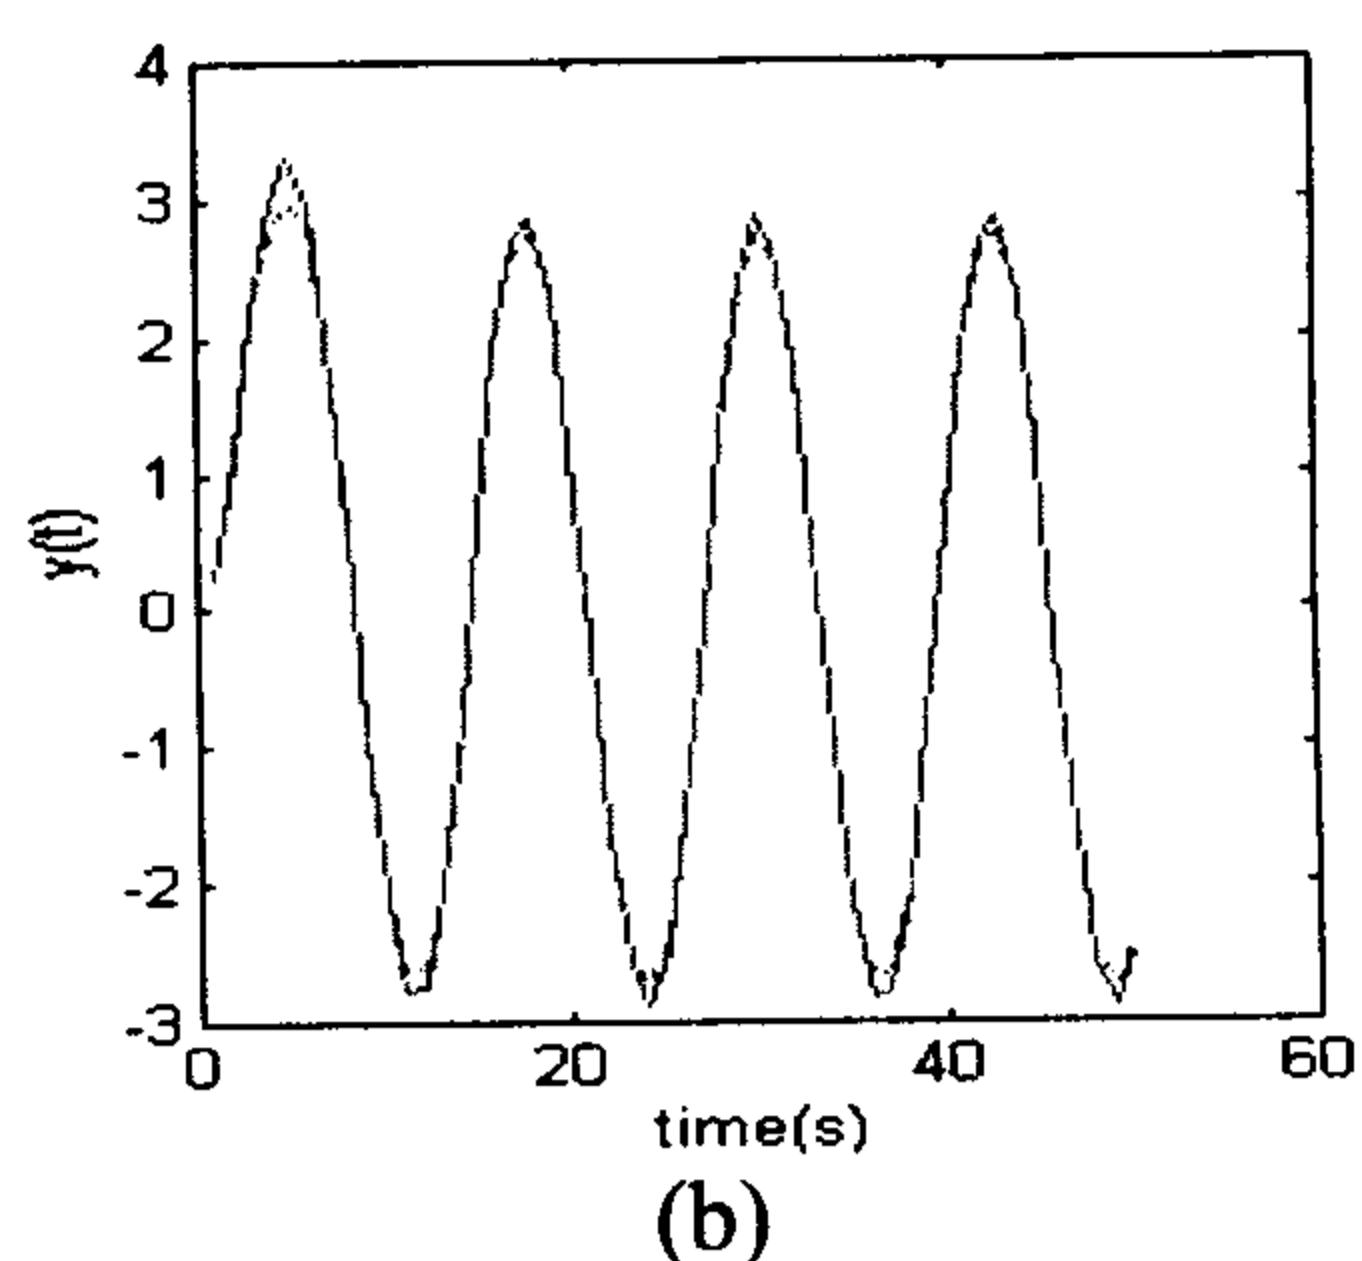
- (a) : تقریب با دقت ۱

- (b) : تقریب با دقت ۲

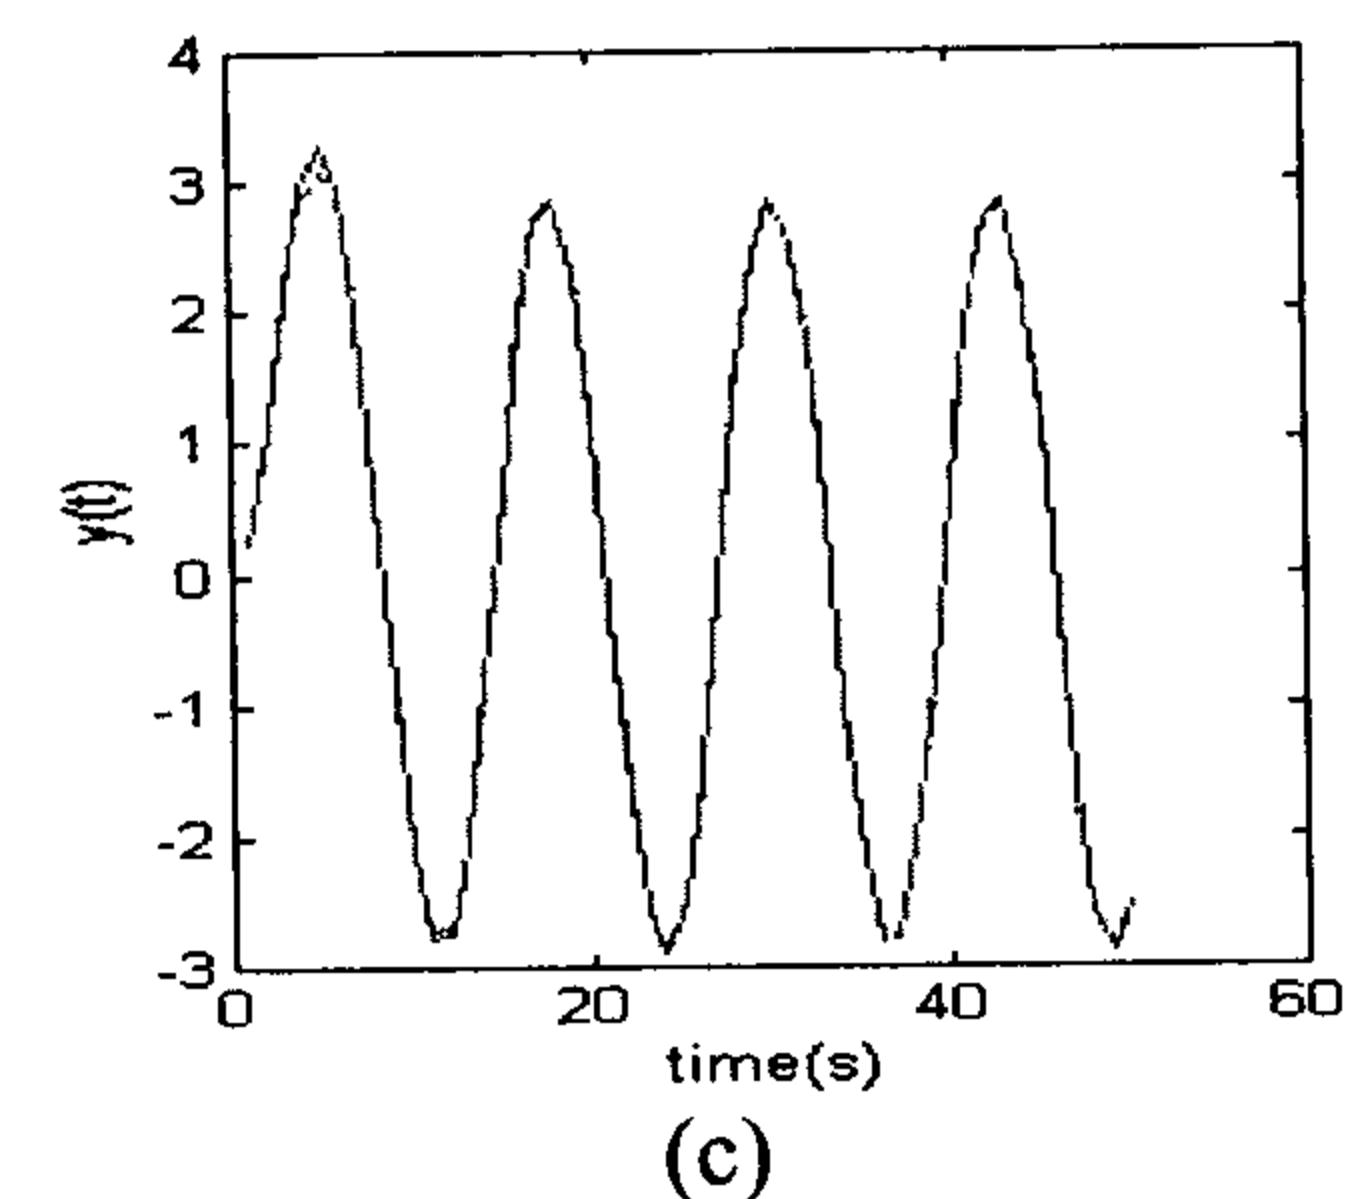
- (c) : تقریب با دقت ۳

خط پیوسته تابع اصلی خط (-) تابع تقریب

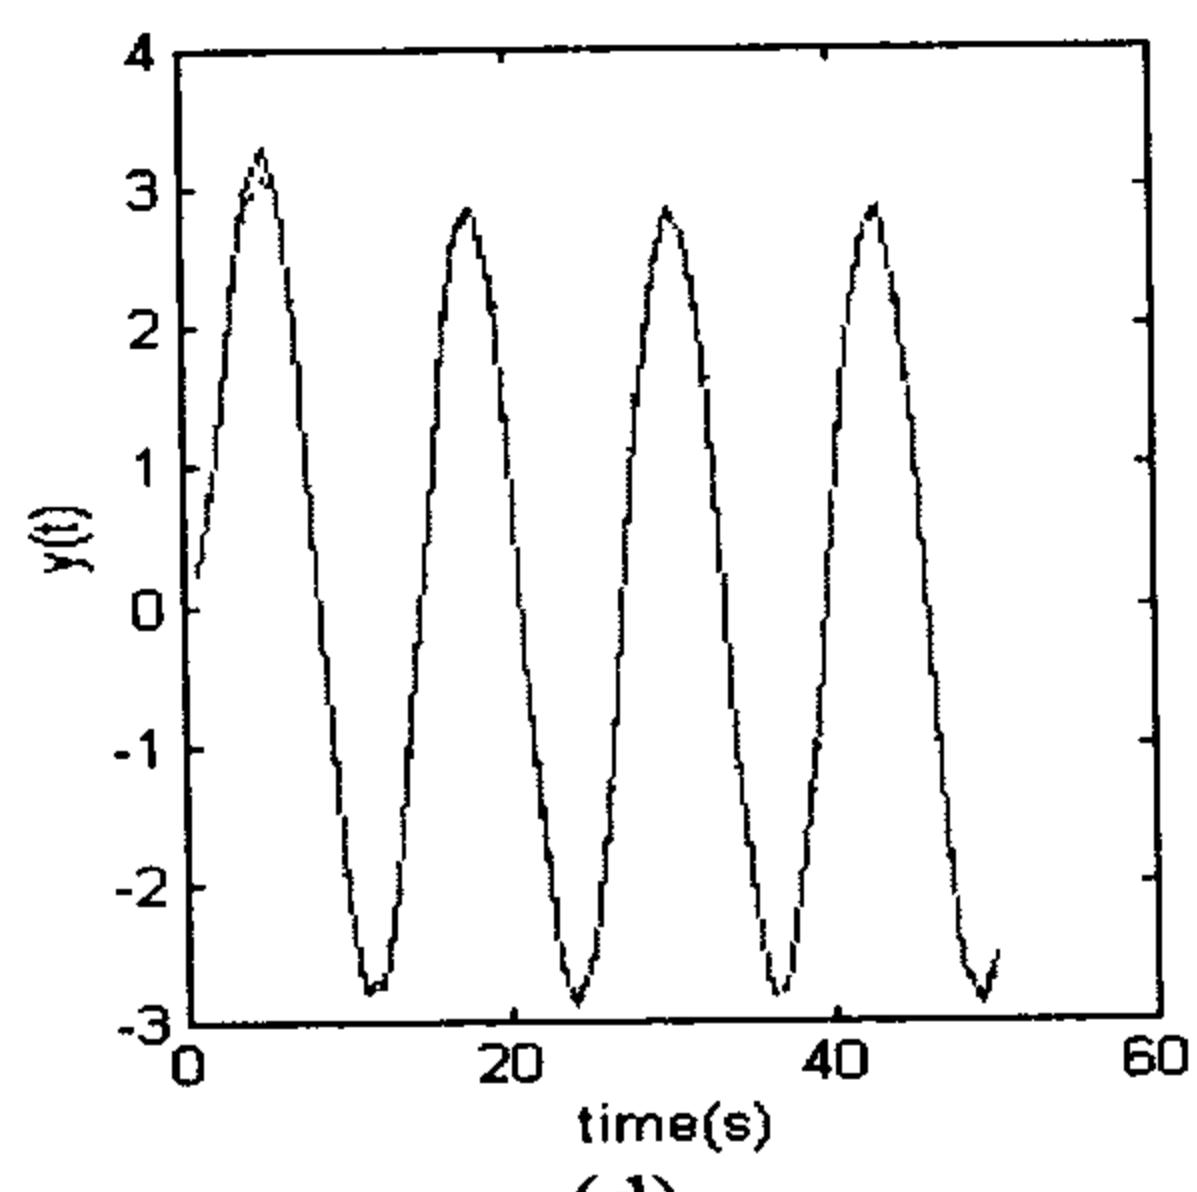
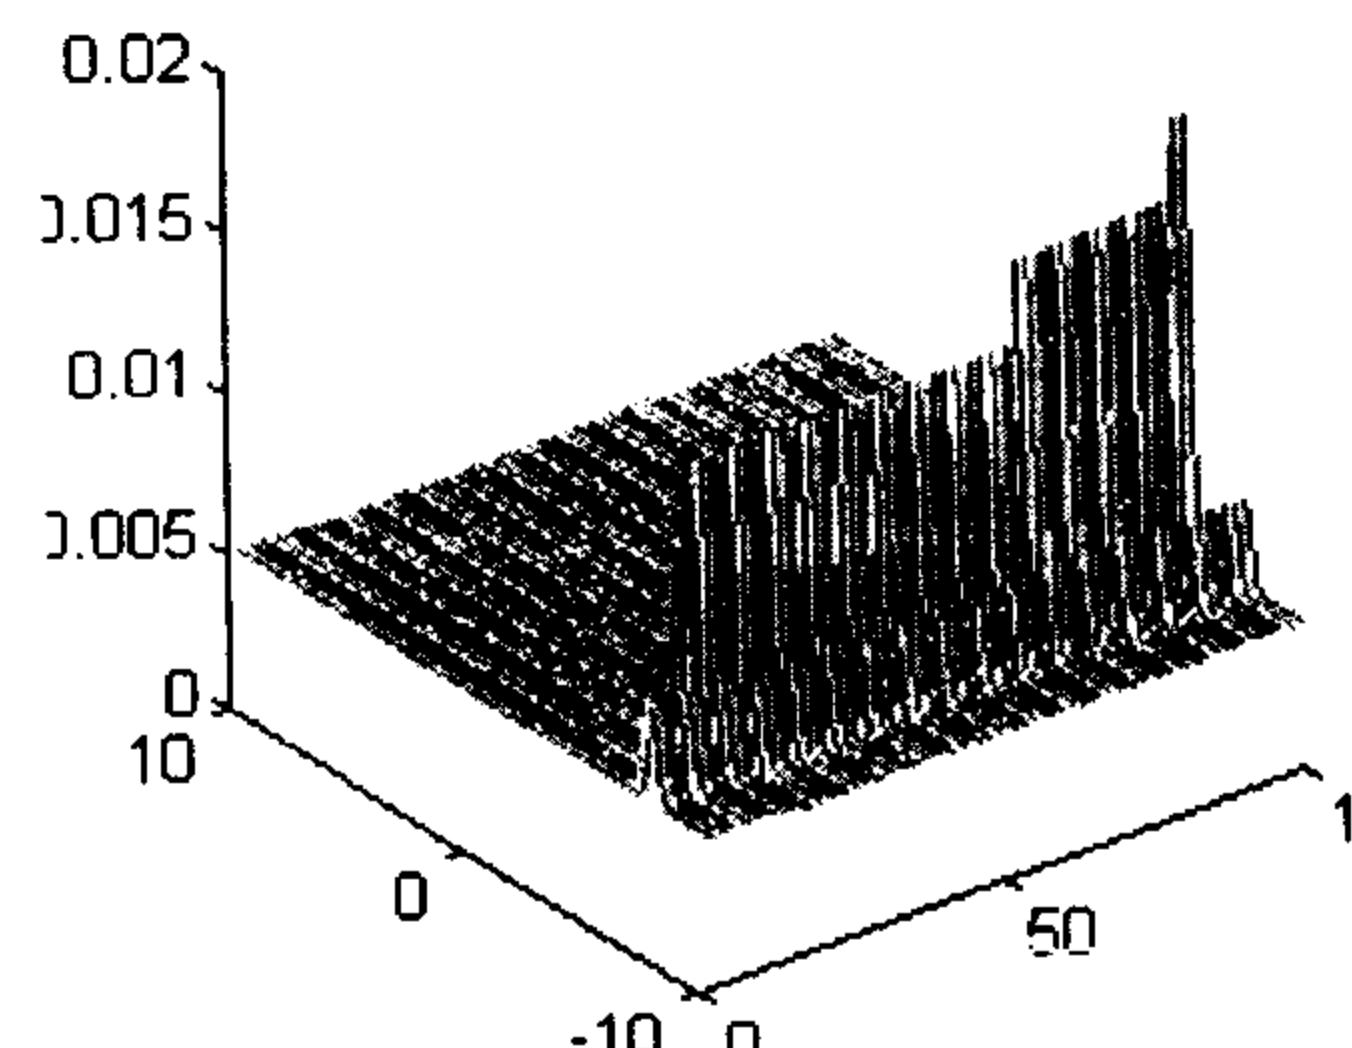
فاصله  $[10, -10]$  نمونه برداری شده استفاده شده است. ۲۰۰ نمونه برای محاسبه تقریب و ۲۰۰ نمونه برای آزمون تقریب تابع به کار برده شده است. شده برای هر سه الگوریتم تابع ویولت به کار برده شده تابع گوسی  $\psi(x) = \text{Exp}(-\frac{1}{2}x^2)$  می باشد. در اتماتای پیوسته برای هر ضریب یک اتماتا با تابع توزیع احتمال پیوسته به کار برده شده است. چگونگی عملکرد این اتماتا به این ترتیب است که تابع توزیع احتمال در همسایگی بهترین اقدام به سمت ماکزیمم خود میل می کند. همانگونه که در شکل (۷) نشان داده شده است بهترین مقادیر بدست آمده برای دو ضریب اول به سمت  $-0.195$  و  $0.192$  میل می کند که مقدار واقعی آنها  $-0.192$  و  $0.195$  می باشد. به منظور مقایسه چهار پارامتر اول بدست آمده با الگوریتمهای مختلف در جدول (۵) و یک نمونه از تقریب در شکل (۸) و مقادیر متوسط خطای تقریب در جدول (۶) نشان داده شده است.



(b)

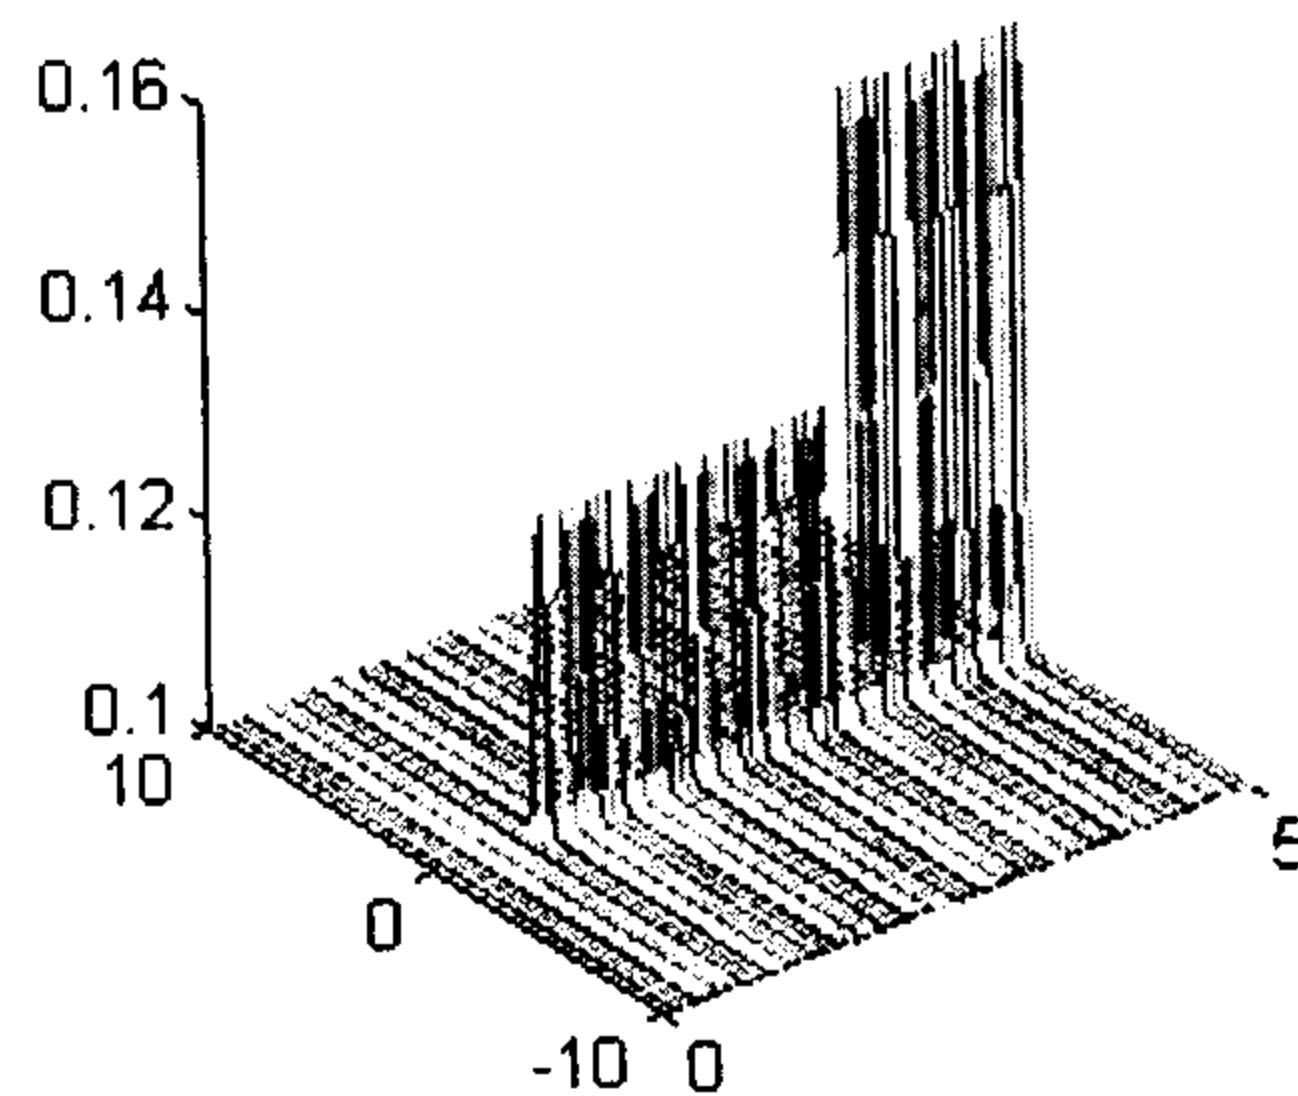


(c)



شکل ۶:

- (a): تقریب با دقت ۰ (b): تقریب با دقت ۱
- (c): تقریب با دقت ۲ - (d) تقریب با دقت ۳
- خط پیوسته تابع اصلی خط (-) تابع تقریب.

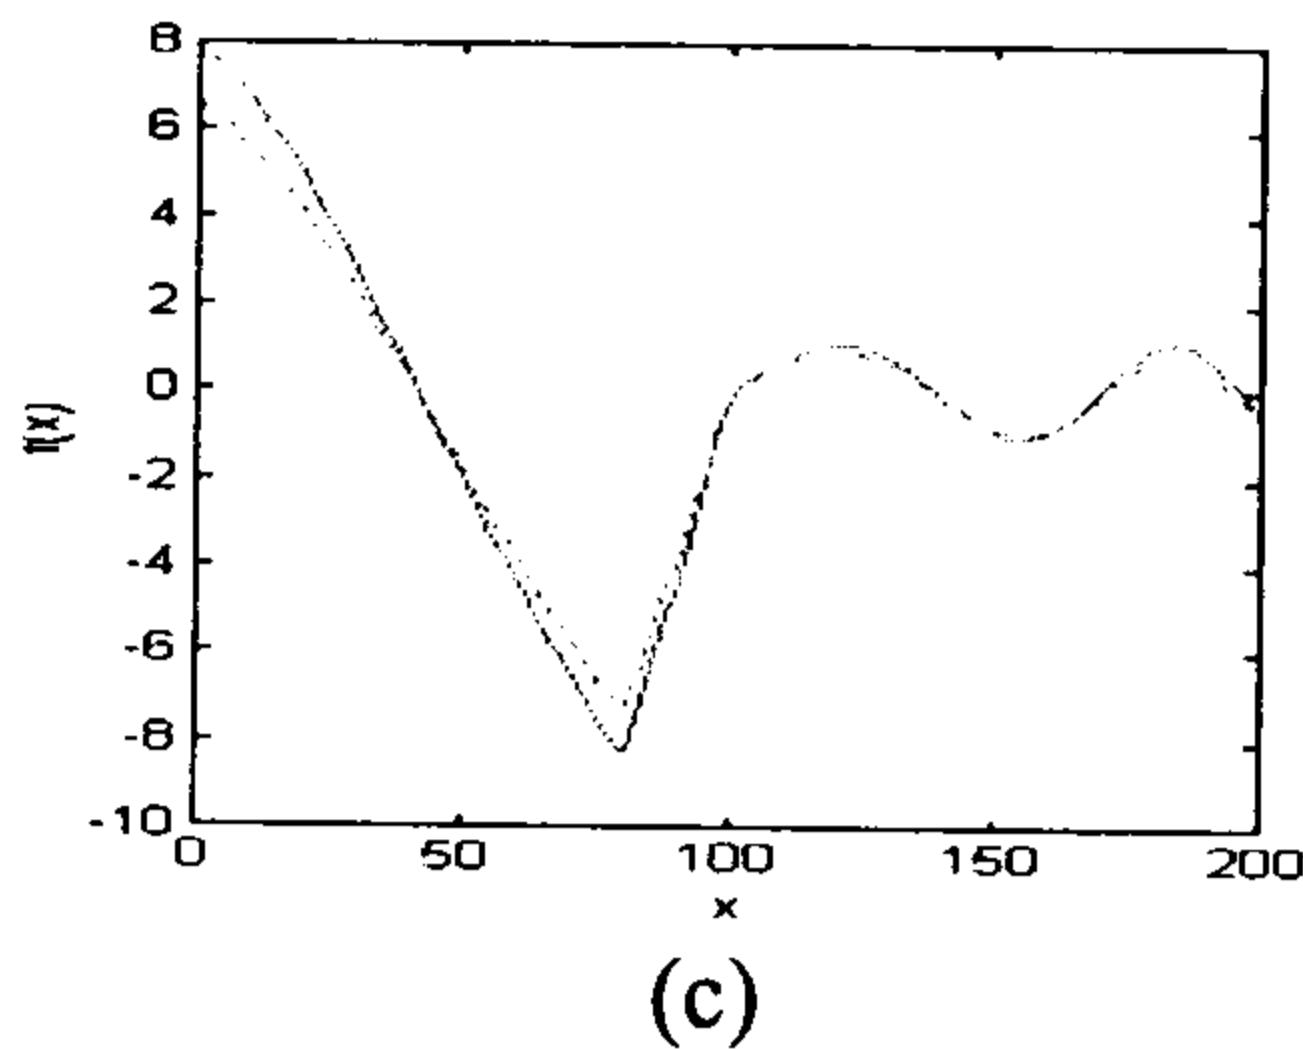


مثال سوم: در این مثال تابع زیر با استفاده از سه الگوریتم ۱ و ۳ و الگوریتم آموزش نزول در امتداد گرادیان تقریب زده شده است.

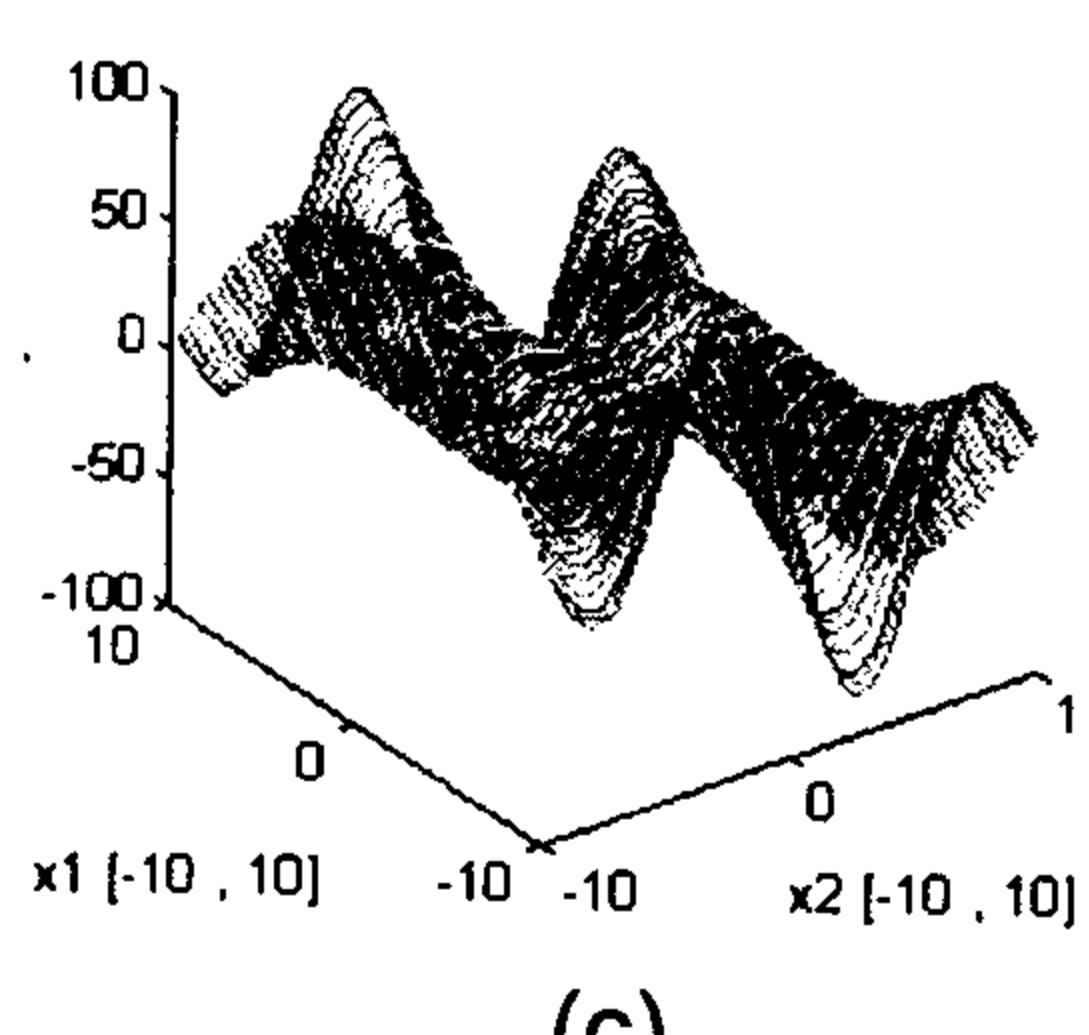
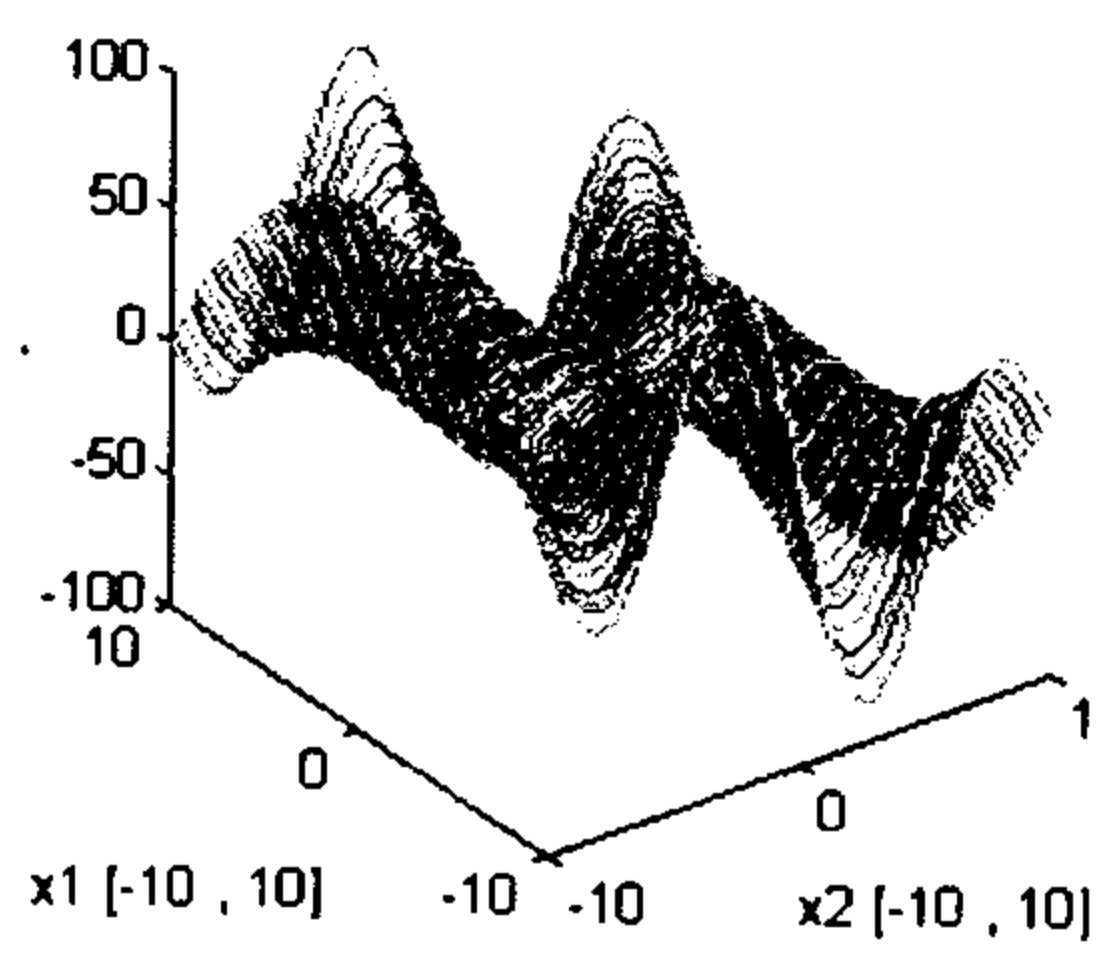
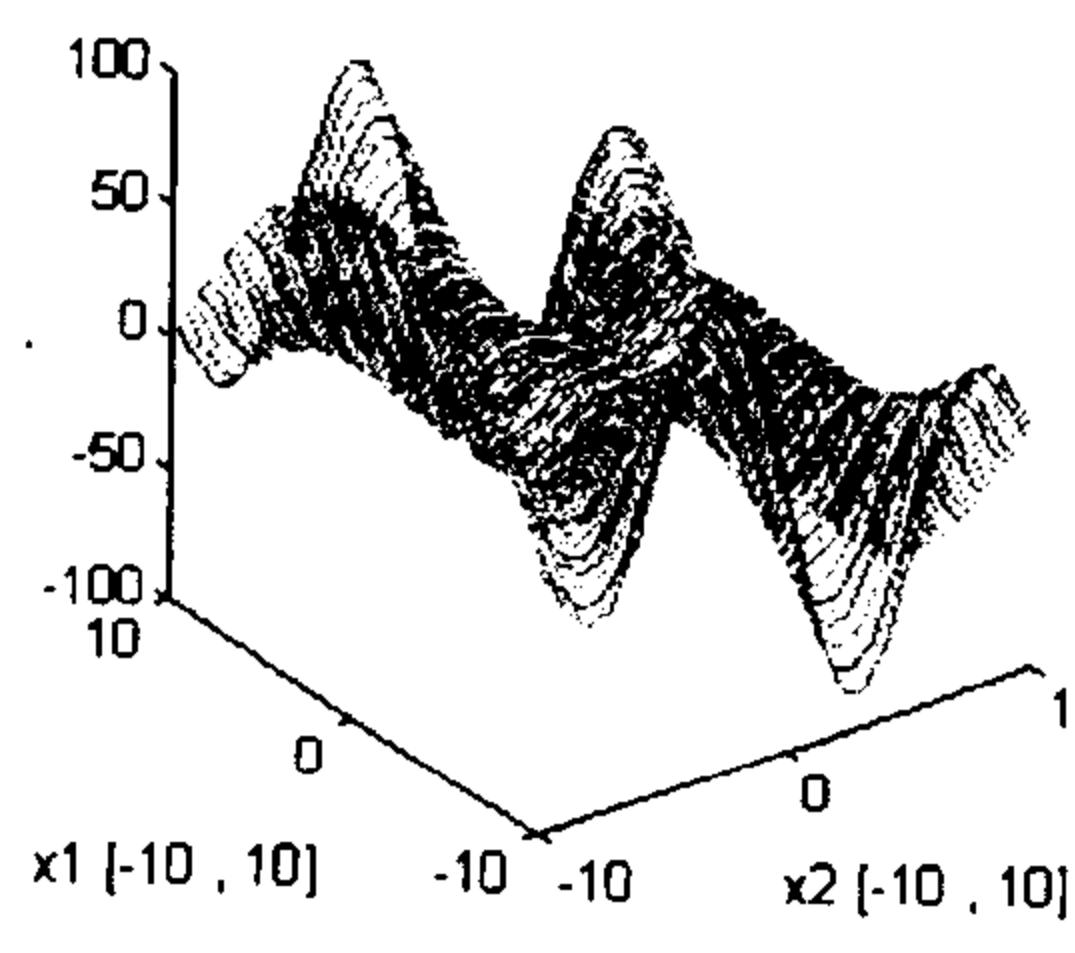
$$F(x) = \begin{cases} -2.186x - 12.864 & -10 \leq x < -2 \\ 4.246x & -2 \leq x < 0 \\ \sin((0.03x + 0.7)x) & 0 \leq x < 10 \end{cases}$$

شکل ۷: تابع توزیع احتمال بر اساس تعداد دفعات تکرار.

برای تقریب تابع از ۴۰۰ نمونه که به صورت یکنواخت در



شکل ۸: (a): تقریب تابع با استفاده الگوریتم ۳ (b): تقریب تابع توسط شبکه عصبی (c): تقریب تابع با استفاده الگوریتم ۱ خط پیوسته تابع اصلی خط (-) تابع تقریب.



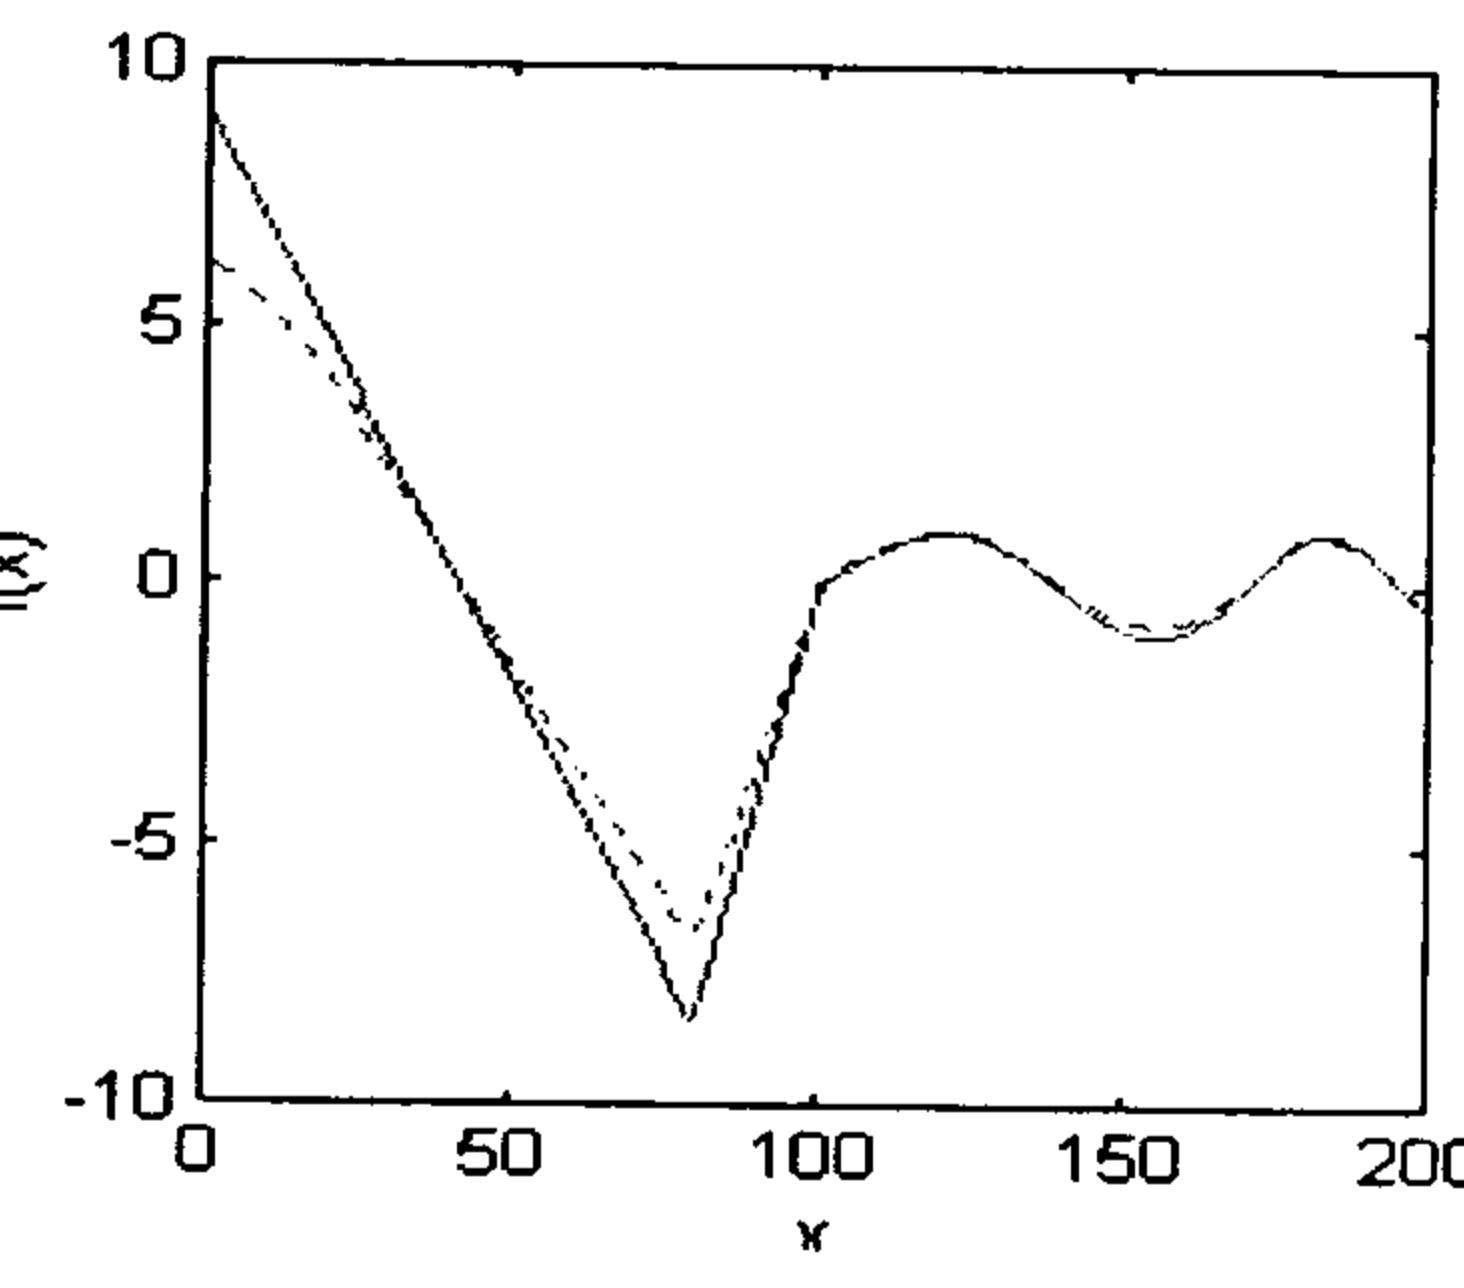
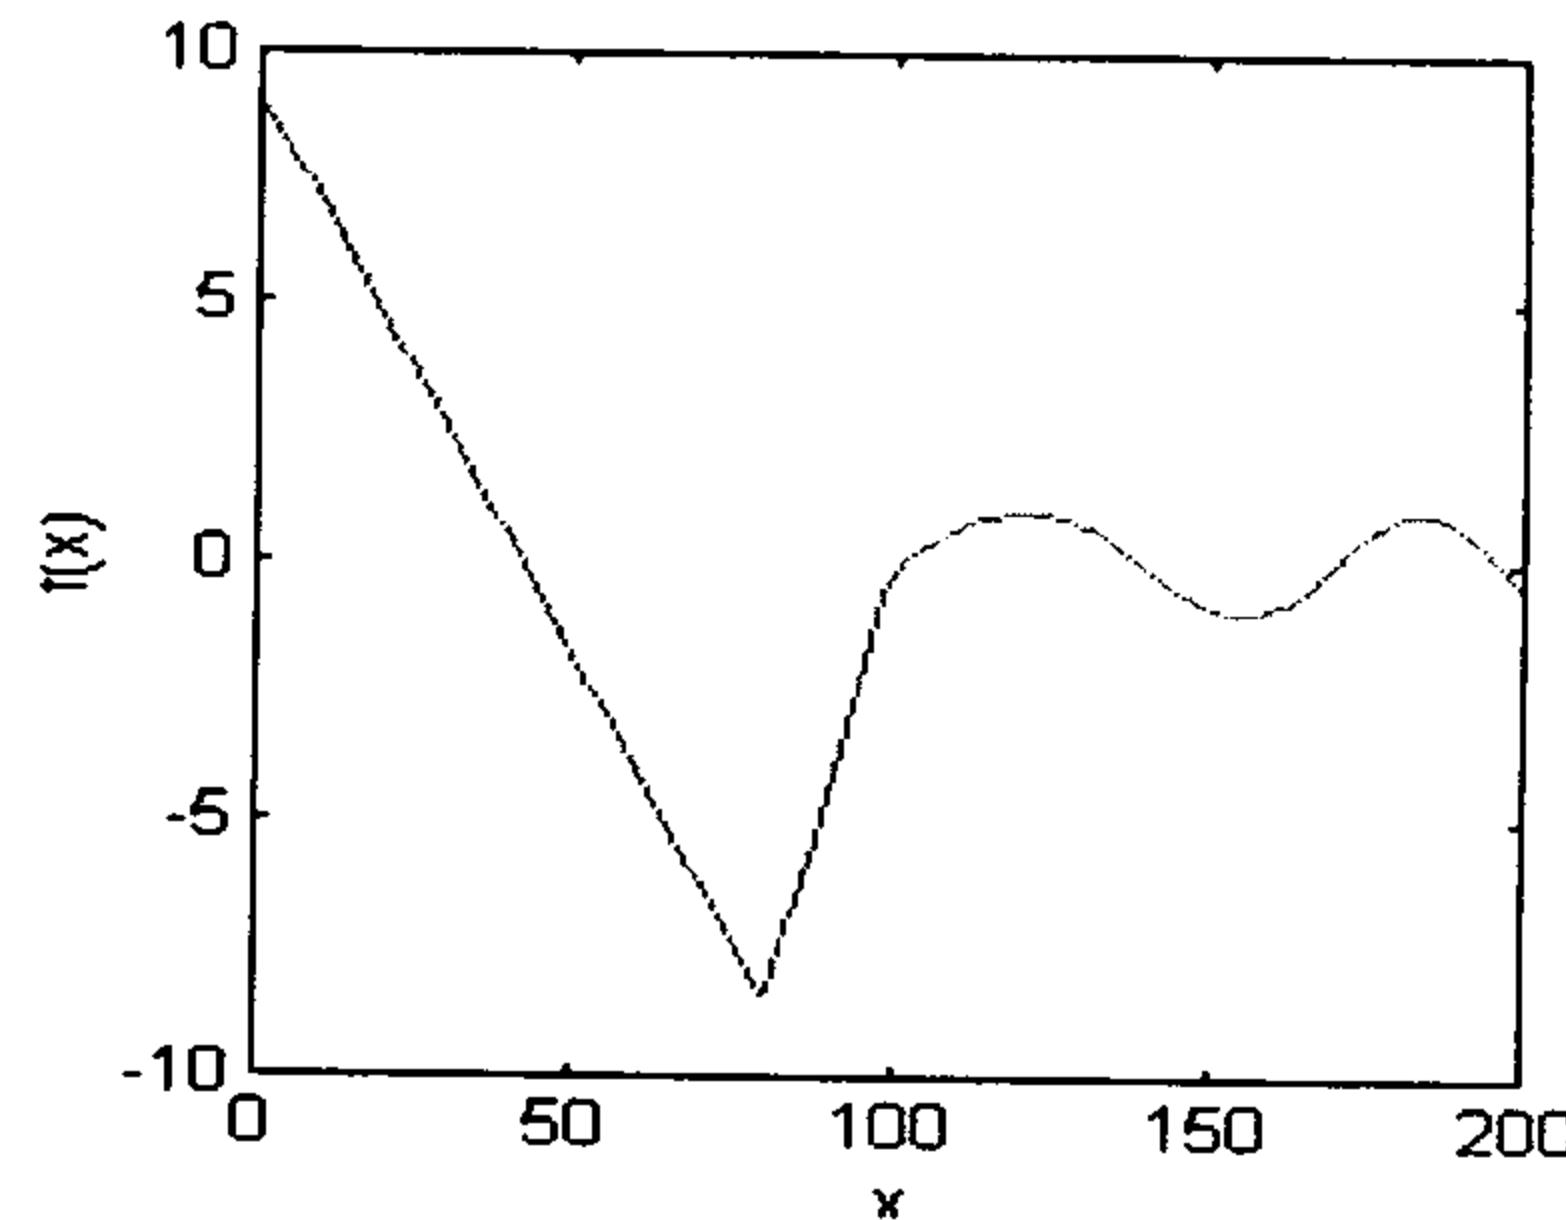
شکل ۹: (a): تابع اصلی (b): تقریب تابع توسط الگوریتم ۳  
(c): تقریب تابع توسط الگوریتم ۱.

جدول ۵: چهار پارامتر اول بدست آمده با الگوریتمهای مختلف.

الگوریتم	شماره پارامترها
الگوریتم ۳	۰۰۰۳۹۷
الگوریتم ۱	۰۰۰۴۶
ویونت	.

جدول ۶: مقادیر متوسط خطای تقریب برای الگوریتمهای مختلف.

الگوریتم	تعداد پارامترها
الگوریتم ۳	۰۰۰۹۳۴
الگوریتم ۱	۰۰۰۶۷۵۱
ویونت	۰.۱۳۲۸

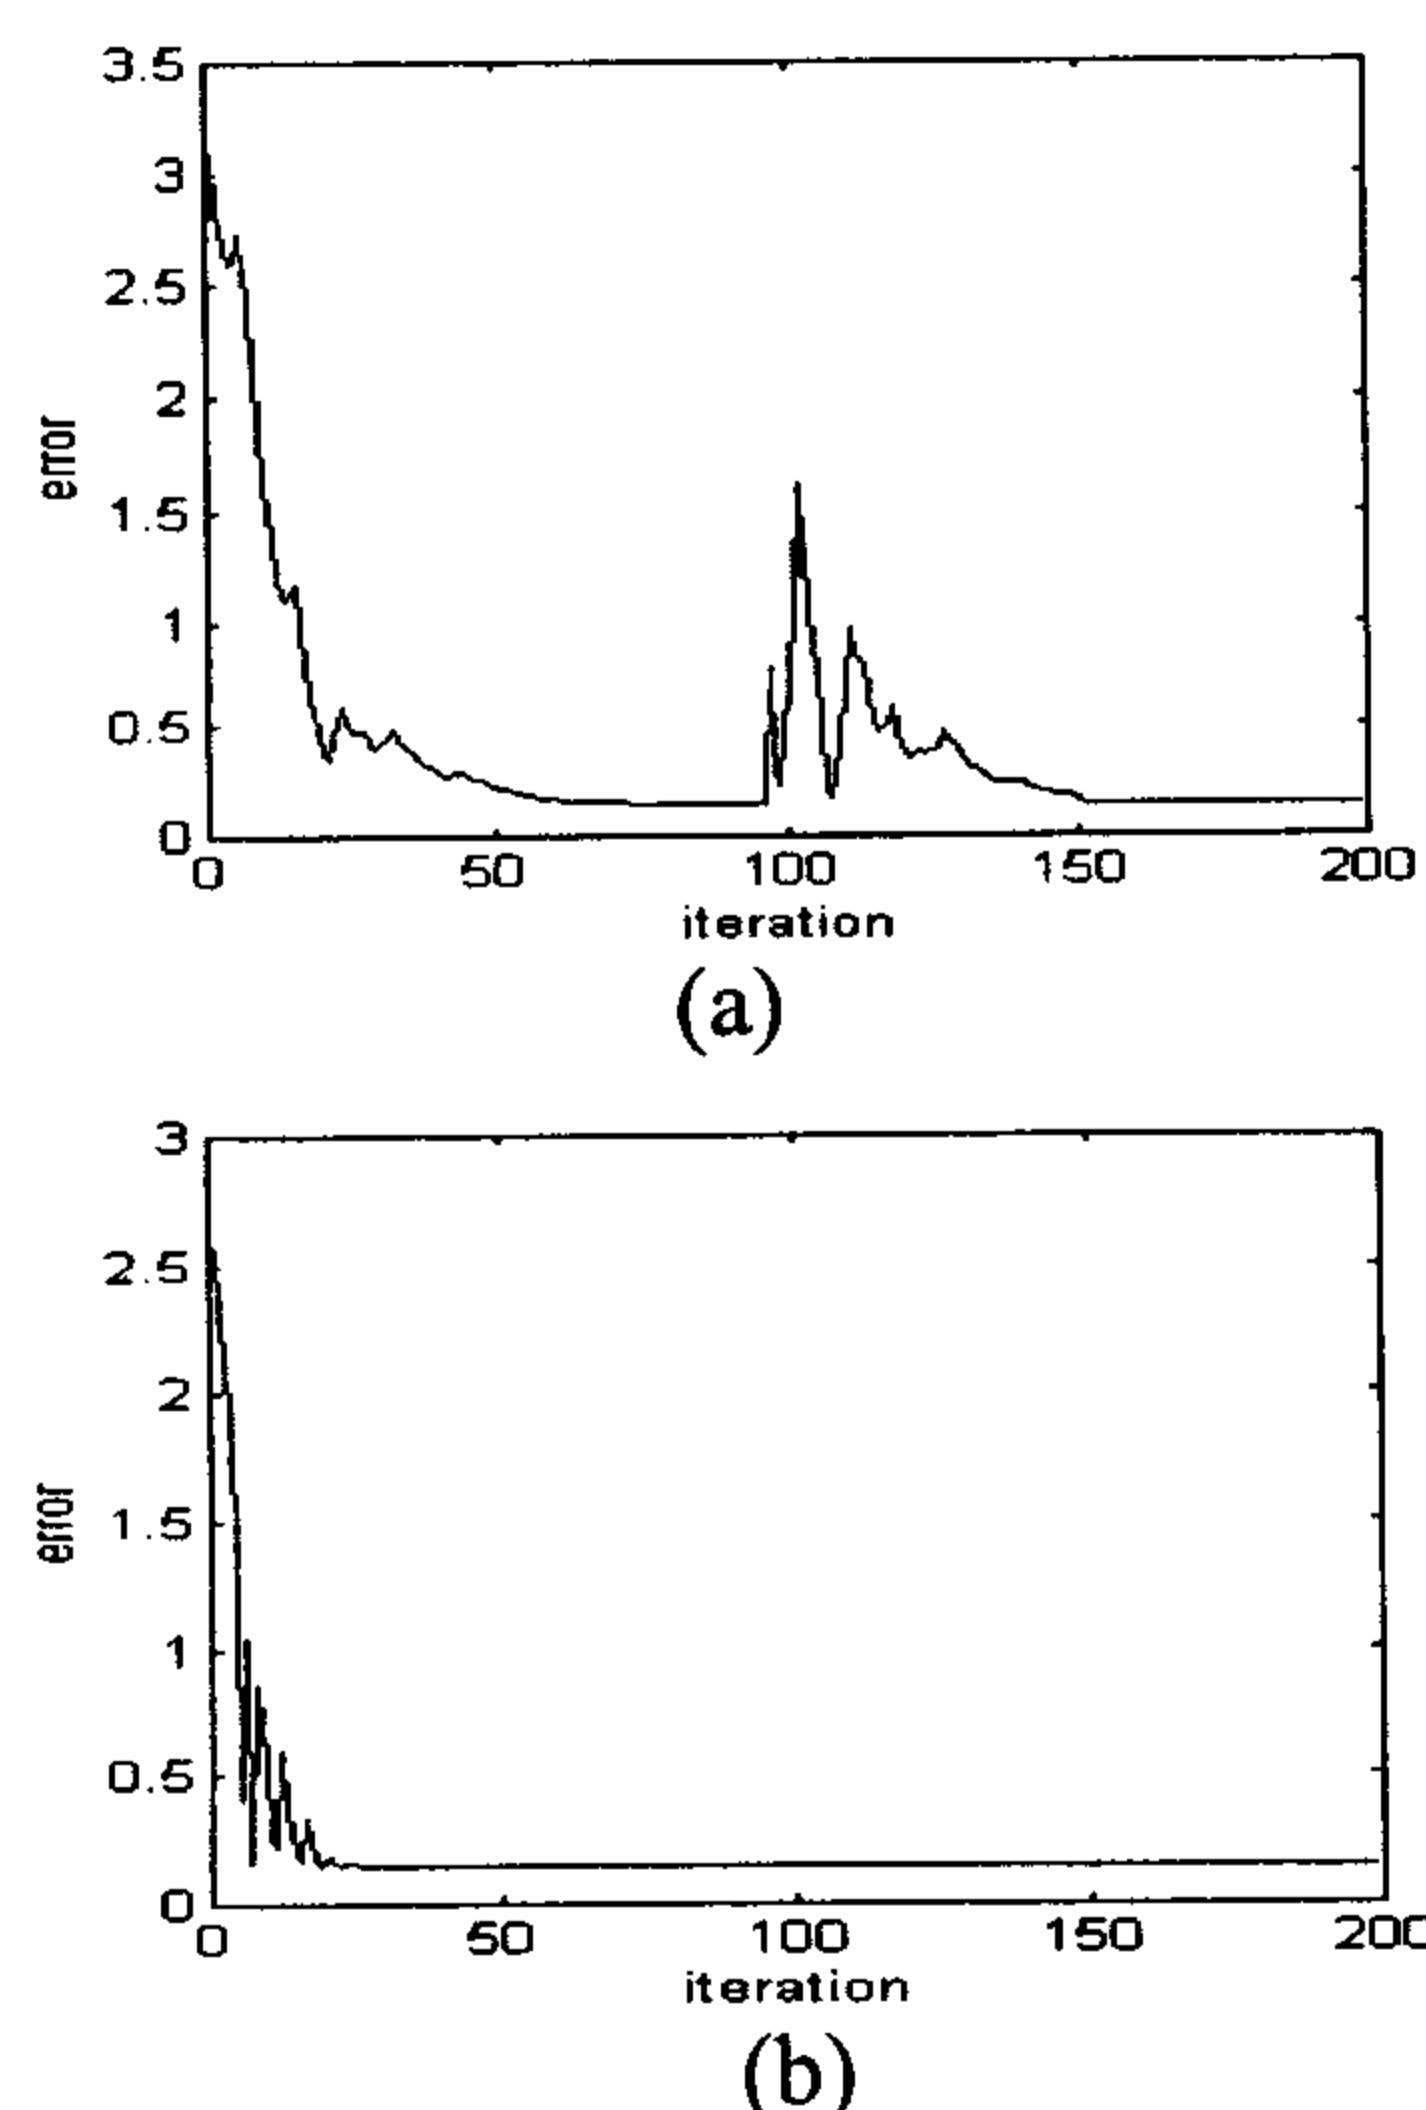


(b)

(b)

الگوریتمها قابل توجه می باشد این است که در هر مرحله میتوان فقط یک ویولت اضافه نمود و آنهایی را که کمکی به بهبود تقریب نمی کنند حذف کرد. بنابر این با حفظ دقت تقریب میتوان تعداد پارامترها یعنی ویولت ها را کاهش داد. به عبارت دیگر الگوریتمهای پیشنهادی بطور اتوماتیک تعداد ویولتهای مورد نیاز را تعیین میکند. نتایج به دست آمده را می توان به صورت زیر خلاصه نمود.

۱ - روشهای پیشنهادی هم در تقریب تابع و هم در پیش بینی تابع در نقاط بین نقاط نمونه برداری شده بهتر از شبکه های عصبی با آموزش در امتداد نزول گرادیان عمل می کنند. ۲ - خطای بدست آمده از اتوماتای پیوسته کمتر از دو اتوماتای دیگر است. ۳ - اتوماتای اتوماتای پیوسته سریعتر همگرا می شود. چگونگی کاهش خطای تقریب با توجه به دفعات تکرار برای الگوریتم ۳ در شکل (۱۰) نشان داده شده است. همانگونه که مشاهده می شود در الگوریتم ۳ خطای پس از نوسانات اولیه سریعاً کاهش یافته و به سمت مقدار پایدار خود میل میکند اما در آموزش در امتداد نزول گرادیان خطای پس کاهش بدلیل ناهمواری سطح جستجو و تغییر گرادیان تابع ارزیابی ممکن است دوباره حالت نوسانی پیدا کند.



شکل ۱۰: کاهش خطای تقریب نسبت به تعداد دفعات تکرار (a) : ویونت (b) : اتوماتای یادگیر.

**مثال چهارم :** به عنوان آخرین مثال تقریب تابع دو متغیره  $F(x) = (x_1^2 - x_2^2) \sin(0.5x_1)$  در فاصله  $[10,10] = [x_1, x_2]$  را با استفاده از الگوریتم ۳ نشان می دهیم. تابع ویولت استفاده شده گوسی دو متغیره  $\psi(x) = x_1 x_2 \exp(-\frac{1}{2}(x_1^2 + x_2^2))$  جهت شبیه سازی به ازای هر پارامتر تقریب یک اتوماتای پیوسته که که اقدام ان در فاصله فاصله  $[0,0]$  تغییر می کند در نظر گرفته شده است. نتایج شبیه سازی برای سه روش آموزش در امتداد نزول گرادیان و الگوریتم و اتوماتای پیوسته در شکل (۹) و خطای بدست آمده در جدول (۷) نشان داده شده است. میزان متوسط خطای بدست آمده پس از بیست بار تکرار برای آموزش در جهت نزول گرادیان برابر  $0.075$  و برای الگوریتمهای ۱ و ۳ بترتیب  $0.127$  و  $0.167$  می باشد.

جدول ۷ : مقادیر متوسط خطای تقریب برای الگوریتم های ۱ و ۳.

تعداد پارامتر	الگوریتم ۱	الگوریتم ۴	ویونت
۰.۳۷۴۲	۰.۰۱۶۷	۰.۰۱۲۷	۰.۰۷۵۲۳
۰.۴۵۶۴			
۰.۵۲۳۴			

### نتیجه گیری

در این مقاله ۳ الگوریتم مبتنی بر اتوماتای یادگیر برای محاسبه ضرائب ویولت ارائه گردیده است. این الگوریتمها خاصیت سلسه مراتبی ویولتها را حفظ کرده و به صورت پویا عمل می کنند. نکته ای که باید مورد توجه قرار گیرد این است که اتوماتای یادگیر مقادیر بهینه پارامترها را بین دو مقدار حداقل و حد اکثر جستجو می کند بنابر این باید از قبل اطلاعاتی در مورد مقادیر حداقل و حد اکثر پارامترها در دست باشد. در مورد مسائل کاربردی با توجه به اینکه محدوده عملیاتی سیستم از قبل قابل پیش بینی می باشد بدست آوردن مقادیر حداقل و حد اکثر پارامترها امکان پذیر است اما در مورد سایر مسائل می توان از روشهای دیگر مانند ضرب مسقیم یک مقدار اولیه برای هر پارامتر بدست آورد سپس مقدار بهینه را اطراف این مقدار اولیه جستجو کرد. نکته دیگری که در این

## مراجع

- 1 - Poggio, T. T. and Girosi, F. (1990). "Networks for approximation and learning." *Proc. IEEE*, Vol. 78, No. 9.
- 2 - Daubechies, I. (1990). "The wavelet transform, time-frequency localization and signal analysis." *IEEE Trans. Information Theory*, Vol. 36.
- 3 - Mallat, S. G. (1989). "A theory or multiresolution signal decomposition: the wavelet representation." *IEEE Trans. PAMI*, Vol. 11.
- 4 - Zhang, Q. and Benveniste, A. (1992). "Wavelet networks." *IEEE Trans. on Neural Networks*, No. 6, PP. 889-898.
- 5 - Bakhshi, B. R. and Stephanopoulos, G. (1993). "Wave-net: a mmultiresolution, hierarchical neural nnetworks with localized learning." *AICHE Journal*, No. 1.
- 6 - Safavi, A. A. (1997). "On the learning algorithms of wave-net." *Proceedings of Fifth Iranian Conference on Electrical Engineering*.
- 7 - Grossman, A. and Morlet, J. (1984). "Decomposition of hardly functions into square integrable wavlets." *SIAM. Math. Anal.*
- 8 - Daubechies, I. (1988). "Orthonormal basis of compactly suported waveles." *Communications on Pure and Applied Math.*, Vol. 41, PP. 909-999.
- 9 - Rao, S. and Pappu, R. S. (1993). "Hierarchical wavelet neural networks." *IEEE Trans. on Neural Networks*.
- 10 - Narendra, K. S. and Thathachar, M. A. L. (1989). *Learning automata : an introduction*. Printice -Hall.
- 11 - Narendra, K. S. and Thathachar, M. A. L. (1974). "Learning automata :a survey." *IEEE Trans. MC* 4.
- 12 - Mars, P., Narendra, K. S. and Chrystall, M. (1983). "Learning automata control of computer communication networks." *Proc. of Third Yale Workshop on Applications of Adaptive Systems Theory*, Yale University.
- 13 - Meybodi, M. R. and Lakshmivarhan, S. (1982). "Optimality of a general class of learning algorithm." *Information Science*, Vol. 28, PP. 1-20.
- 14 - Meybodi, M. R. and Lakshmivarhan, S. (1984). *On a class of learning algorithms which have a symmetric behavior under success and failure*. Springer Verlag Lecture Notes in Statistics, PP.145-155.
- 15 - Howell, M. N. and Gordon, T. J. (1998). "Continous learning automata and adaptive digital designs." *Proceedings of UKACC International Conference on Control*, PP. 100-105.

## واژه های کلیدی به ترتیب استفاده در متن

1 – Wavelet	2 – Harr	3 – Environment
4 – Unfavorable	5 – Stationary	6 – Non-Stationary
7 – Fixed Structure	8 – Actions	9 – Variable Structure
10 – Linear Reward Penalty	11 – Linear Reward Epsilon Penalty	
12 - Linear Reward Inaction	13 – Gradient Decent	14 – Direct Inner Product
15 – Continuous Srirred Tank Reactor		