

مقایسه کنترل کننده PID شبکه‌ی عصبی با دو روش تطبیقی مرسوم

فرهاد شهرکی*⁺، علیرضا ارجمندزاده

زاهدان، دانشگاه سیستان و بلوچستان، دانشکده مهندسی شهید نیکبخت، گروه مهندسی شیمی، صندوق پستی ۹۸۱۶۷-۱۶۴

محمدعلی فنایی شیخ‌الاسلامی

مشهد، دانشگاه فردوسی مشهد، دانشکده مهندسی، گروه مهندسی شیمی

چکیده: در این مقاله سعی شده است تا ضمن بررسی عملکرد کنترل کننده PID شبکه عصبی، به مقایسه آن با روش‌های مرسوم تنظیم تطبیقی این کنترل کننده پرداخته شود. در قسمت شبیه سازی، روش‌ها از نظر محل قرار گرفتن قطب‌های مدل فرایند، فرایند غیر مینیمم فاز و تغییر در مدل فرایند مورد بررسی قرار گرفته اند. به این ترتیب، نتیجه‌های حاصل از شبیه سازی و انجام آزمایش عملی بیان می کنند که PID شبکه عصبی با میزان سعی و خطای بسیار کم‌تری تنظیم شده و در صورت تغییر مدل فرایند از عملکرد مقاوم‌تری برخوردار خواهد بود و در هنگام کنترل فرایند در صورت تغییرهای متناوب مقدار مقرر پاسخ‌های مناسب و یکنواختی خواهد داشت.

واژه‌های کلیدی: کنترل کننده PID، شبکه عصبی، کنترل تطبیقی.

KEY WORDS: PID controller, Neural network, Adaptive control.

مقدمه

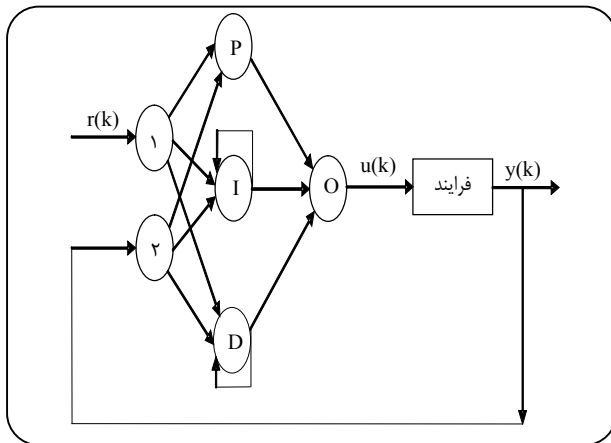
در پارامترهای فرایند تنظیم شوند [۴]. نیاز روزافزون صنایع به فرآورده‌های با کیفیت هرچه بالاتر آنها را ملزم به استفاده از کنترل کننده‌هایی می کند که هرچه مطمئن‌تر، مناسب‌تر و مقاوم‌تر باشند. اما به صورت ویژه، گستردگی استفاده صنایع از کنترل کننده‌های PID تحقیق و بررسی در مورد آنها را برای رسیدن به عملکرد هرچه مطلوب‌تر از اهمیت ویژه ای برخوردار می کند [۵]. پیشرفت‌هایی که در زمینه شبکه‌های عصبی حاصل شده و مشخص شدن قابلیت‌های این شبکه‌ها در تخمین هر تابع غیرخطی پیوسته در صورت داشتن حداقل یک لایه مخفی با تعداد کافی گره (نرون) [۶] و استفاده از این شبکه‌ها در مدل سازی و کنترل فرایندهای غیرخطی [۷ و ۸] طراحان را بر آن داشته تا از قابلیت‌های شبکه‌های عصبی در ارتقای عملکرد کنترل کننده‌های PID تطبیقی استفاده کنند [۵، ۹ و ۱۰].

کنترل کننده‌های PID، یکی از رایج‌ترین الگوریتم‌های کنترل کننده ای است که سال‌هاست به طور گسترده در صنایع شیمیایی مورد استفاده قرار می گیرد [۱ و ۲]. علت این امر، الگوریتم ساده آن و عملکرد مناسبی است که در صورت تنظیم مناسب از آن برخوردار خواهد بود. برای تنظیم این کنترل کننده نیز تاکنون روش‌های متعددی ارائه شده است [۳].

عملکرد این کنترل کننده‌ها در فرایندهای غیرخطی به‌طور عمومی به مرور زمان تحلیل می رود. لذا برای اصلاح عملکرد آن، باید دوباره تنظیم شود و این خود در طی یک فرایند سعی و خطا انجام می شود. که البته این نیز فرایندی زمان بر است و به تجربه اپراتور بستگی دارد. برای رفع این مشکل کنترل کننده‌هایی تحت عنوان کنترل کننده‌های تطبیقی ارائه شده‌اند تا به وسیله‌ی آنها پارامترهای کنترل کننده به‌طور خودکار و پیوسته، همراه با تغییر

*E-mail: fshahraki@hamoon.usb.ac.ir

*عهده دار مکاتبات



شکل ۱- چیدمان شبکه‌ی عصبی.

نیز از الگوریتم پس انتشار خطا به صورت روی خط (on-line) استفاده می‌کند.

چیدمان شبکه عصبی

همان‌گونه که در شکل ۱ مشخص است، این شبکه دارای ساختار درک کننده چند لایه به صورت پیش‌خور است که در لایه ورودی دارای دو گره از نوع P، در لایه میانی دارای سه گره از نوع P، I و D و در لایه خروجی دارای یک گره از نوع P است. تابع تحریک گره نوع P به صورت معادله‌ی (۱) ارایه شده است.

$$O_i(k) = \begin{cases} 1 & \text{net}_i(k) > 1 \\ \text{net}_i(k) & -1 \leq \text{net}_i(k) \leq 1 \\ -1 & \text{net}_i(k) < -1 \end{cases} \quad (1)$$

تابع تحریک گره نوع I به صورت معادله‌ی زیر بیان می‌شود:

$$O_j(k) = \begin{cases} 1 & O_j(k) > 1 \\ O_j(k-1) + \text{net}_j(k) & -1 \leq O_j(k) \leq 1 \\ -1 & O_j(k) < -1 \end{cases} \quad (2)$$

تابع تحریک گره نوع D نیز به صورت معادله‌ی (۳) آمده است:

$$O_j(k) = \begin{cases} 1 & O_j(k) > 1 \\ \text{net}_j(k) - \text{net}_j(k-1) & -1 \leq O_j(k) \leq 1 \\ -1 & -1 \leq O_j(k) \leq -1 \end{cases} \quad (3)$$

ورودی به گره ۱ از لایه ورودی مقدار مقرر و ورودی به گره ۲ از لایه ورودی خروجی فرایند است. ورودی‌های گره‌های لایه مخفی از معادله‌ی (۴) به‌دست می‌آید:

با توجه به این که ساختار، یکی از ویژگی‌های مورد توجه کنترل کننده PID است، طراحان سعی می‌کنند تا در الگوریتم‌هایی که ارایه می‌دهند، این مزیت کنترل کننده PID را حفظ کنند. به عنوان نمونه، الگوریتم ارایه شده در مرجع [۹] بدون هیچ تغییری در ساختار کنترل کننده PID با استفاده از شبکه عصبی مصنوعی و مفاهیم کنترل خطی، الگوریتمی ارایه کرده است که در کنترل فرایندهای به شدت غیر خطی عملکرد خوبی را نشان می‌دهد.

همچنین الگوریتم ارایه شده در مرجع [۵] بدون تغییر در ساختار کنترل کننده PID با استفاده از قابلیت پیش بینی شبکه عصبی عملکرد این کنترل کننده را بهبود بخشیده است. یکی دیگر از الگوریتم‌های ساده کنترل کننده PID تطبیقی با مبنای شبکه عصبی، ساختار ارایه شده به وسیله‌ی مرجع [۱۱] است. این کنترل کننده نوعی شبکه‌ی عصبی مصنوعی است که گره‌های (نرون‌های) لایه میانی آن به عنوان ترم‌های کنترل کننده PID عمل می‌کنند. روی این الگوریتم به عنوان یک الگوریتم جدید، تاکنون پژوهش جامعی انجام نشده و برتری‌ها و کاستی‌های آن نسبت به روش‌های مرسوم تنظیم تطبیقی PID مشخص نشده است. به این دلیل در این مقاله سعی شده است تا همراه با بررسی عملکرد کنترل کننده PID شبکه‌ی عصبی به مقایسه آن با روش‌های مرسوم تنظیم تطبیقی این کنترل کننده پرداخته شود. در ادامه، ابتدا به ارایه ساختارهای کنترلی مورد مقایسه پرداخته می‌شود و سپس این روش‌ها به وسیله‌ی شبیه‌سازی کامپیوتری مورد مقایسه قرار می‌گیرند. در این قسمت الگوریتم‌ها از نظر محل قرار گرفتن قطب‌های مدل فرایند، فرایند غیر مینیمم فاز و تغییر در مدل فرایند مورد مقایسه قرار می‌گیرند. در قسمت بعد به مقایسه این روش‌ها به وسیله‌ی نصب روی یک فرایند آزمایشگاهی پرداخته می‌شود و در نهایت به ارایه نتیجه‌ها می‌پردازیم.

ارایه الگوریتم‌های تطبیقی

PID شبکه عصبی

این نوع کنترل کننده PID، به علت ساختار خود که به صورت یک شبکه‌ی عصبی است از مزایای شبکه‌های عصبی استفاده می‌کند و به دلیل استفاده از مفاهیم کنترل کننده PID از مزایای این کنترل کننده نیز بهره مند است. این نوع کنترل کننده نوعی از شبکه‌های عصبی است که گره‌های لایه میانی به عنوان ترم‌های P، I و D کنترل کننده PID عمل می‌کند. این شبکه برای آموزش

برای به دست آوردن رابطه اصلاح وزن برای وزن‌های سیناپس‌های بین لایه ورودی و لایه مخفی با استفاده از قاعده زنجیری برای محاسبه $\partial J / \partial w_{oi}$ معادله‌ی (۱۱) حاصل می‌شود.

$$\frac{\partial J}{\partial w_{ji}} = \frac{\partial J}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial \text{net}_o} \frac{\partial \text{net}_o}{\partial O_j} \frac{\partial O_j}{\partial \text{net}_j} \frac{\partial \text{net}_j}{\partial w_{ji}} \quad (11)$$

با استفاده از تقریب مشتق، می‌توان نوشت:

$$\frac{\partial O_j}{\partial \text{net}_j} = \frac{O_j(k) - O_j(k-1)}{\text{net}_j(k) - \text{net}_j(k-1)} \quad (12)$$

با استفاده از معادله‌ی (۱۰)، معادله به صورت معادله‌ی (۱۳) خواهد شد:

$$\frac{\partial J}{\partial w_{ji}} = -\frac{2}{N} \sum_{k=1}^N [r(k) - y(k)] \frac{y(k) - y(k-1)}{u(k) - u(k-1)} w_{oi} \times \frac{O_j(k) - O_j(k-1)}{\text{net}_j(k) - \text{net}_j(k-1)} O_i \quad (13)$$

روش‌های تطبیقی مرسوم

تاکنون روش‌های متعددی برای تنظیم تطبیقی کنترل کننده PID ارائه شده است [۱۲]. چهار مورد از این روش‌ها در مرجع [۱۳] مورد مقایسه قرار گرفته‌اند. با توجه به نتیجه‌های این پژوهش از دو روش حذف [۱۴] و جایگزینی قطب [۱۵] برای مقایسه با PID شبکه‌ی عصبی استفاده می‌کنیم. در این دو روش قطب‌های مدل فرایند با روش‌های متفاوت حذف می‌شوند.

در روش حذف دینامیک فرایند به وسیله‌ی تابع تبدیل درجه دوم مدل می‌شود و پارامتر طراحی به گونه‌ای تنظیم می‌شود تا در حاشیه فاز مطلوب قطب‌های مدل فرایند به وسیله‌ی صفرهای کنترل کننده حذف شوند. در روش جایگزینی، همین شرایط تحقق می‌یابد با این تفاوت که پارامترهای کنترل کننده به گونه‌ای تعیین می‌شوند تا با قرار دادن قطب‌های تابع تبدیل مدار بسته در محل مورد نظر، قطب‌های مدل فرایند به وسیله‌ی صفرهای کنترل کننده حذف شوند. این دو روش از روش‌های کنترل تطبیقی غیر مستقیم است. بنابراین، الگوریتم کنترل کننده، به الگوریتمی برای شناسایی پارامترهای مدل فرایند نیاز دارد. برای این منظور، از الگوریتم حداقل مربعات بازگشتی (RLS) با فاکتور فراموشی متغیر [۱۶] استفاده شد.

$$\text{net}_i = \sum_{j=1}^r w_{ij} O_j \quad (4)$$

در این معادله، i شماره گره عصبی لایه مخفی و j گره عصبی لایه ورودی است. ورودی تنها گره لایه خروجی از معادله‌ی (۵) به دست می‌آید:

$$\text{net}_o = \sum_{j=1}^r w_{oj} O_j \quad (5)$$

که در این معادله‌ی j شماره گره عصبی لایه مخفی و o تنها گره عصبی لایه خروجی است.

آموزش

برای آموزش این شبکه از الگوریتم پس انتشار خطا به صورت روی خط استفاده می‌شود. تابع هدف در این الگوریتم به صورت زیر است:

$$J = \frac{1}{N} \sum_{k=1}^N [r(k) - y(k)]^2 \quad (6)$$

در معادله‌ی بالا، N تعداد کل نمونه گیری است. معادله‌ی اصلاح وزن برای لایه خروجی به صورت زیر است:

$$w_{oi}(k+1) = w_{oi}(k) - \alpha \frac{\partial J}{\partial w_{oi}} \quad (7)$$

بنابراین، مسأله به محاسبه $\partial J / \partial w_{oi}$ منجر می‌شود. برای این موضوع نیز با استفاده از قاعده زنجیری معادله‌ی (۸) به دست می‌آید:

$$\frac{\partial J}{\partial w_{oi}} = \frac{\partial J}{\partial y} \frac{\partial y}{\partial u} \frac{\partial u}{\partial \text{net}_o} \frac{\partial \text{net}_o}{\partial w_{oi}} \quad (8)$$

در این معادله، با توجه به در دسترس نبودن تابع تبدیل فرایند و همچنین مدل فرایند، برای محاسبه $\partial y / \partial u$ از تقریب زیر استفاده می‌شود:

$$\frac{\partial y}{\partial u} = \frac{y(k) - y(k-1)}{u(k) - u(k-1)} \quad (9)$$

به این ترتیب معادله‌ی اصلاح وزن برای وزن‌های سیناپس‌های بین لایه میانی و لایه خروجی به صورت معادله‌ی (۱۰) است.

$$\frac{\partial J}{\partial w_{oi}} = -\frac{2}{N} \sum_{k=1}^N [r(k) - y(k)] \frac{y(k) - y(k-1)}{u(k) - u(k-1)} O_j \quad (10)$$

جدول ۱- پارامتر طراحی الگوریتم های کنترل کننده.

الگوریتم کنترل کننده	پارامتر طراحی
PID شبکه‌ی عصبی	(ضریب آموزش) α
حذف	(حاشیه فاز) ϕ_m
جایگزینی قطب	(محل قطب) p

جدول ۲- تابع‌های تبدیل مدل‌های شبیه سازی.

شماره فرایند	تابع تبدیل گسسته فرایند
۱	$y(k) = \frac{0.9q^{-1}}{1-1.4q^{-1}+0.49q^{-2}}u(k)$
۲	$y(k) = \frac{0.5q^{-1}}{1-0.99q^{-1}+0.49q^{-2}}u(k)$
۳	$y(k) = \frac{q^{-2}(0.5+0.8q^{-1})}{1-1.4q^{-1}+0.49q^{-2}}u(k)$

جدول ۳- تابع‌های تبدیل مدل‌های شبیه سازی و ترتیب اعمال آنها.

ترتیب	تعداد پریود نمونه گیری	مدل پیوسته فرایند
۱	۰-۲۴۰	$\frac{1}{1+1.0s+4.0s^2}$
۲	۲۴۰-۴۸۰	$\frac{e^{-2s}}{1+1.0s+4.0s^2}$
۳	۴۸۰-۷۲۰	$\frac{1}{1+1.0s}$
۴	۷۲۰-۹۶۰	$\frac{e^{-2s}}{1+1.0s}$
۵	۹۶۰-۱۲۰۰	$\frac{(0.5-s)e^{-s}}{(3s+1)(4.53s+1)}$

فرومیرا و غیر مینیمم فاز پس از تنظیم پارامترهای آن می تواند پاسخ‌های مناسبی را ارایه دهد. نکته ای که تنظیم پارامتر طراحی این الگوریتم را به طور قابل ملاحظه ای از دو الگوریتم دیگر متمایز می کند این است که به میزان سعی و خطای بسیار کمتری نیاز دارد تا مناسبترین پاسخ خود را ارایه دهد، به گونه‌ای که در مورد هر سه فرایند بالا با یک مقدار پارامتر طراحی، کنترل فرایند به طور مناسبی انجام می پذیرد. در دو روش حذف و جایگزینی با وجود غنی شدن سیگنال‌های ورودی آنها، در ابتدا

نتیجه‌های شبیه سازی

در این قسمت سه الگوریتم ارایه شده در بالا به وسیله‌ی شبیه‌سازی کامپیوتری از نظر تاثیر سه عامل زیر مورد مقایسه قرار می‌گیرند.

۱) محل قرار گرفتن قطب‌های مدل فرایند

۲) فرایند غیر مینیمم فاز

۳) تغییر در مدل فرایند

پارامترهای طراحی در سه الگوریتم مطابق جدول ۱ ارایه شده و به گونه‌ای تنظیم می‌شوند تا بهترین پاسخ را با کمترین مقدار قدر مطلق انتگرال خطا (IAE) به صورت معادله‌ی (۱۴) داشته باشد.

$$IAE = \int |e(t)| dt \quad (14)$$

در معادله‌ی بالا $e(t)$ خطای ورودی به کنترل کننده به صورت رابطه (۱۵) است:

$$e(t) = r(t) - y(t) \quad (15)$$

اثر محل قرار گرفتن قطب‌ها و فرایندهای غیر مینیمم فاز

تابع‌های تبدیل به صورت جدول ۲ در نظر گرفته می‌شوند. این تابع‌های تبدیل به گونه ای انتخاب شده اند که فرایند اول دارای مدل درجه دوم با قطب‌های حقیقی مثبت به عنوان فرایند فرا میرا، و فرایند دوم دارای قطب‌های مختلط به عنوان فرایند فرومیرا و فرایند سوم نمونه از یک فرایند غیر مینیمم فاز باشد.

در هر مورد با تغییر مقدار مقرر پس از هر ۶۰ دوره نمونه‌گیری به میزان ۰/۲ رفتار الگوریتم ها با یکدیگر مقایسه می شود. برای دو الگوریتم حذف و جایگزینی موج PRBS که موج تصادفی باینری است به تعداد ۱۰ دوره نمونه گیری به صورت مدار باز با دامنه ۰/۴ به سیستم داده می‌شود. به این ترتیب با غنی کردن سیگنال‌های ورودی به الگوریتم RLS در جهت تخمین پارامترهای فرایند کمک می‌کند. با توجه به این که روش شبکه‌ی عصبی PID از الگوریتمی متفاوت با دو مورد دیگر برخوردار است، وارد کردن این موج در آن لزومی ندارد. به منظور بررسی اثر اغتشاش (Load) بر عملکرد کنترل کننده‌های مورد بررسی، از پریود نمونه گیری ۱۸۰ اغتشاش به میزان ۰/۰۱ اعمال می‌شود.

همان‌گونه که از شکل‌های ۲، ۳ و ۴ و جدول ۴ مشخص است، الگوریتم شبکه‌ی عصبی PID در هر سه فرایند فرامیرا،

جدول ۴ - مقدارهای انتگرال قدرمطلق خطا مربوط به دوره های نمونه گیری ۱۸۰-۱۲۰ و ۲۴۰-۱۸۰.

الگوریتم کنترل فرایند	شبکه‌ی عصبی		حذف		جایگزینی	
	۱۸۰ - ۱۲۰	۲۴۰ - ۱۸۰	۱۸۰ - ۱۲۰	۲۴۰ - ۱۸۰	۱۸۰ - ۱۲۰	۲۴۰ - ۱۸۰
۱	۰٫۶۲۵۸	۰٫۱۷۸۷	۰٫۱۸۱۱	۰٫۱۱۸۳	۲٫۱۲۹۹	۰٫۶۴۷۸
۲	۰٫۲۲۴۹	۰٫۰۵۸۸	۰٫۱۴۴۷	۰٫۰۵۰۰	۰٫۲۲۹۳	۰٫۰۶۰۲
۳	۲٫۶۷۴۹	۰٫۷۲۸۷	۲٫۵۸۶۷	۱٫۹۱۸۷	۲٫۷۱۰۲	۱٫۹۳۱۸

همان‌گونه که در شکل ۷ مشخص است هر دو الگوریتم در کنترل این فرایند پاسخ‌های قابل قبولی را ارائه داده‌اند، اما الگوریتم شبکه‌ی عصبی PID از عملکرد بهتری نسبت به الگوریتم حذف برخوردار است، به ویژه در قسمت‌های ابتدایی آزمایش که روش حذف ضعیف‌ترین عملکرد را از خود به نمایش می‌گذارد و علت آن نیز الگوریتم RLS است که با وجود اعمال شدن موج PRBS به میزان ۲۰ دوره نمونه گیری هنوز تخمین مناسبی را از پارامترهای فرایند به دست نیاورده است. افزون بر این با تغییر مقدار مقرر پاسخ‌های الگوریتم حذف فراجش‌های بزرگی دارد که البته در تغییرهای بعدی مقدار مقرر از میزان این فراجش‌ها کاسته می‌شود.

نتیجه‌گیری نهایی

در این تحقیق، عملکرد کنترل کننده PID شبکه‌ی عصبی به وسیله‌ی شبیه سازی کامپیوتری و آزمایش‌های عملی مورد مقایسه قرار گرفت. نتیجه‌های حاصل از شبیه سازی نشان دادند که این کنترل کننده با میزان سعی و خطای بسیار کم‌تر برای تنظیم پارامتر طراحی، در فرایندهای فرامیرا، فرامیرا و نیز فرایندهای غیر مینیمم فاز عملکرد مناسبی را ارائه می‌دهد. حال آن‌که در روش‌های مرسوم برای به دست آوردن پاسخ‌های مناسب به سعی و خطای زیادتری برای تنظیم پارامترهای طراحی نیاز است.

این کنترل کننده از عملکرد مقاوم‌تر نسبت به روش‌های مرسوم برخوردار است. در این قسمت مشخص شد که عملکرد این روش نیز با نزدیک شدن قطب‌های فرایند به دایره واحد تحلیل می‌رود. نتیجه‌های حاصل از قسمت آزمایش عملی کنترل کننده در کنترل فشار هوا در دو مخزن هوا که به صورت سری به یکدیگر متصل هستند نیز در تایید نتیجه‌های حاصل از شبیه‌سازی قرار گرفتند.

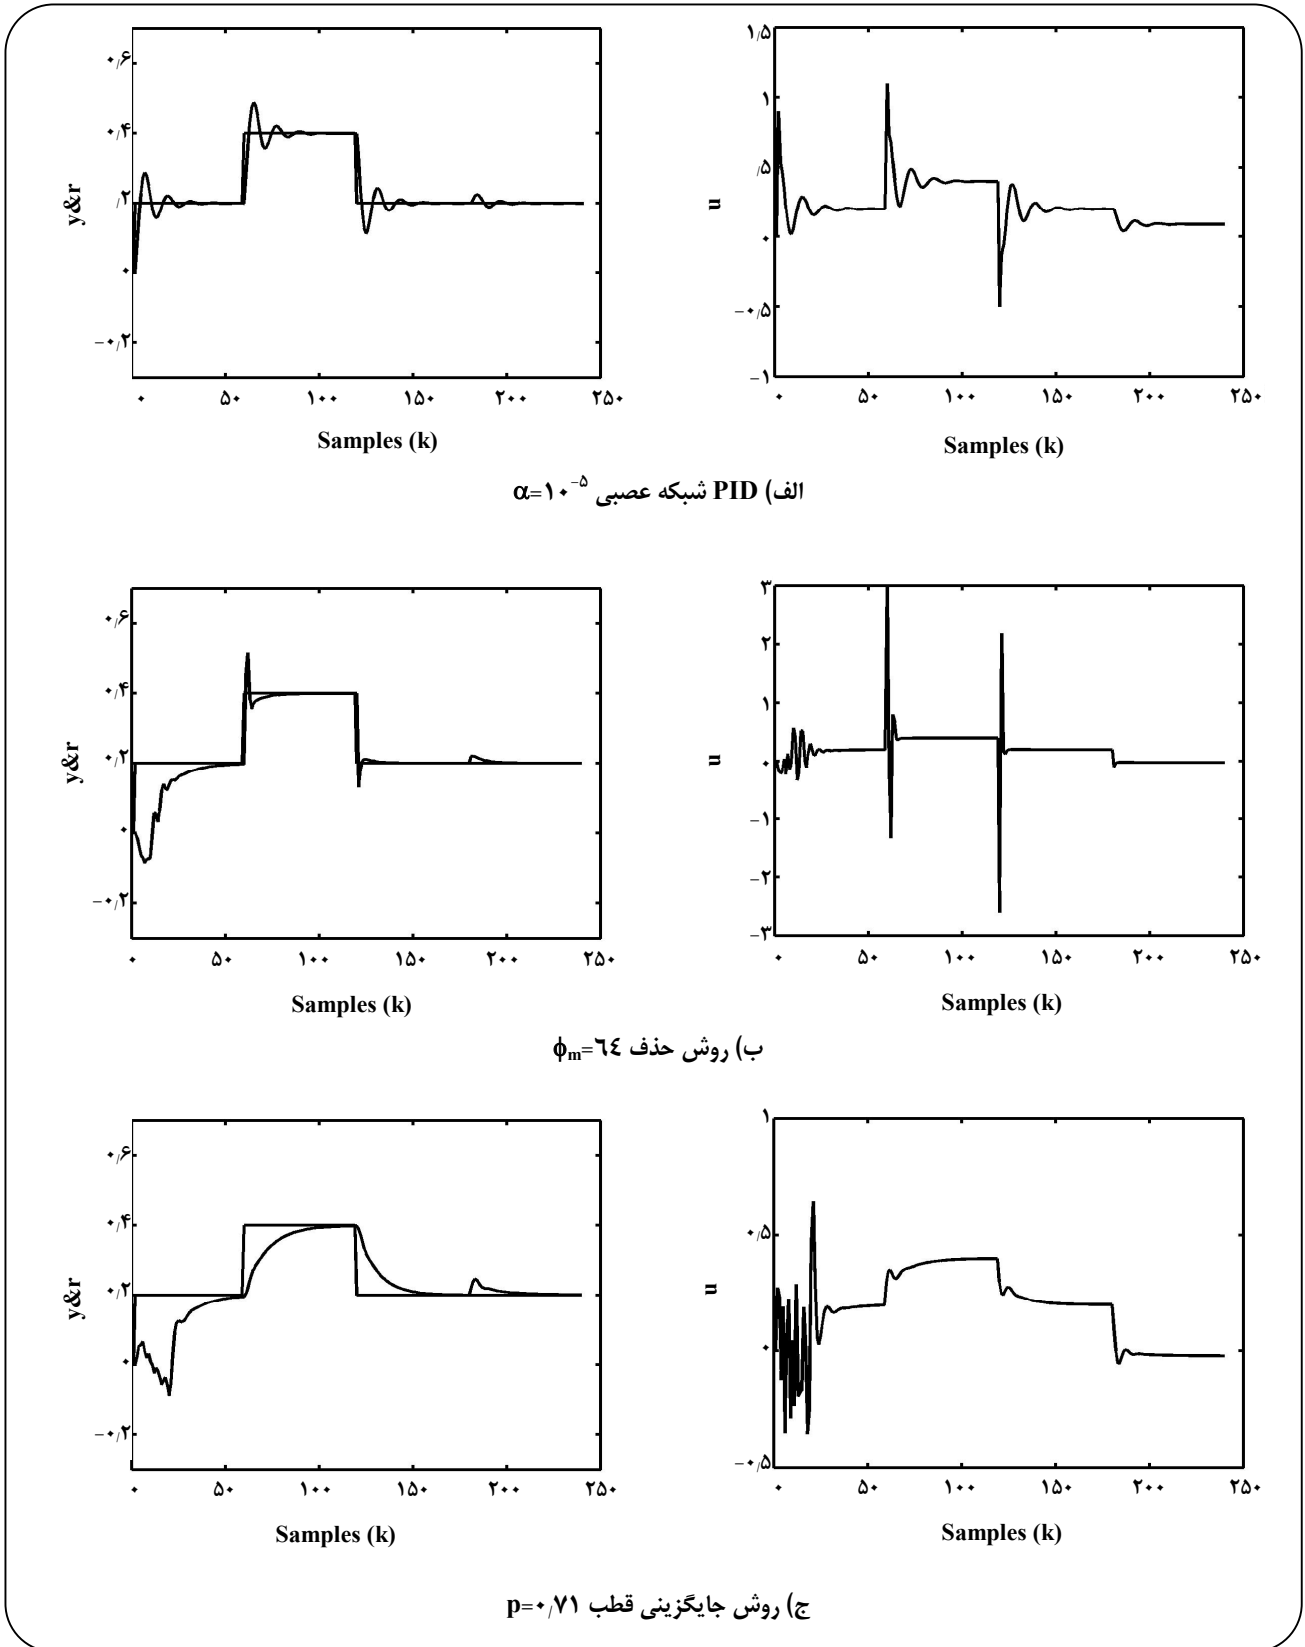
هر دو الگوریتم پاسخ‌های بسیار نامناسبی ارائه می‌دهند که البته این ضعف را در طول اجرای عملیات کنترل اصلاح می‌کنند. روش جایگزینی قطب به جز در فرایند فرامیرا، پاسخ‌های نامناسبی را در مقایسه با سایر الگوریتم‌ها ارائه می‌دهد. نکته دیگر این‌که، هر سه الگوریتم با نزدیک شدن قطب‌های مدل فرایند به دایره واحد عملکرد آنها، تحلیل می‌رود اما الگوریتم شبکه‌ی عصبی PID به این موضوع حساسیت بیشتری نشان می‌دهد. در صورت اعمال اغتشاش الگوریتم شبکه عصبی PID، عملکرد خوبی را در مقایسه با دو روش دیگر نشان می‌دهد، به‌ویژه در مورد فرایندهای غیرمینیمم فاز که از عملکرد بسیار بهتری برخوردار است. اما این الگوریتم در مورد اعمال اغتشاش نیز به نزدیک شدن قطب‌های مدل فرایند به دایره واحد حساسیت نشان می‌دهد.

اثر تغییر در مدل فرایند

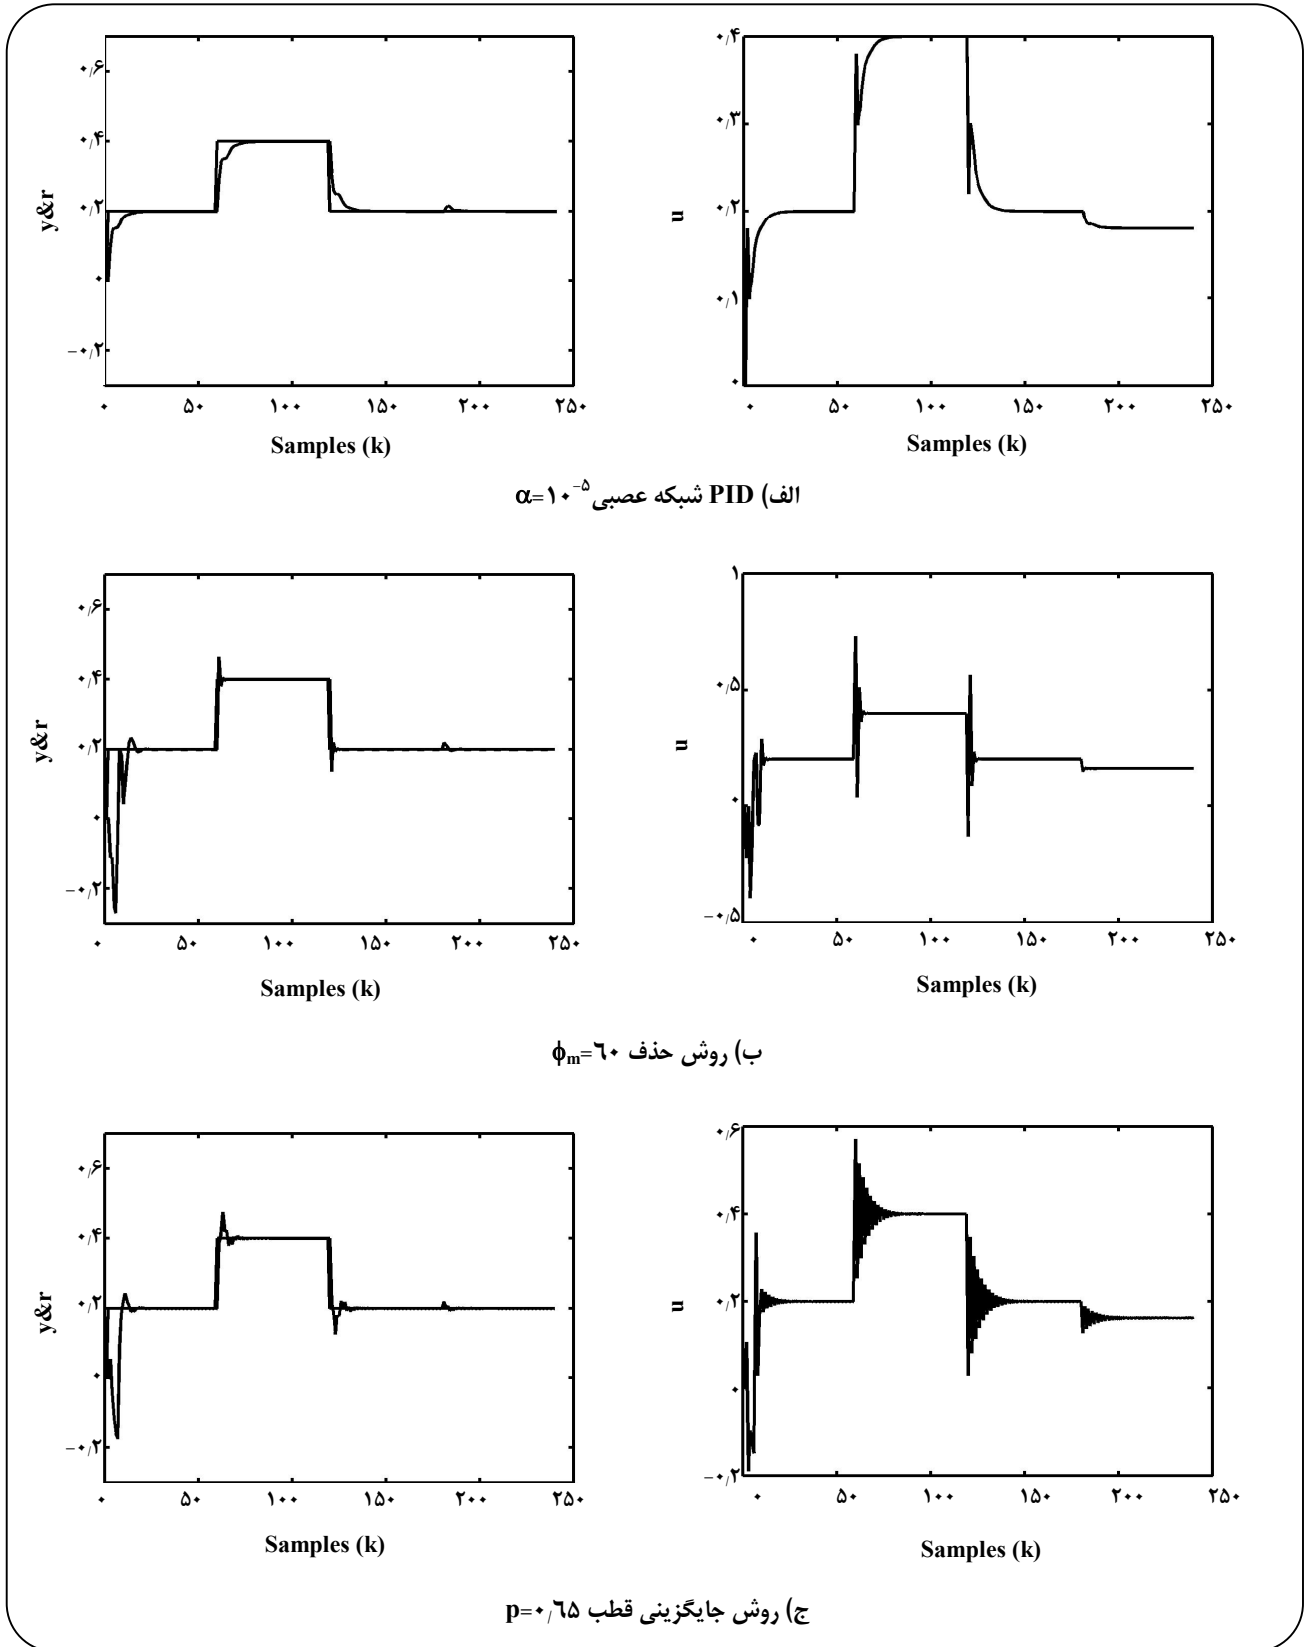
در این قسمت اثر تغییر در مدل فرایند بر عملکرد الگوریتم کنترل کننده مورد بررسی قرار می‌گیرد. نحوه تغییر مدل فرایند به همراه زمان‌های اعمال آنها در جدول ۳ آورده شده است. همان‌گونه که از شکل ۵ مشخص است الگوریتم شبکه‌ی عصبی PID نسبت به تغییر در مدل فرایند، کم‌ترین میزان حساسیت را نشان می‌دهد. این موضوع به علت برخورداری از ساختار شبکه عصبی است [۱۷].

نتیجه‌های آزمایشگاهی



همان‌گونه که در قسمت شبیه سازی مشاهده شد، روش جایگزینی نسبت به دو روش دیگر از عملکرد ضعیف‌تری برخوردار بود. از این رو در این قسمت شبکه عصبی PID با روش حذف مقایسه می‌شود. چیدمان فرایند در شکل ۶ آورده شده است. در این فرایند فشار مخزن دوم $y(k)$ به وسیله‌ی دبی هوای ورودی $u(k)$ به وسیله‌ی یک شیر کنترل نیوماتیکی کنترل می‌شود.





شکل ۲- پاسخ مدار بسته برای فرایند ۱.





شکل ۳- پاسخ مدار بسته برای فرایند ۲.



الف) PID شبکه عصبی $\alpha=10^{-5}$

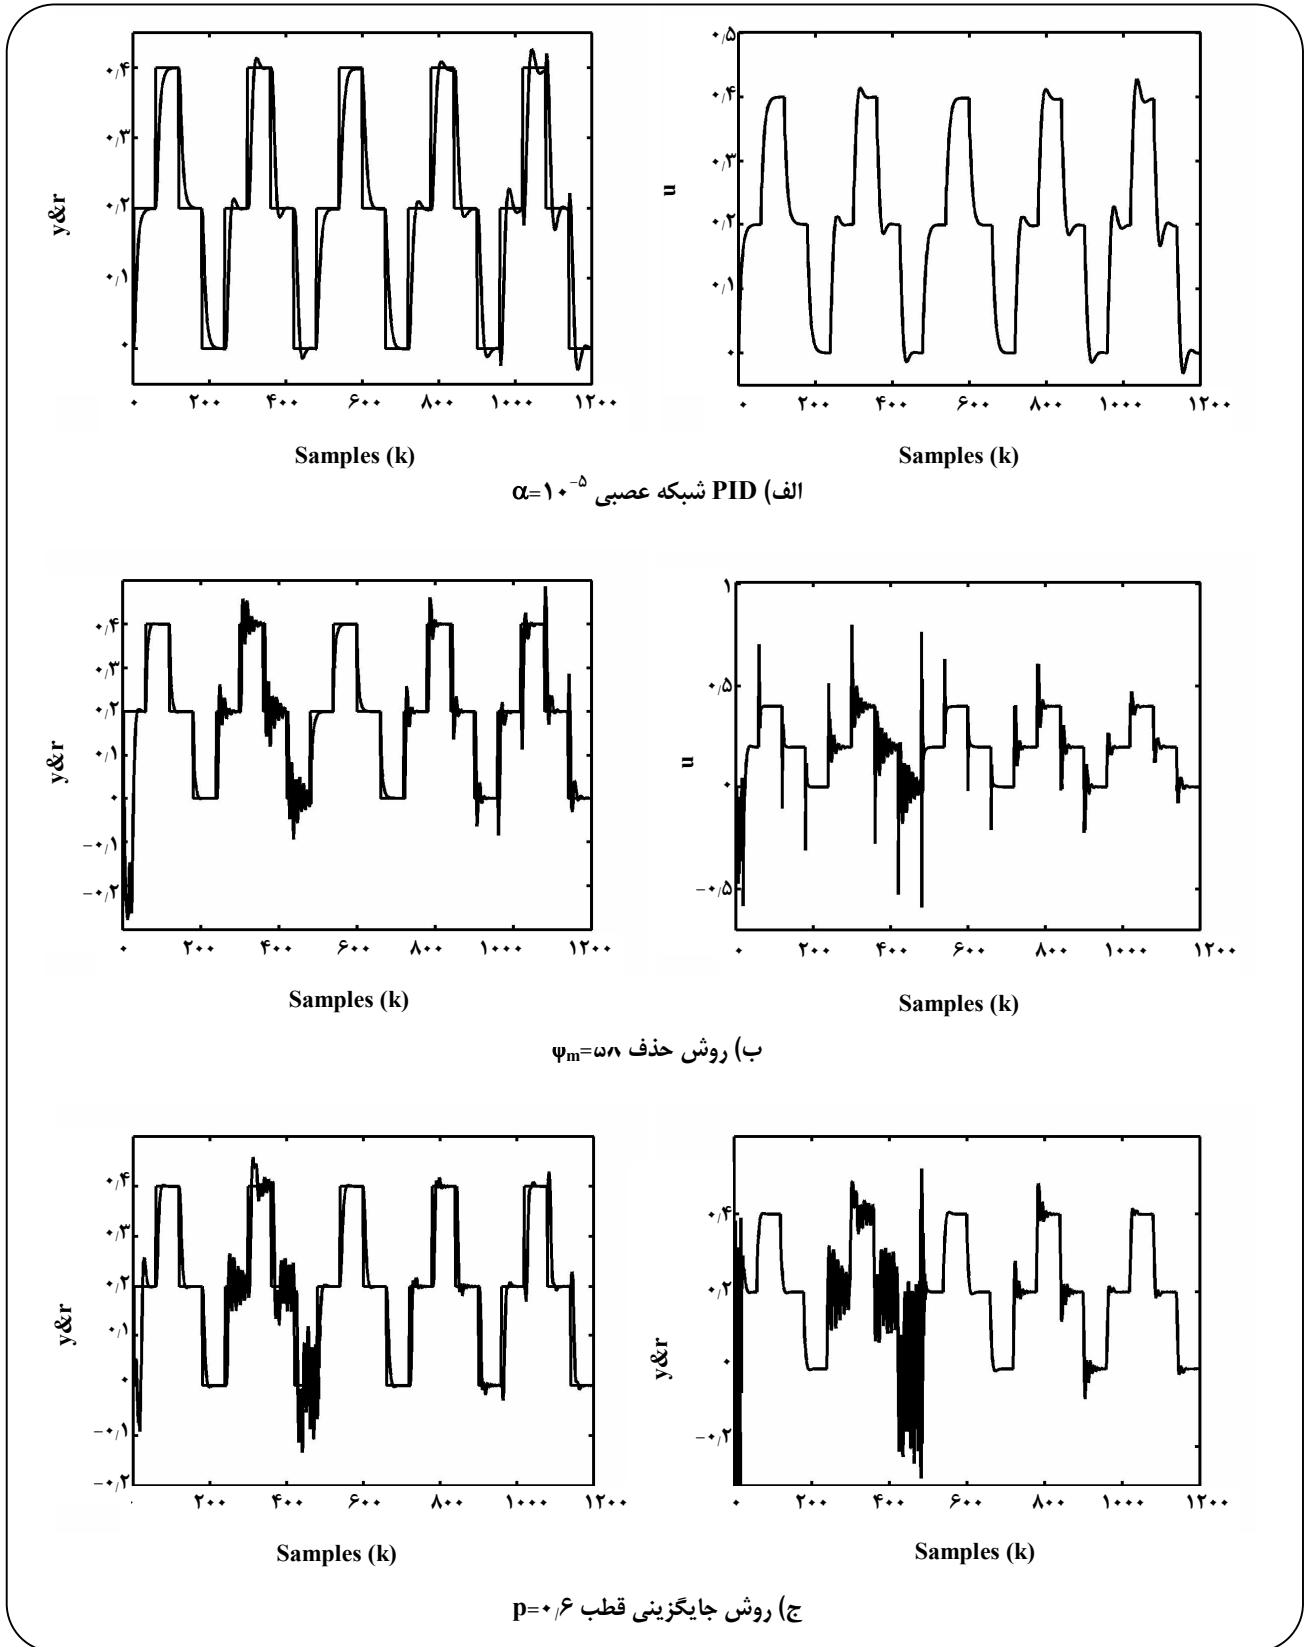


ب) روش حذف $\phi_m=55$

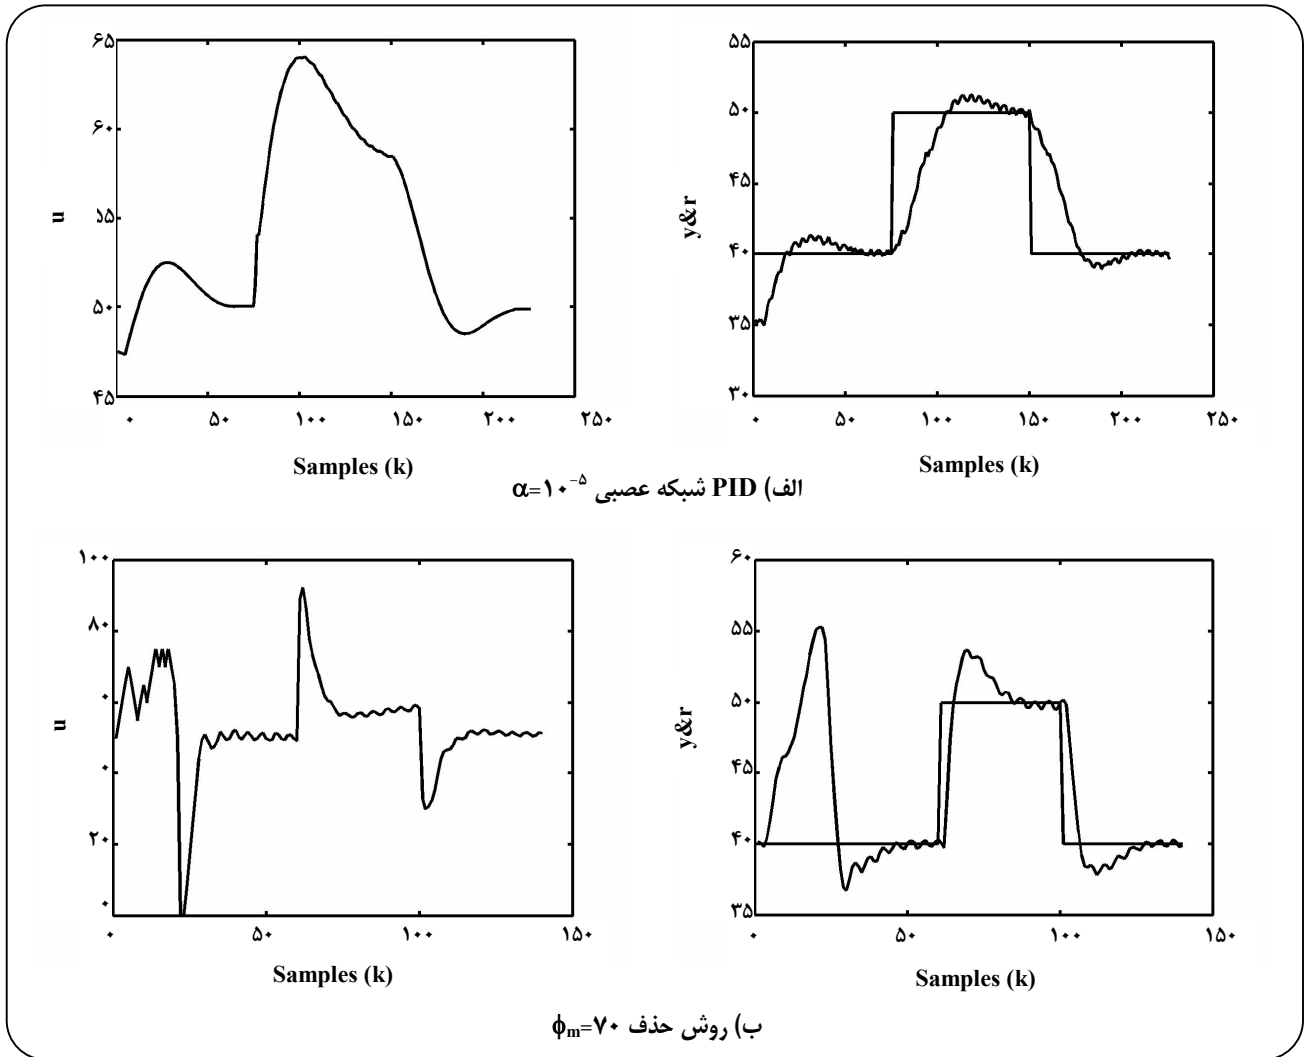


ج) روش جایگزینی قطب $p=0.58$

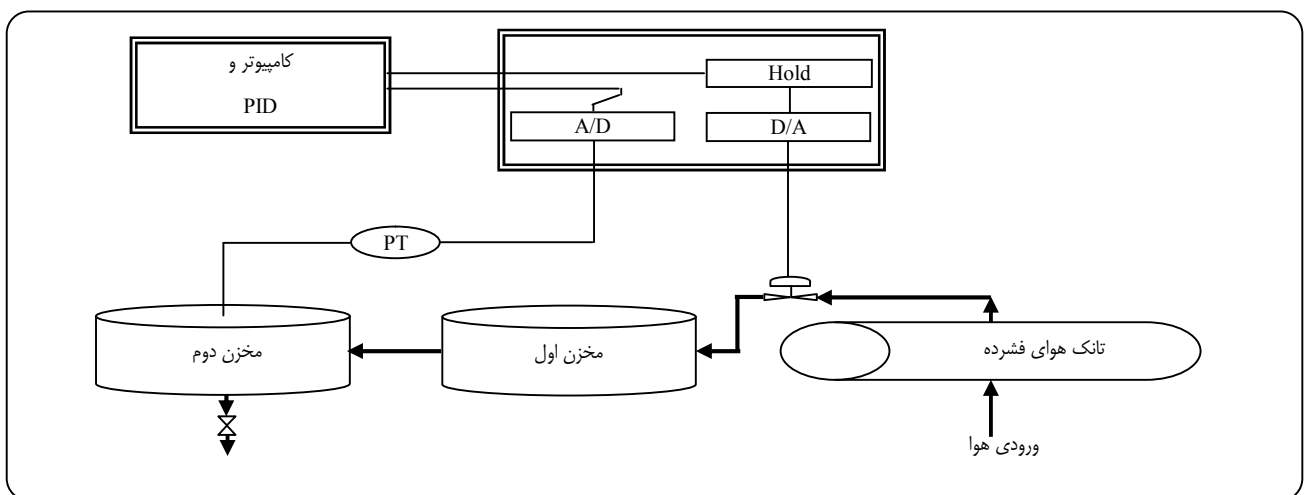
شکل ۴- پاسخ مدار بسته برای فرایند ۳.



شکل ۵- پاسخ مدار بسته الگوریتم‌ها.



شکل ۷- پاسخ‌های الگوریتم‌های PID شبکه عصبی و حذف در کنترل فشار روی مدل آزمایشگاهی.



شکل ۶- فرایند مورد استفاده در آزمایشگاه.

فهرست علائم

حروف انگلیسی

تابع هدف

شماره پریود نمونه گیری

ورودی به تابع تحریک

خروجی گره عصبی i ام

محل قطب مطلوب

عملگر انتقال دهنده عقب‌گرا

مقدار مقرر

s متغیر تبدیل لاپلاس

u خروجی کنترل کننده

w_{ij} وزن سیناپس گره j به i

y خروجی فرایند

حروف یونانی

α پارامتر آموزش

φ_m حاشیه فاز مطلوب

تاریخ دریافت: ۱۵/۴/۰۴ ؛ تاریخ پذیرش: ۱۵/۸/۰۴

J

k

net

O_i

p

q^{-1}

r

مراجع

- [1] Desbrough, L. and Miller, R., Increase Customer Value of Industrial Control Performance Monitoring-Honeywell's Experience, *AICHE J.*, Symposium Series Number 328, 98 (2002).
- [2] Astrom, K. J. and Hagglund, T., "The Future of PID Control", *Control Engineering Practice*, 9, 1163-1175 (2001).
- [3] Atherton, D.P., "PID Controller Tuning", *Computing & Control Engineering*, pp. 44-50 (1999).
- [4] Widrow, B. and Stearns, S. D., "Adaptive Signal Processing", Prentice Hall (1985).
- [5] Martins, G.F. and Coelho, M.A.N., Application of Feed-Forward Artificial Neural Networks to Improve Process Control of PID - Based Control Algorithms, *Computers and Chemical Engineering*, **24**, p. 853 (2000).
- [6] Hornik, K., Stinchcombe, M. and White, H., Multilayer Feed-Forward Neural Networks are Universal Approximator, *Neural Networks*, **2**, pp. 359 (1989).
- [7] Heach, R., "Theory of Back - Propagation Neural Networks", *IEEE Proceedings of the International Conference on Neural Networks*, **1**, pp. 593 (1989).
- [8] Tsen, A. D., Jang, S. S. and Wong, D. S. H., Predictive Control of Quality in Batch Polymerization Using Hybrid ANN Models, *AICHE*, **42**(2), p. 455 (1996).
- [9] Junghui, C. and Huang, T. C., Applying Neural Networks to On-Line Updated PID Controllers for Nonlinear Process Control, *Journal of Process Control*, **14**, p. 211 (2004).
- [10] Andrasik, A., Meszaros, A. and Azevedo, S. F., On-Line Tuning of a PID Controller Based on Plant Hybrid Modelling, *Computers and Chemical Engineering*, **28**, p. 1499 (2004).
- [11] Huailin, S. and Pi, Y., PID Neural Networks for Time-Delay Systems, *Computers and Chemical Engineering*, **24**, p. 859 (2000).
- [12] Astrom, K. J. and Hagglund, T., Automatic Tuning of PID Controllers, Instrument Society of America, Research Triangle Park (1988).
- [13] Shahrokhi, M. and Fanaei, M. A., Comparison of Four Adaptive PID Controllers, *Scientia Iranica*, **7**, p. 129 (2000).

- [14] Banyacz, C. S., Hetthessy, J. and Keviczky, L., "An Adaptive PID Regulator Dedicated for Microprocessor-Based Compact Controllers, IFAC Symp. Ident. & Syst. Para. Est., pp. 1299, New York (1985).
- [15] Tjorkro, S. and Shah, S. L., "Adaptive PID Control", Proc. Amer. Cont. Conf., 3, pp. 1525-1529 (1985).
- [16] Fortescue, T.R., et. al., "Implementation of Self-Tunings Regulators with Variable Forgetting Factors", *Automatica*, **17**, pp. 831 (1981).

[۱۷] اچ. ام. کارت رایت، "هوش مصنوعی و کاربردهای آن در شیمی"، ترجمه دکتر محمد خشنودی، انتشارات دانشگاه آزاد اسلامی (۱۳۷۹).