مجله کنترل
ISSN (print) 2008-8345
ISSN (online) 2538-3752
مقاله پژوهشی
جلد۱۷، شماره ۱، بهار ۱۴۰۲، صفحه ۹۱-۷۷

ارزیابی کیفیت محصول مبتنی بر روش پارامتر وابسته به متغیر حالت با کاربرد در فرآیند تنسی ایستمن (TEP)

رعنا حسن پور[۱]، میرمحمد خلیلی پور[۲،*]، جعفر صادقی[۳]، بهاره بیدار[۴]

[۱] فارغ‌التحصیل کارشناسی ارشد مهندسی شیمی، گروه مهندسی شیمی، دانشکده مهندسی شهید نیک‌بخت، دانشگاه سیستان و بلوچستان، rana.hasanpour20@gmail.com
[۲،*] استادیار، گروه مهندسی شیمی، دانشکده مهندسی شهید نیک‌بخت، دانشگاه سیستان و بلوچستان، a.khalilipour@eng.usb.ac.ir
[۳] دانشیار، گروه مهندسی شیمی، دانشکده مهندسی شهید نیک‌بخت، دانشگاه سیستان و بلوچستان، sadeghi@eng.usb.ac.ir
[۴] استادیار، گروه مهندسی شیمی، دانشکده مهندسی شهید نیک‌بخت، دانشگاه سیستان و بلوچستان، b.bidar@eng.usb.ac.ir

دریافت: ۱۴۰۱/۰۹/۱۲ ویرایش: ۱۴۰۲/۰۱/۲۲ پذیرش: ۱۴۰۲/۰۲/۲۰

چکیده: توسعه و پیاده‌سازی روش‌های پیشرفته نظارت و کنترل نیازمند اندازه‌گیری متغیرهایی است که تعیین آن‌ها به روش فیزیکی امکان‌پذیر نیست یا اینکه سنجش آن‌ها بسیار دشوار است. حسگرهای نرم می‌توانند با تخمین متغیرهای دشوار اندازه‌گیر بوسیله متغیرهای آسان اندازه‌گیر جایگزین مناسبی برای حسگرهای سخت‌افزاری باشند. در این مقاله حسگر نرم داده محور بر مبنای مدل‌سازی پارامتر وابسته به حالت با استفاده از تکنیک متغیر سودمند محلی[۱] (LIV) به منظور تخمین کیفیت در فرآیند تنسی ایستمن ارائه گردیده است. این تکنیک ساختاری ساده دارد و نسبت به سایر روش های مدلسازی به تعداد متغیرهای ورودی کمتری نیازمند است، قابلیت شناسایی متغیرهای تأثیرگذار بر روی متغیرهای هدف را نیز داراست. در این مطالعه، مدل‌های حسگر نرم مبتنی بر LIV به منظور پیش‌بینی غلظت اجزاء A و E توسط نرم افزار MATLAB توسعه یافتند. نتایج حاصل از ارزیابی مدل‌های ارائه شده بر روی مجموعه داده‌ی آزمون، خطای جذر میانگین مربع خطا (RMSE) را به ترتیب ۰/۳۱۹۱ و ۰/۰۱۷۴ برای جزء A و جزء E گزارش می‌دهد. مدل LIV پیشنهادی، خطای پیش‌بینی (RMSE) برای غلظت جزء E را نسبت به روش‌های کمینه مربعات جزئی[۲] (PLS) و کمینه مربعات جزئی درونی پویا[۳] (DiPLS) به ترتیب به میزان ۹۸/۱۸٪ و ۹۷/۶ ٪ کاهش داده است.

کلمات کلیدی: تخمین کیفیت، حسگر نرم داده محور، فرآیند تنسی ایستمن، مدل‌سازی پارامتر وابسته به متغیر حالت، روش متغیر سودمند محلی.

SDP-Based Quality Monitoring with Application to the Tennessee Eastman Process (TEP)

Rana Hassanpour, Mir Mohammad Khalilipour, Jafar Sadeghi, Bahareh Bidar

Abstract: Development and implementation of advanced monitoring and control techniques requires measurement of variables which cannot be determined physically or difficult to measure. Soft sensors can be used as a relatively inexpensive alternative for hardware sensors as a suitable solution in the process industries by estimation of easy-to-measure variables using hard-to-measure variables. In this study, design of data-driven soft sensor based on state-dependent parameter modeling method by using local instrumental variable (LIV) have been presented to predict quality

[1] Local Instrumental Variable
[2] Partial Least Squares
[3] Dynamic inner Partial least squares

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

variables in Tennessee Eastman (TE) process. Unlike other soft sensor modeling methods, the state dependent parameter modeling method has simple structure and often requires fewer input variables. Moreover, state dependent modeling method using local instrumental variable can identify influencing variables which have been affected the target variables. The performance of identifying technique and proposed soft sensors has been investigated on Tennessee Eastman process. In the present study, LIV based Soft sensor models have been developed using MATLAB software to predict concentration of A and E components. The evaluation results of the proposed models on the test data set report that the root mean squared error (RMSE) for concentration of components A and E are 0.3191 and 0.0174, respectively. The proposed LIV model reduced prediction error (RMSE) for the concentration of component E by 98.18% and 97.6% as compared to Partial Least Squares (PLS) and Dynamic Inner Partial least squares (DiPLS) methods, respectively.

Keywords: Quality prediction, Data-driven soft sensor, Tennessee Eastman process, State-dependent parameter modeling, Local instrumental variable method.

۱- مقدمه

فرآیندهای صنعتی به دلیل نیاز به کنترل کیفیت محصول، کاهش آلودگی های زیست محیطی و افزایش ایمنی فرآیند نیازمند بهبود سیستم‌های اندازه‌گیری و کنترل خود هستند. هنگامی که امکان اندازه‌گیری متغیرهای مهم فرآیندی که اطلاعات مربوط به کیفیت محصول را ارائه می‌دهند، با استفاده از تجهیزات ابزار دقیق یا حسگرهای سخت افزاری وجود نداشته و یا اندازه‌گیری‌های انجام شده توسط این حسگرها غیر قابل اعتماد و هزینه بر باشد، مشکلات کنترلی و نظارت مستمر بر فرآیند ظاهر می‌شوند. این متغیرها، متغیرهای دشوار اندازه‌گیر[۱] نامیده می شوند که در بیشتر موارد توسط تجزیه و تحلیل آزمایشگاهی توام با تأخیر طولانی اندازه‌گیری می‌شوند. در این راستا حسگرهای نرم[۲] (حسگرهای استنتاجی) به عنوان یک راه حل جهت بهبود قابلیت اطمینان سیستم‌های اندازه‌گیری، نظارت و کنترل فرآیند در حال توسعه هستند. یکی از مهم ترین کاربردهای حسگرهای نرم، پیش‌بینی برخط[۳] متغیرهای دشوار اندازه‌گیر بر مبنای متغیرهای فرآیندی آسان اندازه‌گیر[۴] که توسط حسگرهای سخت‌افزاری موجود به راحتی اندازه‌گیری می‌شوند، است [۱].

حسگرهای نرم، مزایای بسیاری در مقایسه با تجهیزات ابزار دقیق سنتی دارند. این حسگرها با پیش‌بینی داده‌ها به صورت برخط، مشکل تحلیل‌های آزمایشگاهی را برطرف می‌کنند، بنابراین باعث بهبود عملکرد سیستم کنترل می‌شوند. همچنین با جمع‌آوری اطلاعات پنهان در داده‌ها، دید بهتر و دقیق‌تری نسبت به فرآیند در اختیار متخصصین قرار می‌دهند. از آنجایی که قابلیت بکارگیری به صورت موازی با تجهیزات اندازه‌گیری موجود را دارند، لذا امکان داشتن فرآیند با قابلیت اطمینان بیشتری را فراهم می‌کنند. همچنین در مقایسه با هزینه‌های لازم برای بسیاری از تجهیزات سخت افزاری، پیاده سازی این حسگرها هزینه کمتری دارد [۲ و ۳].

براساس نوع روش مدل‌سازی، حسگرهای نرم به دو دسته کلی مدل محور[۵] و داده محور[۶] تقسیم می‌شوند. واضح است که امکان توسعه حسگرهای مدل محور برای فرآیندهای صنعتی بسیار مشکل و غیرعملی است زیرا به دانش پدیده شناسی بالایی از فرآیند احتیاج است. در نتیجه در فرآیندهای صنعتی، حسگرهای داده محور محبوبیت پیدا کردند که شرایط واقعی یک واحد فرآیندی را بر مبنای داده‌های اندازه‌گیری شده ورودی و خروجی فرآیند، توصیف می‌کنند [۴و۵].

محبوب‌ترین تکنیک‌های مدل‌سازی خطی که برای حسگرهای نرم داده محور بکار برده می‌شوند شامل روش تحلیل مؤلفه اصلی[۷](PCA)، روش کمینه مربعات جزئی[۸] (PLS) می‌باشد. مدل‌های بدست آمده از ترکیب روش‌های PCA و PLS با مدل‌های رگرسیونی، مدل رگرسیون کمینه مربعات جزئی[۹](PLSR) و مدل رگرسیون مؤلفه اصلی[۱۰] (PCR) نامیده می‌شوند. با این حال، نقاط ضعف این مدل‌ها نیز در طبیعت خطی و ناتوانی در مدل‌سازی سیستم‌های غیرخطی و اغلب پیش‌بینی ضعیف به دلیل چشم‌پوشی از رابطه بین ورودی و خروجی سیستم است، در نتیجه به عنوان مرحله پیش‌پردازش برای سایر روش‌های آماری به کار می‌روند [۶و۷]. متداول‌ترین تکنیک‌های غیرخطی، روش شبکه عصبی مصنوعی[۱۱](ANN)، سیستم عصبی- فازی[۱۲](NFS) و ماشین بردار پشتیبان[۱۳](SVM) می‌باشند. شبکه عصبی مصنوعی یک روش مشهور در مدل‌سازی غیرخطی برای حسگرهای نرم داده محور است. روش سیستم عصبی- فازی به موجب شبکه عصبی دارای توانایی یادگیری تطبیق پذیر، قابلیت پردازش موازی و دارای قابلیت لحاظ نمودن داده‌های دیده نشده است. مشکل اساسی روش NFS افزایش ابعاد است که بالتبع هزینه محاسبات و حافظه موردنیاز را افزایش می‌دهد. در سال های اخیر، روش

[1] Difficult-to-measure
[2] Soft sensor
[3] Online prediction
[4] Easy-to-measure
[5] Model-driven
[6] Data-driven
[7] Principal component analysis
[8] Partial least squares
[9] Partial least squares regression
[10] Principal component regression
[11] Artificial Neural Network
[12] Neuro-Nuzzy System
[13] Support Vector Machine

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

SVM محبوبیت زیادی بدست آورده است چرا که مشکلات کمینه کردن محلی و بیش برازش[1] که در شبکه عصبی مصنوعی رخ می‌دهد را ندارد. مدل رگرسیون بردار پشتیبان[2](SVR) سعی می‌کند یک سطح بهینه به عنوان تابع تصمیم گیرنده در فضایی با ابعاد بالا پیدا کند که بخاطر استفاده از تکنیک‌های خاص آماری با رگرسیون معمولی تفاوت دارد [۸و۹].

به منظور بررسی تغییرات با زمان فرآیندها، تکنیک شناسایی متغیر با زمان مورد استفاده قرار گرفت. این تکنیک بر مبنای شناسایی کمینه مربعات بازگشتی[3] (RLS) استوار است که با استفاده از بهینه‌سازی اَبر پارامترها[4] و تکنیک‌های پالایش[5] بازگشتی تخمین‌های بهتری برای پارامترهای متغیر با زمان[6] (TVP) بدست آورد. از آنجایی‌که الگوریتم TVP در شناسایی تغییرات بسیار شدید پارامترهای وابسته به حالت در سیستم‌های غیرخطی ناتوان بود، رویکرد پارامتر وابسته به حالت[7] (SDP) برای تحلیل رفتار سیستم های غیرخطی ارائه گردید [۱۰]. روش مبنای SDP به صورت تک متغیر حالت بوده، لذا برای رفع مشکل پارامتر با تابعیت چندحالته، صادقی و توکلی [۱۱و۱۲] رویکرد مدل پارامتر وابسته به چندین متغیر حالت[8] (MSDP) را توسعه داد. در ادامه بیدار و همکاران [۱۳] با بکارگیری متغیر سودمند محلی[9]، یک روش جدید از تخمین پارامتر وابسته به حالت (SDP) به نام روش متغیر سودمند محلی (LIV) ارائه نمودند. این روش که بر مبنای کمینه مربعات وزنی[10] (WLS) استوار است، می‌تواند به صورت مستقیم و بدون پارامتری کردن مدل نهایی، برای درون‌یابی[11] در مجموعه داده‌ها استفاده شود. این قابلیت به همراه عدم نیاز به تعداد بالایی از متغیرهای ورودی مدل از مزیت های مهم روش LIV می باشد. در سال‌های اخیر تکنیک‌های مدلسازی بر مبنای رویکرد SDP به صورت موفقیت آمیزی در فرآیندهای مختلف صنعتی مورد استفاده قرار گرفتند [۲۰-۱۴].

فرآیند شیمیایی شرکت ایستمن در سال ۱۹۹۳ توسط داونز و وگل [۲۱] برای آزمودن روش‌های جدید کنترل فرآیند مطرح شد. شرکت شیمیایی ایستمن با شبیه سازی فرآیند تنسی ایستمن[12] (TEP) امکان طراحی و ارزیابی روش‌های کنترل و نظارت فرآیند را بر روی مدلی از یک فرآیند صنعتی واقعی محقق نمود. پس از آن مطالعات گسترده ای در زمینه‌های مختلف از جمله طراحی حسگر نرم داده محور بر روی این فرآیند انجام گردید.

جی و سونگ [۲۲] یک مطالعه مقایسه‌ای از سه روش مختلف یادگیری بهنگام[13](JITL) براساس حداقل مربعات جزئی (PLS)، رگرسیون بردار پشتیبان (SVR) و حداقل مربعات رگرسیون بردار پشتیبان (LSSVR) به منظور مدل‌سازی حسگر نرم برای فرآیند تنسی ایستمن انجام دادند. گربیک و همکارانش [۲۳] یک روش تطبیقی برای حسگر نرم برای پیش‌بینی آنلاین و نظارت بر فرآیند براساس ترکیبی از مدل‌های گوسی ارائه کردند. نتایج بدست آمده با استفاده از فرآیند معیار تنسی ایستمن نشان داد که مدل حسگر پیشنهاد شده، دقت کمتری نسبت به مدل PCA بازگشتی دارد، اما این مدل نیازمند متغیرهای فرآیندی کمتری است. یان و همکاران [۲۴] یک روش جدید مدل‌سازی حسگر نرم مبتنی بر رگرسیون ترکیبی گاوسی[14] (GMR) برای پیش‌بینی کیفیت در فرآیندهای چند مرحله‌ای و چندفازی معرفی کردند. عملکرد روش پیشنهادی در فرآیند تنسی ایستمن حاکی از عملکرد موثرتر مدل GMR در در پیش‌بینی کیفیت در مقایسه با مدل ترکیبی گاوسی مبتنی بر کمینه مربعات جزئی[15] (GMM-PLS) است.

هی و همکاران [۲۵] یک مدل ماشین یادگیری افراطی موازی دوگانه با ضریب همبستگی پیرسون[16] (PCC) مبتنی بر زیر شبکه مستقل (PCCIS-DPELM[17]) برای مدل سازی دقیق فرآیندهای شیمیایی پیچیده ارائه کردند. مدل PCCIS-DPELM بر روی فرآیند تنسی ایستمن پیاده گردید و نتایج خطای پیش‌بینی کمتری نسبت به مدل‌های DPELM و ELM نشان داد. علاوه بر این، در مقایسه با مدل DPELM و مدل ELM، مدل پیشنهادی با ساختار ساده و پاسخ سریع توانست به عملکرد مطلوب-تری دست یابد.

دانگ و کین [۲۶] روش کمینه مربعات جزئی درونی پویا[18] (DiPLS) را برای مدل‌سازی پویا فرآیندها ارائه کردند. نتایج پیاده‌سازی مدل پیشنهادی بر روی فرآیند تنسی ایستمن نشان داد که وقتی ارتباطات پویا در داده‌ها وجود دارد، مدل‌سازی داده‌ها با روش DiPLS در مقایسه با روش مدل‌سازی PLS کارآمدتر است. کین و همکاران [۲۷] الگوریتم جدید رگرسیون ترکیبی تدریجی وابسته به کیفیت[19] (QSFR) را به عنوان پایه حسگر نرم ارائه دادند. نتایج این مدل در مقایسه با روش رگرسیون ترکیبی تدریجی (SFR) و PLS بر روی فرآیند تنسی ایستمن پیش‌بینی-های بهتری را گزارش کرد.

گوا و همکاران [۲۸] یک مدل حسگر نرم مبتنی بر رمزگذار خودکار متغیر گاوسی[20] (GMVAE) تحت چارچوب یادگیری به‌موقع[21] (JITL) توسعه دادند که بتواند بر روی داده های صنعتی با ابعاد بالا، غیر خطی و چند وجهی اعمال گردد. اثربخشی روش پیشنهادی از طریق پیاده سازی بر روی فرآیند معیار تنسی ایستمن مورد تایید قرار گرفت. ژانگ و همکاران [۲۹] یک مدل حسگر نرم برای پیش بینی کیفیت مبتنی بر ماشین ماتریس

[1] Over-fitting
[2] Support vector regression
[3] Recursive least squares
[4] Hyper-parameter
[5] Filtering
[6] Time varying parameter
[7] State dependent parameter
[8] Multi state-dependent parameter models
[9] Local instrumental variable
[10] Weighted least squares
[11] Interpolation
[12] Tennessee Eastman Process
[13] Just in Time Learning
[14] Gaussian Mixture Regression
[15] Gaussian Mixture Model
[16] Pearson Correlation Coefficient
[17] Double Parallel Extreme Learning Machine with Pearson Correlation Coefficient based Independent Subnets
[18] Dynamic inner PLS
[19] Quality-relevant slow feature regression
[20] Gaussian mixture Variational Autoencoder
[21] Just-in-time learning

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

پشتیبان چند کلاسه[1] (MSMM) به همراه تکنیک بگینگ-اسمت[2] و یک روش تحلیل حساسیت براساس تغییر شکل منحنی پیشنهاد نمودند. سپس، حسگر پیشنهادی بر روی فرآیند تنسی ایستمن اعمال گردید و شاخص‌های عملکردی قابل قبولی حاصل گردید.

لی و همکاران [۳۰] یک روش مدلسازی حسگر نرم جدید به نام رگرسیون بردار پشتیبان گروهی نیمه نظارت شده[3] (SSESVR) توسط ترکیب یادگیری نیمه نظارت شده با یادگیری گروهی پیشنهاد کردند. تأیید اثربخشی و برتری روش SSESVR پیشنهادی بر روی فرآیند تنسی ایستمن انجام شد. یو و همکاران [۳۱] براساس تحلیل علیت و یادگیری پایدار، حسگرهای نرم برای پیش‌بینی پایدار متغیرهای کیفیت و دشوار اندازه‌گیر پیشنهاد نمودند. اثربخشی روش پیشنهادی در فرآیند معیار تنسی ایستمن نشان داده شد و نتایج خوبی بدست آمد.

به جهت پرداخت به خاصیت غیرخطی بودن، رفتار متغیر با زمان، و کمبود برچسب در داده‌های فرآیندی، وانگ و همکاران [۳۲] یک حسگر نرم مبتنی بر خوشه‌بندی برخط پویا[4] (ODCSS) برای سیستم‌های با داده نیمه‌نظارت‌شده صنعتی پیشنهاد کردند. نتایج کاربرد این روش بر روی فرآیند تنسی ایستمن نشان داد که رویکرد حسگر نرم ODCSS پیشنهادی نسبت به حسگرهای نرم متداول در یک محیط یکسان عملکرد بهتری دارد. به منظور مقابله با این مشکلات، کوسول سونگ تاوی و همکاران [۳۳] یک حسگر نرم بر اساس زیر مجموعه‌های ضریب همبستگی تطابق ادغام شده با ماشین یادگیری افراطی آزاد معکوس موازی (CCCS-PIFELM) برای فرآیندهای شیمیایی چند متغیره پیشنهاد کردند. به منظور ارزیابی عملکرد پیش‌بینی رویکرد CCCS-PIFELM، فرآیند معیار تنسی ایستمن به عنوان مطالعه موردی برای پیش‌بینی ترکیبات محصول استفاده شد. با توجه به نتایج شبیه‌سازی، رویکرد CCCS-PIFELM پیشنهادی می‌تواند دقت پیش‌بینی بالاتری را در مقایسه با رویکردهای سنتی به دست آورد. شن و همکاران [۳۳] یک مدل حسگر نرم مبتنی بر رگرسیون رمزگذار خودکار متغیر β خود وزنی[5] (SW-β-VAER) برای نظارت و اندازه‌گیری فرآیندهای صنعتی با شرایط چند حالته توسعه دادند مدل پیشنهادی بر روی واحد صنعتی تنسی ایستمن پیاده‌سازی گردید و مقایسه نتایج اثربخشی و برتری آن را نسبت به سایر روش‌ها نشان داد.

همانطور که از ارزیابی مطالعات پیشین بر روی فرآیند تنسی ایستمن مشخص است، در سال‌های اخیر تکنیک‌های متعددی به منظور طراحی حسگر نرم داده محور با هدف پیش‌بینی بر خط و نظارت بر این فرآیند ارائه شده است. با این حال، برای چنین فرآیندهای پیچیده صنعتی، ارائه تکنیک های نوآورانه ضروری است. با توجه به قابلیت‌هایی روش شناسایی و مدل‌سازی وابسته به متغیر حالت، انتخاب این روش شناسایی برای تخمین کیفیت اجزاء در فرآیندهای که رفتاری پیچیده و نامشخص دارند، می‌تواند منجر به طراحی و توسعه حسگرهای نرم محور با بکارگیری متغیرهای ورودی محدودتر و قابلیت پیش‌بینی مطلوب‌تر گردد. لذا، هدف از این پژوهش، استفاده از رویکرد LIV در طراحی حسگر نرم داده محور به منظور پیش‌بینی متغیرهای کیفیت در فرآیند تنسی ایستمن است. به موازات طراحی مدل حسگر، شناسایی متغیرهای تأثیرگذار بر متغیرهای نهایی انجام گرفته تا مدلی با ساختار ساده و خطی ارائه گردد که از لحاظ مدت زمان محاسبات و پردازش مدل در مقایسه با سایر مدل های ارائه شده، زمان محاسبات و خطای پیش بینی کمتری داشته باشد.

۲- تئوری روش شناسایی مدل‌های LIV

فرض کنید مدل‌سازی مبتنی بر داده برای یک سیستم غیرخطی، یک مدل با پارامترهای وابسته به حالت را در هر نمونه زمانی t، مانند رابطه زیر پیشنهاد می‌دهد [۱۳و۱۸].

$$\begin{cases} y_t = \sum_{i=1}^{n} a_{i,t} \cdot z_{i,t} + e_t \\ a_{i,t} = a_i\left(x_{1,i,t}, x_{2,i,t}, \ldots, x_{ns_i,i,t}\right) \end{cases} \quad , \quad \forall t \qquad (۱)$$

که در آن y_t خروجی مدل، n تعداد پارامترها/رگرسورها، $z_{i,t}$ رگرسور iام و $a_i(\cdot)$ پارامتر وابسته به حالت iام است که تابعی از ns_i حالت‌های متناظر ($x_{j,i,t}$, $j = 1,2,\ldots,ns_i$) می‌باشد. زمانی که فرض می‌شود $a_{i,t}$ ثابت باشد و تابع هیچ متغیر حالتی نیست، $ns_i = 0$ خواهد بود. $e_t = N\left(0,\sigma^2\right)$ خطای ناشناخته سفید با متوسط صفر، توزیع گاوسی و واریانس σ^2 است. در تکنیک LIV مفاهیم مدل‌سازی چندجمله‌ای با مفهوم متغیر سودمند مورد استفاده قرار گرفته‌اند تا یک روش تخمین پارامترها را به طوری که به طور همزمان آن‌ها را تخمین بزند، بدست دهد. اگر فرض شود که عملکرد هر پارامتر وابسته به حالت نسبت به حالت‌های متناظر آن می‌تواند توسط چند جمله‌ای محلی در فضای متغیر حالت تعریف شود، در نتیجه تخمین محلی پارامترهای این چند جمله‌ای‌ها با بکارگیری روش متغیر سودمند امکان‌پذیر خواهد بود. با این فرض، $a_{i,t}$ می‌تواند به صورت زیر تعریف گردد [۱۳و۱۸].

$$a_{i,t} = \mathbf{S}_{i,t}\mathbf{A}_{i,t} \quad i = 1,2,\ldots,n \qquad (۲)$$

که در آن $\mathbf{A}_{i,t}$ بردار پارامترهای ثابت محلی چند جمله‌ای توصیف کننده $a_{i,t}$ است و $\mathbf{S}_{i,t}$ توسط رابطه (۳) بیان می‌شود.

$$\begin{aligned} &\mathbf{S}_{i,t} = \mathbf{S}_{0,i,t} \otimes \mathbf{S}_{1,i,t} \otimes \mathbf{S}_{2,i,t} \otimes \cdots \otimes \mathbf{S}_{ns_i,i,t} \quad , \quad i = 1,2,\ldots,n \\ &\mathbf{S}_{j,i,t} = \begin{bmatrix} 1 & x_{j,i,t} & x_{j,i,t}^2 & \cdots & x_{j,i,t}^{q_{j,i}} \end{bmatrix} \quad , \quad j = 0,1,2,\ldots,ns_i \\ &q_{0,i} = 0 \end{aligned} \qquad (۳)$$

نماد $\otimes$، نماد ضرب تانسوری کرونکر[6] است و $q_{j,i}$ درجه چند جمله‌ای توصیف کننده $a_{i,t}$ با توجه به $x_{j,i,t}$ است. تعداد پارامترها در $\mathbf{A}_{i,t}$ توسط رابطه زیر بدست می‌آید.

$$p_i = \prod_{j=0}^{ns_i}\left(1 + q_{j,i}\right) \qquad (۴)$$

[1] Multiclass support matrix machine
[2] Bagging-SMOTE technique
[3] Semi-supervised ensemble support vector regression
[4] Online-dynamic-clustering-based soft sensor
[5] Self-weighted β variational autoencoder regression
[6] Kronecker tensor product

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

تمامی عضوهای $\mathbf{A}_{i,t}$ توابع وابسته به حالت‌های $x_{j,i,t}$, $j=1,2,\ldots,ns_i$ هستند. با جایگزین نمودن از رابطه (۲)، مدل ارائه شده در رابطه (۱) به فرم برداری زیر تبدیل می‌شود.

$$y_t = \mathbf{z}_t \mathbf{A}_t + e_t \qquad (۵)$$

که در آن $\mathbf{A}_t$ بردار پارامترهای چندجمله‌ای‌های محلی توصیف کننده پارامترهای وابسته به حالت و $\mathbf{z}_t$ بردار جدید رگرسورها در نمونه زمانی t است که به صورت زیر تعریف می‌شود [۱۳و۱۸].

$$\mathbf{z}_t = \begin{bmatrix} z_{1,t}\mathbf{S}_{1,t} & z_{2,t}\mathbf{S}_{2,t} & \cdots & z_{n,t}\mathbf{S}_{n,t} \end{bmatrix} \qquad (۶)$$

با تعریف $\mathbf{Z} = \begin{bmatrix} \mathbf{z}_1^T & \mathbf{z}_2^T & \mathbf{z}_3^T & \cdots \end{bmatrix}^T = \begin{bmatrix} \mathbf{Z}_1 & \mathbf{Z}_2 & \cdots & \mathbf{Z}_p \end{bmatrix}$، که در آن $p = \sum_{i=1}^{n} p_i$ بیان‌کننده‌ی تعداد رگرسورها در $\mathbf{z}_t$ یا به صورت معادل برابر تعداد تمام پارامترهای مدل در $\mathbf{A}_t$ است. اگر $\mathbf{y} = \begin{bmatrix} y_1 & y_2 & y_3 & \cdots \end{bmatrix}^T$ باشد، سپس راه حل تخمین IV در رابطه (۵) در نمونه k ام می‌تواند به شکل زیر نوشته شود.

$$\hat{\mathbf{A}}_k = \left(\mathbf{U}_k^T \mathbf{Z}\right)^{-1} \mathbf{U}_k^T \mathbf{y} \qquad (۷\text{–الف})$$

$$\mathbf{P}_k = \hat{\sigma}_k^2 \left(\mathbf{U}_k^T \mathbf{Z}\right)^{-1} \left(\mathbf{U}_k^T \mathbf{U}_k\right) \left(\mathbf{Z}^T \mathbf{U}_k\right)^{-1} \qquad (۷\text{–ب})$$

$$\hat{\sigma}_k^2 = \mathrm{var}\left(\mathbf{y} - \mathbf{Z}\hat{\mathbf{A}}_k\right) \qquad (۷\text{–ج})$$

$\mathbf{P}_k$ ماتریس کوواریانس تخمین پارامتر وابسته به حالت است، $\hat{\mathbf{A}}_k$ در نمونه k ام و $\mathbf{U}_k$ همانطور که در رابطه (۸) تعریف شده است، نقش ماتریس IV در آن نمونه را ایفا می‌کند که اصطلاحاً متغیر سودمند محلی (LIV) نامیده می‌شود.

$$\mathbf{U}_k = \begin{bmatrix} \mathbf{U}_{1,k} & \mathbf{U}_{2,k} & \cdots & \mathbf{U}_{p,k} \end{bmatrix} \qquad (۸)$$

$\mathbf{U}_{m,k}$ متغیر سودمند محلی متناظر با $\mathbf{Z}_m$ برای هر $m = 1,2,\ldots,p$ است. متغیر سودمند ایده‌آل انتخاب شده برای تخمین پارامتر، متغیر سودمندی است که با رگرسورهای غیرمتناظر در ارتباط نمی‌باشد. این به این دلیل است که درایه‌های خارج از قطر $\mathbf{U}_k^T\mathbf{Z}$ توسط $\mathbf{U}_k$ برابر صفر قرار داده می‌شود و در نتیجه $\mathbf{U}_k^T\mathbf{Z}$ یک ماتریس قطری خواهد بود و این سبب می‌گردد که تخمین هر پارامتر وابسته به حالت تحت تأثیر تخمین سایر پارامترها قرار نمی‌گیرد. بنابراین تخمین همزمان پارامترها در فضاهای متغیر حالت خودشان بدون نیاز به برگشت متناسب امکان‌پذیر است. با استفاده از ماتریس LIV پیشنهاد شده، پارامترهای تخمین زده شده در رابطه (۷) پس از آن می‌تواند به سادگی زیر فرمول بندی گردد [۱۳و۱۸].

$$\hat{\mathbf{A}}_k = \mathbf{U}_k^T \mathbf{y} \qquad (۹\text{–الف})$$

$$\mathbf{P}_k = \hat{\sigma}_k^2 \left(\mathbf{U}_k^T \mathbf{U}_k\right) \qquad (۹\text{–ب})$$

ماتریس وزنی محلی، $\mathbf{W}_{m,k}$، برای برخورد با برخی الزامات در مدل می‌تواند به طور کلی تعریف شود. یک تعریف ساده از ماتریس وزنی محلی در تخمین پارامتر وابسته به حالت می‌تواند یک ماتریس قطری باشد که درایه‌های قطری آن مقادیر تابع کرنل متناظر با iامین پارامتر وابسته به حالت در نمونه k ام است. به عنوان نمونه $\mathbf{W}_{m,k}$ به صورت زیر تعریف می‌شود.

$$\begin{cases} \mathbf{W}_{m,k} = diag\left(K\left(\Delta_{i,k,t}\right)\right) \\ \Delta_{i,k,t} = \sum_{j=1}^{ns_i} \left(\dfrac{x_{j,i,t} - x_{j,i,k}}{\lambda_{j,i}} \right)^2 \end{cases} \quad \begin{cases} \forall t \\ 0 < \sum_{v=1}^{i-1} p_v < m \le \sum_{v=1}^{i} p_v \end{cases} \qquad (۹)$$

$K(\cdot)$ تابع چگالی کرنل[1] و $\lambda_{j,i}$ پهنای باند متناظر با $x_{j,i,t}$ است که به عنوان اَبَر پارامتر[2] شناخته می‌شود. معیار پهنای باند در مدل‌های LIV نظیر یک شاخص آنالیز حساسیت عمل می‌نماید. به طوری‌که هر چه میزان پهنای باند بیشتر باشد یا به عبارت دیگر به سمت بی‌نهایت میل کند، کرنل هموارتر می‌شود و تقریباً وزن یکسانی به داده‌های کنار هم می‌دهد که نشان دهنده این است که کرنل، تفاوت زیادی بین داده‌ها قائل نمی‌شود. در این حالت خطا زیاد شده و عدم قطعیت پایین می‌آید و میزان نوسان در شناسایی پارامتر کمتر می‌گردد. در مقابل پهنای باند کمتر، به نقطه اوج کرنل وزن بیشتری داده و خطا در آن نقطه را کمینه می‌نماید که سبب بالا رفتن عدم قطعیت می‌گردد. در این حالت میزان نوسان در شناسایی پارامتر بیشتر می‌شود، به همین جهت می‌بایست مقادیر بهینه پهنای باند تعیین گردد. بهینه‌سازی پهنای باندها به دو روش بهینه‌سازی بیشینه احتمال[3] (ML) و اعتبار سنجی متقابل[4] قابل انجام است. تابع چگالی کرنل براساس نوع داده‌ها و نحوه تغییرات متغیر حالت می‌تواند به شش فرم تابع یکنواخت[5] (UF)، تابع اپانچنیکوف[6] (EP)، تابع وزنی-دوگانه[7] (BW)، تابع وزنی-سه‌گانه[8] (TW)، تابع مکعبی-سه گانه[9] (TC) و تابع گاوسی نرمال[10] (NG) در نظر گرفته شود. با جایگزین کردن $\hat{\mathbf{A}}_k$ تخمین زده شده در رابطه (۲)، تخمین پارامتر و کوواریانس آن در نمونه k ام به صورت زیر حاصل می‌گردد [۱۳و۱۸].

$$\begin{cases} \hat{\mathbf{a}}_k = \mathbf{S}_k \hat{\mathbf{A}} \\ \mathrm{cov}\left(\hat{\mathbf{a}}_k\right) = \mathbf{S}_k \mathbf{P} \mathbf{S}_k^T \end{cases} \qquad (۱۱۱۰)$$

$\hat{\mathbf{a}}_k$ و $\mathbf{S}_k$ به صورت روابط (۱۲) و (۱۳) بیان می‌شوند که در آن‌ها $\mathbf{0}$ ، بردار صفر است.

[1] Kernel Density Function
[2] Hyper parameter
[3] Maximum Likelihood
[4] Cross-Validation
[5] UniForm function
[6] Epanechnikov function
[7] Bi-Weight function
[8] Tri-Weight function
[9] Tri-Cube function
[10] Normal Gaussian function

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

$$\hat{\mathbf{a}}_k = \begin{bmatrix} \hat{a}_{1,k} & \hat{a}_{2,k} & \cdots & \hat{a}_{n,k} \end{bmatrix}^T \quad (۱۲۱۱)$$

$$\mathbf{S}_k = \begin{bmatrix} \mathbf{S}_{1,k} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{S}_{2,k} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{S}_{n,k} \end{bmatrix} \quad (۱۳)$$

۳- شرح فرآیند تنسی ایستمن

همانطور که در شکل (۱) نشان داده شده است، فرآیند تنسی ایستمن شامل پنج واحد عملیاتی اصلی رآکتور[1]، چگالنده[2] محصول، جداکننده مایع/بخار[3]، کمپرسور[4] جریان برگشتی و عریان‌ساز[5] محصول می‌باشد. در این فرآیند مواد واکنش‌دهنده A، C، D، E و ماده بی اثر B در حالت گازی به عنوان خوراک وارد راکتور می‌شوند و محصولات G و H به صورت مایع در مسیر خروجی تشکیل می‌شود. ماده F نیز به صورت محصول جانبی واکنش‌ها در فرآیند تولید می‌شود. روابط شیمیایی حاکم بر واکنش‌ها در ادامه بیان شدند.

$A(g) + C(g) + D(g) \rightarrow G(liq)$ محصول اول، (۱۴-الف)

$A(g) + C(g) + E(g) \rightarrow H(liq)$ محصول دوم، (۱۴-ب)

$A(g) + E(g) \rightarrow F(liq)$ محصول جانبی، (۱۴-ج)

$3D(g) \rightarrow 2F(liq)$ محصول جانبی، (۱۴-د)

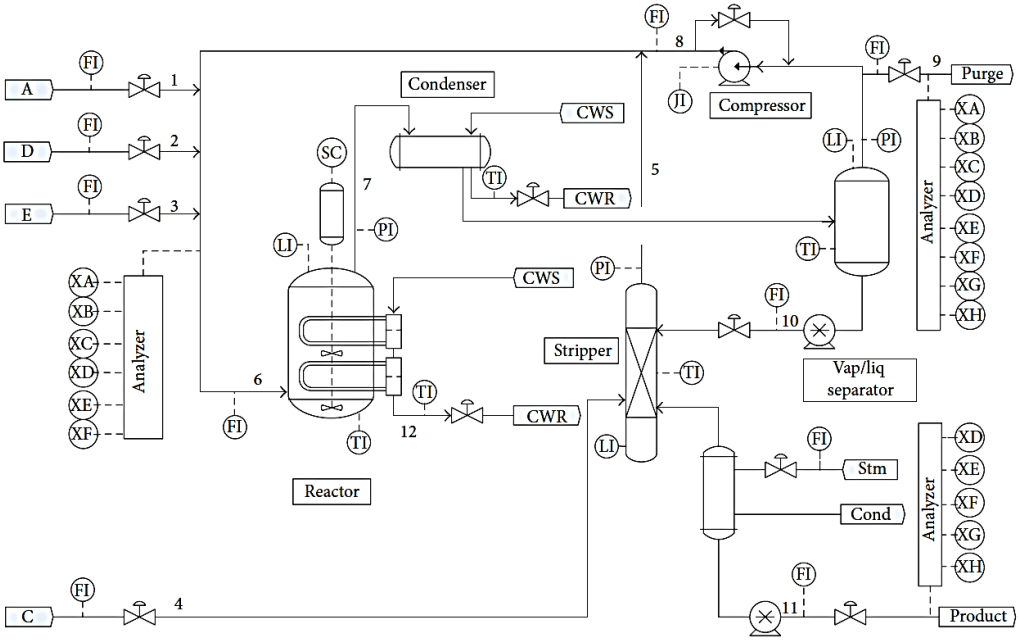

شکل ۱. نمودار جریان فرآیند تنسی ایستمن [۳۵]

نرخ واکنش‌ها براساس رابطه‌ی آرنیوس تابعی از دما است. هم‌چنین واکنش‌ها برگشت‌ناپذیر و گرمازا می‌باشند. واکنش تولید محصول G دارای انرژی فعالیت بیشتری نسبت به واکنش تولید محصول H بوده و در نتیجه به دما حساس تر است. خوراک فرآیند به صورت گاز و کاتالیست مورد استفاده قابل حل در فاز مایع و غیر فرار است. محصول بصورت فاز گاز رآکتور را ترک کرده و پس از عبور از چگالنده و جداکننده مایع/بخار، محصولات به صورت فاز مایع از مواد اولیه‌ی تبدیل نشده که به صورت فاز گاز هستند، جدا می‌شوند. جریان گازی مواد اولیه تبدیل نشده قبل از ورود به رآکتور از کمپرسور جریان برگشتی عبور می‌کند. محصولات به برج عریان‌ساز محصول خورانده می‌شوند و مواد مورد نظر G و H که محصولات فرآیند هستند از پایین برج گرفته می‌شوند، هم‌چنین مواد F و B از بالای برج به صورت بخار برای زدایش[6] فرستاده می‌شوند. این فرآیند دارای ۴۱ متغیر قابل اندازه‌گیری[7] یا خروجی‌های فرآیند و ۱۲ متغیر قابل تنظیم[8] است. مشخصات متغیرهای قابل تنظیم در جدول (۱) آورده شده است.

۱۹ از بین ۴۱ متغیر قابل اندازه‌گیری، ۲۲ متغیر که به صورت XMEAS(1) تا XMEAS(22) معرفی شدند، متغیرهای آسان اندازه‌گیر هستند و در شبیه سازی هر ۰/۰۳ دقیقه یک بار نمونه برداری می‌شوند. در جدول (۲) توصیف این متغیرها آورده شده است. متغیر دیگر که به صورت XMEAS(23) تا XMEAS(41) نشان داده شدند، متغیرهای دشوار

[1] Reactor
[2] Condenser
[3] Vapor/liquid separator
[4] Compressor
[5] Stripper
[6] Purge
[7] Measurement Variable
[8] Manipulated Variable

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

اندازه‌گیر فرآیند هستند، که توسط آنالیز کروماتوگرافی بر روی خطوط جریان ۶، ۹ و ۱۱ بدست می‌آیند.

جدول ۱. متغیرهای قابل تنظیم [۲۱]

متغیر	توصیف متغیر
XMV(1)	جریان خوراک D (خط جریان ۲)
XMV(2)	جریان خوراک E (خط جریان۳)
XMV(3)	جریان خوراک A (خط جریان۱)
XMV(4)	جریان خوراک A و C (خط جریان۴)
XMV(5)	شیر کمپرسور برگشتی
XMV(6)	شیر زدایش
XMV(7)	جریان مایع جداساز (خط جریان۱۰)
XMV(8)	جریان محصول مایع عریان‌ساز (خط جریان ۱۱)
XMV(9)	شیر بخار عریان‌ساز
XMV(10)	جریان آب خنک کننده رآکتور
XMV(11)	جریان آب خنک کننده کمپرسور
XMV(12)	سرعت همزن

جدول ۲. متغیرهای آسان اندازه‌گیر [۲۴]

متغیر	واحد	توصیف متغیر
XMEAS(1)	kscmh	خوراک A (خط جریان ۱)
XMEAS(2)	$kg\ h^{-1}$	خوراک D (خط جریان ۲)
XMEAS(3)	$kg\ h^{-1}$	خوراک E (خط جریان ۳)
XMEAS(4)	kscmh	خوراک A و C (خط جریان ۴)
XMEAS(5)	kscmh	جربان برگشتی (خط جریان ۸)
XMEAS(6)	kscmh	نرخ خوراک راکتور (خط جریان ۶)
XMEAS(7)	kPa	فشار راکتور
XMEAS(8)	%	سطح راکتور
XMEAS(9)	°C	دمای راکتور
XMEAS(10)	kscmh	نرخ زدایش (خط جریان ۹)
XMEAS(11)	°C	دمای جداساز محصول
XMEAS(12)	%	سطح جداساز محصول
XMEAS(13)	kPa	فشار جداساز محصول
XMEAS(14)	$m^3 h^{-1}$	جریان پایین جداساز محصول (خط جریان ۱۰)
XMEAS(15)	%	سطح عریان‌ساز
XMEAS(16)	kPa	فشار عریان‌ساز
XMEAS(17)	$m^3 h^{-1}$	جریان پایین عریان‌ساز (خط جریان ۱۱)
XMEAS(18)	°C	دمای عریان‌ساز
XMEAS(19)	$kg\ h^{-1}$	جریان بخار عریان‌ساز
XMEAS(20)	kW	کار کمپرسور
XMEAS(21)	°C	دمای خروجی آب خنک کننده کمپرسور
XMEAS(22)	°C	دمای خروجی آب خنک کننده جداساز

مقادیری که از خطوط جریان ۶ و ۹ بدست می‌آیند دارای تأخیر زمانی و زمان نمونه برداری ۶ دقیقه‌ای هستند در حالی‌که متغیرهای اندازه‌گیری شده از خط جریان ۱۱ دارای تأخیر زمان نمونه‌برداری ۱۵ دقیقه هستند. در جدول ۳ توصیف متغیرهای دشوار اندازه‌گیر آورده شده است.

در این پژوهش متغیر XMEAS(29) (غلظت جزء A در خط جریان ۹) و متغیر XMEAS(38) (غلظت جزء E در خط جریان ۱۱) به عنوان متغیرهای خروجی و ۲۲ متغیر آسان اندازه‌گیر به عنوان ورودی‌های برای توسعه حسگر نرم در نظر گرفته شدند [۲۱].

جدول ۳. متغیرهای دشوار اندازه‌گیر [۲۴]

خط جریان	متغیر	واحد	نام ماده مربوطه
۶	XMEAS(23)	%mol	A
۶	XMEAS(24)	%mol	B
۶	XMEAS(25)	%mol	C
۶	XMEAS(26)	%mol	D
۶	XMEAS(27)	%mol	E
۶	XMEAS(28)	%mol	F
۹	XMEAS(29)	%mol	A
۹	XMEAS(30)	%mol	B
۹	XMEAS(31)	%mol	C
۹	XMEAS(32)	%mol	D
۹	XMEAS(33)	%mol	E
۹	XMEAS(34)	%mol	F
۹	XMEAS(35)	%mol	G
۹	XMEAS(36)	%mol	H
۱۱	XMEAS(37)	%mol	D
۱۱	XMEAS(38)	%mol	E
۱۱	XMEAS(39)	%mol	F
۱۱	XMEAS(40)	%mol	G
۱۱	XMEAS(41)	%mol	H

٤- مراحل طراحی حسگر نرم داده محور

۴-۱- انتخاب داده‌های فرآیند

در مرحله اول می بایست داده‌های مورد نیاز برای طراحی حسگر نرم داده محور فراهم گردد. در این پژوهش از مجموعه داده معیار[1] ارائه شده توسط راسل و همکاران [۳۶] برای فرآیند تنسی ایستمن استفاده شده است. این داده‌ها در شرایط عملیاتی نرمال فرآیند جمع آوری شده اند و شامل ۱۴۶۰ نمونه است. این مجموعه داده به دو بخش؛ بخش اول حاوی ۵۰۰ نمونه داده‌های آموزش مدل و بخش دوم حاوی ۹۶۰ نمونه داده‌های آزمون تقسیم شده است.

[1] Benchmark dataset

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

۴-۲- انتخاب متغیرها

در دسترس بودن تمامی متغیرها در پایگاه داده‌های واحد به این معنی نیست که همه آن‌ها بر متغیر خروجی تأثیرگذار هستند. لذا انتخاب دقیق و مناسب متغیرهای ورودی مدل حسگر نرم عملکرد حسگر را بهبود می‌بخشد. بعلاوه تعدد متغیرهای ورودی می‌تواند سبب ایجاد بیش‌برازش داده‌های آموزش و کاهش صحت عملکرد پیش‌بینی مدل شود. در نتیجه، انتخاب متغیرها یکی از گام‌های اساسی در توسعه‌ی حسگر نرم داده محور است و به طور مستقیم با دقت پیش‌بینی حسگر ارتباط دارد [۳۷و۳۸] . روش مدل‌سازی LIV که به عنوان روش پایه طراحی حسگر نرم در این پژوهش مورد استفاده قرار گرفته است، در مرحله آموزش داده علاوه بر بدست آوردن مدل حسگر، به طور همزمان قادر به شناسایی متغیرهای تأثیر گذار بر روی متغیر کیفیت خروجی می‌باشد.

۴-۳- شناسایی مدل و تخمین پارامترهای مدل

شناسایی مدل، فرآیند طراحی مدل براساس داده‌های آموزش است. این مرحله شامل انتخاب ساختار مدل و بهینه‌سازی پارامترهای آن است. مراحل آموزش مدل حسگر نرم بر مبنای روش LIV و نحوه‌ی تعیین ساختار و متغیرهای موثر آن با استفاده از دیاگرام شماتیک در شکل (۲) نشان داده شده است.

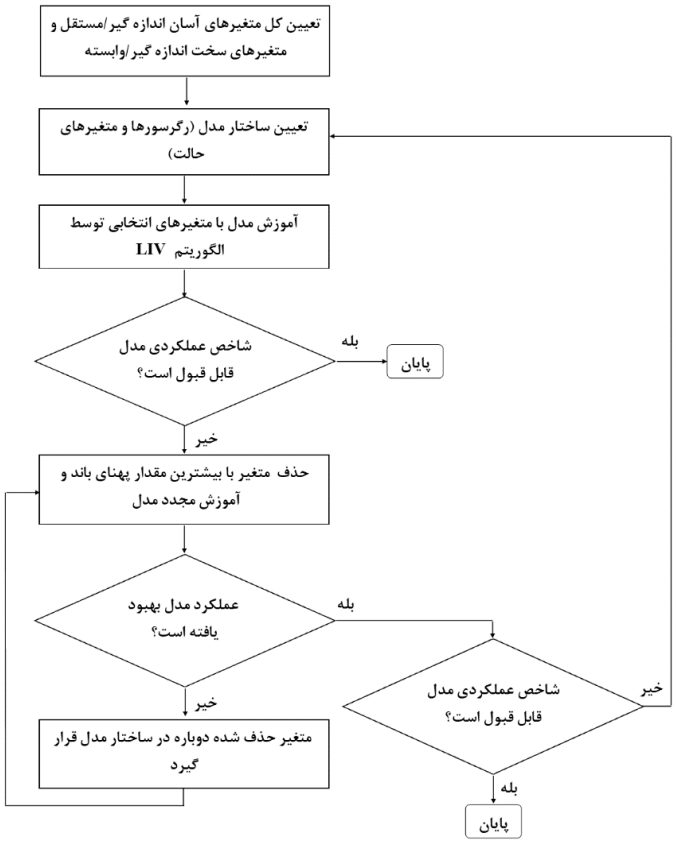

شکل ۲. دیاگرام شماتیک آموزش مدل حسگر نرم براساس روش LIV و تعیین متغیرهای مؤثر

در این پژوهش برای انتخاب بهترین مدل از بین ساختارهای بدست آمده از معیار اطلاعاتی بیزین[1] (BIC) و معیار اطلاعاتی آکائیک[2] (AIC) براساس تابع لگاریتم بیشینه احتمالات استفاده شده است.

۴-۳-۱- معیار اطلاعاتی بیزین

معیار اطلاعاتی بیزین (BIC) معیاری برای انتخاب مدل از بین تعداد متناهی مدل است. در این روش مدلی که دارای BIC کمتری باشد، ترجیح داده می‌شود. این معیار براساس تابع احتمال[3] تعیین می‌شود. در حین برازش مدل‌ها، می‌توان تابع احتمال را با اضافه کردن پارامترهایی افزایش داد اما این کار باعث بیش برازش می‌شود. بیش برازش زمانی رخ می‌دهد که مدل آماری بجای کمیت اصلی، نویزها و یا خطاهای تصادفی را توصیف می‌کند. در BIC این مشکل توسط یک جمله جریمه[4] برطرف می‌شود. معیار اطلاعاتی بیزین به صورت رابطه (۱۵) تعریف می‌شود [۳۹].

$$\mathrm{BIC} = -2\ln(\hat{L}) + k.\ln(n) \qquad (۱۵۱۲)$$

[1] Bayesian Information Criterion
[2] Akaike Information Criterion
[3] Likelihood Function
[4] Penalty Term

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

در این رابطه n تعداد مشاهدات، k تعداد پارامترهای مدل و $\hat{L}$ مقدار تابع بیشینه احتمال مدل است. این روش دارای معایبی نیز است از جمله این‌که رابطه فوق فقط به‌ازای نمونه‌هایی که در آن‌ها اندازه نمونه n بسیار بزرگتر از تعداد پارامترهای k است، معتبر است [۴۰].

۴-۳-۲- معیار اطلاعاتی آکائیک

معیار اطلاعاتی آکائیک (AIC) اندازه‌ای از کیفیت نسبی مدل‌های آماری برای یک مجموعه داده است. با وجود یک سری از مدل‌ها برای داده‌ها AIC کیفیت هر مدل را نسبت به دیگر مدل‌ها برآورد می‌کند. در تئوری اطلاعات AIC برآوردی نسبی از اطلاعات از دست‌رفته در اثر استفاده از یک مدل موجود برای فرآیند داده‌ها، پیشنهاد می‌کند. برای انجام این کار از مقایسه بین خوبی برازش مدل و پیچیدگی مدل استفاده می‌شود. نکته اینجاست که AIC معیاری برای کیفیت مطلق مدل ندارد، به طور مثال اگر تمامی مدل‌ها به‌طور ضعیفی برازش داده شده باشند، AIC نمی‌تواند هشداری در این زمینه بدهد. مقدار AIC طبق رابطه (۱۶) محاسبه می‌شود [۴۱و۴۲].

$$\mathrm{AIC} = 2k - 2\ln(\hat{L}) \qquad (۱۶۱۳)$$

در اینجا نیز k تعداد پارامترهای مدل و $\hat{L}$ مقدار تابع بیشینه احتمال مدل است. با وجود تعدادی مدل پیشنهادی، مدلی ارجح است که کمترین مقدار AIC را داراست.

۴-۴- اعتبار سنجی مدل

به منظور اعتبارسنجی مدل شناسایی شده و بررسی عملکرد آن معیارهای آماری متعددی مورد استفاده قرار گرفت است که در ادامه به آن‌ها اشاره شده است [۴۳]. همبستگی پیرسون[1]- متداول‌ترین معیار اندازه‌گیری همبستگی در آمار- که همبستگی بین مقادیر مشاهده شده و پیش‌بینی شده را ارزیابی می‌کند و توسط رابطه زیر بیان می‌شود:

$$R = \frac{\sum_{i=1}^{N}(\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{N}(\hat{y}_i - \bar{\hat{y}})^2 \sum_{i=1}^{N}(y_i - \bar{y})^2}} \qquad (۱۷۱۴)$$

اعتبارسنجی کمی مدل همچنین می‌تواند با اندازه‌گیری جذر میانگین مربع خطا[2] (RMSE) که متوسط مربع فاصله بین مقدار واقعی و مقدار پیش‌بینی شده توسط مدل را اندازه‌گیری می‌کند، تعیین گردد.

$$\mathrm{RMSE} = \sqrt{\sum_{i=1}^{N}\left(y_i - \hat{y}_i\right)^2 / N} \qquad (۱۸۱۵)$$

یکی دیگر از شاخص‌های کمی، میانگین خطای مطلق[3] (MAE) است.

$$\mathrm{MAE} = \frac{\sum_{i=1}^{N}\left|y_i - \hat{y}_i\right|}{N} \qquad (۱۹)$$

ضریب تعیین[4]، که با R^2 نمایش داده می‌شود، نسبت واریانس متغیر وابسته که قابل پیش‌بینی است را از متغیر(های) مستقل بیان می‌کند. R^2 نشان می‌دهد که به چه میزان نقاط داده پیش‌بینی شده و واقعی با یکدیگر سازگار هستند. ضریب تعیین تعدیل شده[5] (R^2_{adj}) سازگاری مقادیر را با درنظرگرفتن تعداد ترم‌های موجود در مدل نشان می‌دهد.

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{N}(y_i - \bar{y})^2} \qquad (۲۰)$$

$$R^2_{adj} = 1 - \left[\frac{\left(1 - R^2\right)\left(N - 1\right)}{(N - k - 1)}\right] \qquad (۲۱)$$

که در آن‌ها، N تعداد داده‌ها، k تعداد متغیرهای مستقل موجود در مدل و y_i، $\hat{y}_i$، $\bar{y}$ و $\bar{\hat{y}}$ به ترتیب مقدار واقعی، مقدار پیش‌بینی شده، میانگین مقادیر y و میانگین مقادیر $\hat{y}$ است.

۵- نتایج و بحث

در ابتدا ۲۲ متغیر آسان اندازه‌گیر به عنوان ورودی‌های مدل حسگر نرم در نظر گرفته شدند و یک روش ترکیبی برای حذف متغیرهای غیر ضروری از مدل با استفاده از روش حذف پس‌رو و معیار پهنای باند بهینه مدل‌های LIV پیشنهاد گردید. در اینجا برای تعیین مقادیر بهینه پهنای باند از روش بهینه‌سازی بیشینه احتمال (ML) استفاده شده است، هم‌چنین نوع تابع کرنل برای بررسی داده‌ها از نوع تابع گاوسی نرمال فرض شده است.

همانطور که از دیاگرام ارائه شده در شکل (۲) مشخص است، بعد از تعیین کل متغیرها، باید ساختار مدل یا به عبارت دیگر رگرسورها و متغیرهای حالت تعیین شوند. از آنجایی‌که مدل‌های LIV به صورت چند ورودی و تک خروجی هستند، در اینجا نیز شناسایی مدل حسگر نرم برای هر متغیر کیفیت به صورت جداگانه انجام شده است. ساختار مدل LIV بر هر خروجی y_1 (غلظت جزء A) و y_2 (غلظت جزء E) مطابق رابطه (۱) در نظر گرفته شده است. در اینجا تمامی ورودی‌های انتخاب شده که همان ۲۲ متغیر آسان اندازه گیر فرآیند می‌باشند، به عنوان متغیرهای حالت در یک پارامتر در نظر گرفته شده و رگرسور مدل یک فرض شده است. بنابراین رابطه (۱) برای هر متغیر کیفیت فرآیند به شکل زیر بیان می‌شود:

[1] Pearson correlation
[2] Root mean squares error
[3] Mean absolute error
[4] Coefficient of determination
[5] Adjusted coefficient of determination

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

$$y_{1,t} = a_{1,t}\{X_1, X_2, X_3, ..., X_{22}\} \times 1 + e_t \quad (۲۲)$$

$$y_{2,t} = a_{2,t}\{X_1, X_2, X_3, ..., X_{22}\} \times 1 + e_t \quad (۲۳)$$

شناسایی مدل برای هر کدام از متغیرهای خروجی به صورت جداگانه و بر طبق مراحل بیان شده در الگوریتم شکل ۲ انجام گرفت. در هر مرحله پهنای باند ($\lambda_{j,i}$) متناظر با هر متغیر حالت توسط روش بهینه‌سازی بیشینه احتمال تعیین گردید. سپس متغیرهای حالتی که مقدار پهنای باند بدست آمده آن‌ها عدد بسیار بزرگی است یا در مقایسه با مقیاس سایر متغیرهای حالت بزرگ باشد، از مجموعه متغیرهای حالت حذف گردید و دوباره مدل بر مبنای مجموعه متغیرهای حالت جدید آموزش داده شد. درجه چندجمله‌ای محلی برای هر متغیر حالت صفر در نظر گرفته شده است یا به عبارت دیگر نحوه تغییرات متغیر حالت به صورت محلی ثابت فرض می‌شود. در نهایت، پس از چندین مرحله تکرار روش حذف پس‌رو، ساختار مدل با بهترین شاخص‌های عملکردی برای هر دو کیفیت اجزاء بدست می‌آید.

مدل‌های LIV برای پیش‌بینی غلظت جزء A بر طبق الگوریتم شکل ۲ با استفاده از روش سعی و خطا و حذف پس‌رو ساخته شدند که نتایج پیش‌بینی حاصل از مدل‌های آموزش داده شده در هر مرحله با شاخص عملکردی و معیارهای AIC و BIC در جدول ۴ آورده شده است. در هر مرحله با توجه به شاخص‌های عملکردی بدست آمده از نتایج پیش‌بینی مدل مشخص می‌شود که متغیر حذف شده تأثیر قابل توجهی بر میزان دقت مدل دارد یا خیر. در صورتی که دقت مدل با حذف متغیر انتخاب شده به شدت کاهش یابد، وجود آن متغیر در ساختار مدل الزامی است.

جدول ۴. شاخص‌های عملکردی مدل‌های ارائه شده بر روی داده‌های آموزش برای پیش‌بینی غلظت جزء A

شماره	متغیرهای حالت انتخاب شده	تعداد متغیرها	R^2	RMSE	$\ln(\hat{L})$	AIC	BIC
۱	$X_1,X_2,X_3,X_4,X_5,X_6,X_7,X_8,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21},X_{22}$	۲۲	۱	$۲/۶\times۱۰^{-۱۰}$	−۱/۷۹	۴۷/۵۸	۱۴۰/۳
۲	$X_1,X_2,X_4,X_6,X_7,X_8,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{17},X_{19},X_{20},X_{21}$	۱۶	۱	۰/۰۰۴۳	−۱/۷۳۲۹	۳۵/۴۶	۱۰۲/۹
۳	$X_1,X_2,X_6,X_7,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{17},X_{20},X_{21}$	۱۳	۱	۰/۰۲۶۴	−۱/۷۳۲۲	۲۹/۴۶	۸۴/۲۵
۴	$X_1,X_2,X_6,X_7,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{17},X_{20}$	۱۲	۱	۰/۰۱۷۰	−۱/۷۴۳۰	۲۷/۴۸	۷۸/۰۶
۵	$X_1,X_2,X_6,X_7,X_9,X_{10},X_{11},X_{12},X_{17},X_{20}$	۱۰	۰/۹۹۹۹	۰/۱۲۹۲	−۱/۴۴۶۴	۲۲/۸۹	۶۵/۰۳
۶	$X_1,X_2, X_6,X_7,X_9, X_{11},X_{12},X_{17},X_{20}$	۹	۱	۰/۱۰۰۲	−۱/۴۴۷۴	۲۰/۸۹	۵۸/۸۲
۷	$X_1,X_2,X_7,X_9, X_{11},X_{12},X_{17},X_{20}$	۸	۱	۰/۱۲۷۰	−۱/۳۸	۱۸/۷۷	۵۲/۴۸
۸	$X_1,X_2,X_7, X_{11},X_{12},X_{17},X_{20}$	۷	۱	۰/۱۰۷۶	−۱/۴۵	۱۶/۹	۴۶/۴۱
۹	$X_1,X_2,X_7,X_{11},X_{20}$	۵	۰/۹۹۹۴	۰/۱۲۸۲	−۱/۴۳۷۶	۱۲/۸۷	۳۳/۹۴
۱۰	X_1,X_7,X_{11},X_{20}	۴	۰/۹۹۹۳	۰/۱۲۷۹	−۱/۴۳۷۷	۱۰/۸۷	۲۷/۷۳
۱۱	X_1,X_7,X_{20}	۳	۰/۸۲۸۶	۰/۱۵۷۵	−۱/۳۹۹۰	۸/۷۹	۲۱/۴۳

در این حالت، بهترین مدل بدست آمده با توجه به شاخص‌های AIC و BIC، مدل ارائه شده در ردیف ۱۱ جدول ۴ است که با رنگ خاکستری متمایز شده است. در این حالت نرخ خوراک A در خط جریان ۱ (X_1)، فشار رآکتور (X_7) و کار کمپرسور (X_{20}) به عنوان تأثیرگذارترین متغیرهای حالت برای پیش‌بینی غلظت جزء A در ساختار مدل باقی ماندند.

در ادامه با استفاده از روش سعی و خطا و حذف پس‌رو مدل‌های LIV برای پیش‌بینی غلظت جزء E نیز ساخته شدند. نتایج پیش‌بینی مدل‌های ارائه شده با محاسبه شاخص عملکردی و معیارهای AIC و BIC در جدول ۵ آورده شده است. در این حالت مدل ردیف ۱۹ که با رنگ خاکستری متمایز شده است، با توجه به اینکه دارای پایین‌ترین مقدار AIC و BIC است، به عنوان مطلوب‌ترین مدل انتخاب می‌شود. در این حالت نرخ خوراک A در خط جریان ۱ (X_1)، فشار عریان‌ساز (X_{16}) و کار کمپرسور (X_{20}) به عنوان تأثیرگذارترین متغیرها در پیش‌بینی غلظت جزء E در ساختار مدل باقی ماندند. مشخصات مدل‌های انتخاب شده برای حسگر نرم، با پهنای باند بهینه نهایی در جدول ۶ آورده شده است.

همانطور که مشخص است از بین ۲۲ متغیر آسان اندازه‌گیر که به عنوان ورودی‌های اولیه مدل حسگر نرم انتخاب شدند، تنها ۳ متغیر آسان اندازه‌گیر برای پیش‌بینی غلظت جزء A و غلظت جزء E بر مبنای تکنیک LIV کافی است.

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

جدول ۵. شاخص‌های عملکردی مدل‌های ارائه شده بر روی داده‌های آموزش برای پیش‌بینی غلظت جزء E

شماره	متغیرهای حالت انتخاب شده	تعداد متغیرها	R^2	RMSE	$\ln(\hat{L})$	AIC	BIC
۱	$X_1,X_2,X_3,X_4,X_5,X_6,X_7,X_8,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21},X_{22}$	۲۲	۱	$۱/۱\times۱۰^{-۱۰}$	−۴/۹۲۴۴	۵۳/۸۴	۱۴۶/۵۷
۲	$X_1,X_2,,X_4,X_5,X_6,X_7,X_8,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21}$	۲۰	۱	۰/۰۰۱۷	−۴/۸۰۸۸	۴۹/۶۱	۱۳۳/۹۰
۳	$X_1,X_2,X_4,X_5,X_6,X_8,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21}$	۱۹	۱	۰/۰۰۳۴	−۴/۶۲۳۹	۴۷/۲۴	۱۲۷/۳۲
۴	$X_1,X_2,X_4,X_5,X_6,X_8,X_9,X_{10},X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21}$	۱۸	۱	۰/۰۰۲۸	−۴/۶۲۹۳	۴۵/۲۵	۱۲۱/۱۲
۵	$X_1,X_2,X_4,X_6,X_8,X_9,X_{10},X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{19},X_{20},X_{21}$	۱۷	۱	۰/۰۰۲	−۴/۸۴۹۵	۴۳/۶۹	۱۱۵/۳۴
۶	$X_1,X_2,X_4,X_6,X_8,X_9,X_{10},X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20},X_{21}$	۱۶	۱	$۲/۹۴\times۱۰^{-۴}$	−۴/۷۲۲۵	۴۱/۴۴	۱۰۸/۸۷
۷	$X_1,X_4,X_6,X_8,X_9,X_{10},X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20},X_{21}$	۱۵	۰/۹۹۹۴	۰/۰۰۳	−۴/۶۷۷۸	۳۹/۳۵	۱۰۲/۵۷
۸	$X_1,X_4,X_6,X_8,X_9,X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20},X_{21}$	۱۴	۰/۹۷۴۳	۰/۰۰۳۸	−۴/۶۱۰۲	۳۷/۲۲	۹۶/۲۲
۹	$X_1,X_4,X_6,X_8,X_9,X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20}$	۱۳	۱	$۷/۴۸\times۱۰^{-۵}$	−۴/۷۰۷۳	۳۵/۴۱	۹۰/۲۰
۱۰	$X_1,X_4,X_6,,X_9,X_{11},X_{12},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20}$	۱۲	۰/۸۹۰۲	۰/۰۰۱۴	−۴/۷۰۱۵	۳۳/۴۰	۸۳/۹۷
۱۱	$X_1,X_4,X_6,,X_9,X_{11},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20}$	۱۱	۰/۹۹۵۳	$۵/۰۸\times۱۰^{-۴}$	−۴/۷۴۸۴	۳۱/۴۹	۷۷/۸۵
۱۲	$X_1,X_4,X_6,,X_{11},X_{14},X_{15},X_{16},X_{17},X_{18},X_{20}$	۱۰	۰/۸۲۵۰	۰/۰۰۵۲	−۴/۶۶۷۷	۲۹/۳۳	۷۱/۴۸
۱۳	$X_1,X_4,X_6,,X_{11},X_{14},,X_{16},X_{17},X_{18},X_{20}$	۹	۰/۹۷۵۵	۰/۰۰۱۱	−۴/۷۲۱۶	۲۷/۴۴	۶۵/۳۷
۱۴	$X_1,X_4,X_6,,X_{11},X_{14},,X_{16},,X_{18},X_{20}$	۸	۰/۸۳۳۹	۰/۰۰۵	−۴/۶۶۸۰	۲۵/۳۳	۵۹/۰۵
۱۵	$X_1,,X_6,,X_{11},X_{14},,X_{16},,X_{18},X_{20}$	۷	۰/۹۱۰۶	۰/۰۰۳۹	−۴/۵۸۴۶	۲۳/۱۶	۵۲/۶۷
۱۶	$X_1,,X_6,,X_{11},X_{16},,X_{18},X_{20}$	۶	۰/۸۹۹۹	۰/۰۰۴۳	−۴/۶۸۴۴	۲۱/۳۶	۴۶/۶۵
۱۷	$X_1,X_{11},X_{16},X_{18},X_{20}$	۵	۰/۸۵۷۰	۰/۰۰۴۸	−۴/۶۷۱۰	۱۹/۳۴	۴۰/۴۱
۱۸	X_1,X_{16},X_{18},X_{20}	۴	۰/۸۲۶۲	۰/۰۰۴۹	−۴/۶۶۷۱	۱۷/۳۳	۳۴/۱۹
۱۹	X_1,X_{16},X_{20}	۳	۰/۸۴۱۱	۰/۰۰۵۰	−۴/۴۵۵۱	۱۴/۷۰	۲۷/۳۴

جدول ۶. متغیرهای حالت انتخاب شده و پهنای باند متناظر برای مدل‌های بدست آمده

متغیر کیفیت	متغیرهای حالت انتخاب شده	پهنای باند بهینه متناظر با هر متغیر حالت		
غلظت A	X_1, X_7,X_{20}	۰/۰۰۸۲	۰/۰۸۹۱	۰/۰۷۸۳
غلظت E	$,X_{20}\ X_1,\ X_{16}$	۰/۰۱۲۸	۰/۰۵۲۵	۰/۰۶۷۵

به منظور بررسی کمی، شاخص‌های عملکردی مدل‌های پیشنهاد شده بر روی مجموعه داده آموزش در جدول ۷ آمده است. مقادیر R^2_{adj} بدست آمده مشابه مقادیر R^2 هستند که نشان دهنده این است که مدل بیش‌برازشی بر روی داده‌ها انجام نداده و متغیرهای غیر ضروری نیز در ساختار مدل اضافه نشده است، زیرا در این صورت اختلاف بین این دو شاخص افزایش می‌یافت. بعلاوه بر مبنای شاخص RMSE و MAE نیز دقت پیش‌بینی مدل‌های حاصله اثبات می‌شود.

نتایج حاصل از پیش‌بینی آن‌ها بر روی داده‌های آموزش در شکل ۳ آورده شده است. با نگاه کلی به مدل‌های آموزش داده شده می‌توان دریافت مدل‌های منتخب برای پیش‌بینی غلظت جزء A و غلظت جزء E رفتار داده‌ها را به خوبی دنبال می‌کنند. نتایج اعتبارسنجی مدل بر روی یک مجموعه داده‌های آموزش در جدول ۸ آورده شده است. همچنین نتایج پیش‌بینی این مدل‌های آموزش داده شده در شکل ۴ نشان داده شده است. از مقایسه مقادیر RMSE و MAE در جدول ۷ و ۸ مشخص می‌شود که عملکرد پیش‌بینی مدل‌های حسگر نرم بر روی مجموعه داده‌های آزمون افت ناچیزی پیدا کرده است.

جدول ۷. شاخص‌های عملکردی مدل‌های LIV بر روی مجموعه داده آموزش

متغیر کیفیت خروجی	شاخص عملکردی داده‌های آموزش			
	R^2	R^2_{adj}	RMSE	MAE
غلظت جزء A در خط جریان ۹	۰/۸۲۸۶	۰/۸۲۷۵	۰/۱۵۷۵	۰/۱۱۱۹
غلظت جزء E در خط جریان ۱۱	۰/۸۴۱۱	۰/۸۴۰۱	۰/۰۰۵۰	۰/۰۰۳۱

به منظور مقایسه کمی، نتایج عملکرد مدل‌های ردیف ۴، ۸ و ۱۱ به منظور پیش‌بینی غلظت جزء A ساخته شدند، بر روی داده‌های آزمون (۹۶۰ داده) در جدول ۹ آورده است.

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

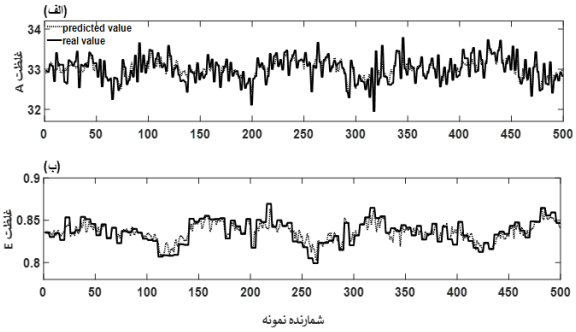

شکل ۳. نتایج پیش‌بینی غلظت با استفاده از حسگر نرم بر روی مجموعه داده آموزش: الف) جزء A ؛ ب) جزء E

جدول ۸ شاخص‌های عملکردی حسگرهای نرم مبتنی بر LIV بر روی مجموعه داده آزمون

متغیر کیفیت خروجی	شاخص عملکردی مجموعه داده آزمون			
	R^2	R^2_{adj}	RMSE	MAE
غلظت جزء A در خط جریان ۹	۱	۱	۰/۳۱۹۱	۰/۲۵۱۵
غلظت جزء E در خط جریان ۱۱	۰/۹۷۳۹	۰/۹۷۳۷	۰/۰۱۷۴	۰/۰۱۳۶

مقایسه نتایج عملکردی مدل‌های بدست آمده بر داده‌های آزمون حاکی از صحت انتخاب مدل ردیف ۱۱ به عنوان پایه حسگر نرم می‌باشد. این ساختار در مقایسه با سایر ساختارهای بررسی شده تنها از ۳ متغیر حالت برای پیش‌بینی متغیر کیفیت خروجی استفاده می‌کند و همچنین دارای کمترین مقدار RMSE و MAE نسبت به دو مدل دیگر است.

همچنین نتایج حاصل از پیش‌بینی مدل‌های ردیف ۴ و ۸ با نتایج پیش‌بینی مدل انتخاب شده به عنوان پایه حسگر نرم بر روی مجموعه داده‌های آزمون مقایسه گردید. همانطور که در شکل ۵-الف و ۵-ب نشان داده شده، مدل ردیف ۴ و ۸ در بسیاری از نقاط مخصوصاً در نقاط انحرافی، پیش‌بینی ضعیفی در مقایسه با داده‌های واقعی ارائه کرده اند. در مقایسه با دو مورد دیگر مدل انتخاب شده ردیف ۱۱ توانسته روند متغیر کیفیت خروجی را بهتر ردیابی کند و عملکرد پیش‌بینی دقیق‌تری را نشان می‌دهد (شکل ۵-ج).

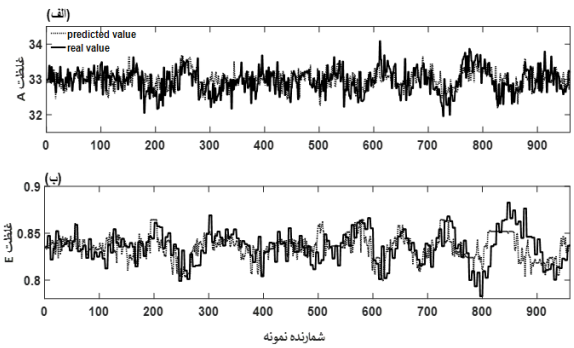

شکل ۴. نتایج پیش‌بینی غلظت با استفاده از حسگرهای نرم بر روی مجموعه داده آزمون: الف) جزء A ؛ ب) جزء E

جدول ۹. شاخص‌های عملکردی مدل‌های ارائه شده بر روی داده‌های آزمون برای پیش‌بینی غلظت جزء A

	متغیرهای حالت انتخاب شده	تعداد	R^2	RMSE	MAE
۴	$X_1,X_2,X_6,X_7,X_9,X_{10},X_{11},X_{12},X_{13},X_{14},X_{17},X_{20}$	۱۲	۰/۸۳۹۴	۰/۳۷۸۵	۰/۲۹۶۹
۸	$X_1,X_2,X_7,X_{11},X_{12},X_{17},X_{20}$	۷	۰/۹۹۹۹	۰/۳۳۴۸	۰/۲۶۶۲
۱۱	X_1,X_7,X_{20}	۳	۱	۰/۳۱۹۱	۰/۲۵۱۵

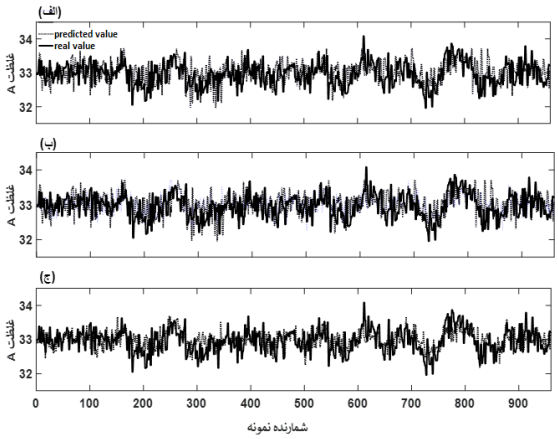

شکل ۵. نتایج پیش‌بینی مدل‌های LIV برای غلظت A بر روی مجموعه داده آزمون: الف) مدل ردیف ۴؛ ب) مدل ردیف ۸؛ ج) مدل ردیف ۱۱

به منظور ارزیابی قابلیت و توانمندی حسگر نرم طراحی شده به منظور پیش‌بینی غلظت جزء E ، آزمایشی ترتیب داده شده که در طی آن به صورت تصادفی برخی از قسمت‌های داده‌های آزمون را با مقادیر از دست رفته جایگزین کرده و سپس نتایج پیش‌بینی مدل بر روی این مجموعه داده جدید نیز بررسی گردید. نتایج حاصل از این بررسی در شکل ۶-ب آورده شده است. همانطور که در شکل ۶ نشان داده شده است، حسگر نرم قادر به پیش‌بینی کیفیت، در بخش‌هایی که در آن مجموعه داده آزمون حاوی داده‌های از دست رفته تصادفی است (با کادر مستطیلی مشخص شده) خواهد بود، که این قابلیت حسگر نرم را در شرایط عدم حضور داده نشان می‌دهد.

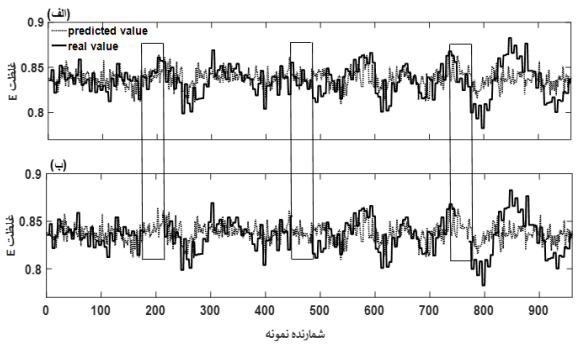

شکل ۶. مقایسه نتایج پیش‌بینی غلظت E بر روی داده‌های آزمون: الف) بدون مقادیر از دست رفته؛ ب) با مقادیر از دست رفته

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

جداول ۱۰ و ۱۱ شاخص‌های عملکردی حسگر نرم پیشنهادی را با سایر تکنیک‌های مدل‌سازی برای پیش‌بینی غلظت جزء A و E مقایسه می‌کند. همانطور که از جدول ۱۰ مشخص می‌شود، مقادیر RMSE برای تکنیک‌های حسگر نرم PLS، SFR و QSFR کمی از روش پیشنهادی ارائه شده بهتر است. اما با مقایسه تعداد متغیرهای ورودی لازم برای این سه روش (۲۲ متغیر ورودی) و روش LIV (۳ متغیر ورودی) مشخص می‌شود که پیچیدگی مدل بدست آمده و حجم محاسبات لازم برای رسیدن به چنین دقتی بالا می‌باشد. به بیان دیگر، تعداد متغیرهای ورودی مدل LIV به میزان حدود ۸۵٪ نسبت به روش‌های ذکر شده در جدول ۱۰ کاهش یافته است. علاوه بر این مدل ارائه شده دارای R^2 بیشتری به نسبت دیگر مدل‌هاست که نشان می‌دهد داده‌های پیش‌بینی و واقعی در این مدل دارای سازگاری بیشتری هستند.

جدول ۱۰. شاخص‌های عملکردی مدل‌های حسگر نرم فرآیند تنسی ایستمن برای پیش‌بینی غلظت جزء A

نویسنده	نوع مدل	تعداد متغیرهای ورودی	R^2	RMSE
کین و همکاران [۳۲]	PLS	۲۲	۰/۵۲۷۱	۰/۳۰۵۶
	SFR	۲۲	۰/۶۰۴۰	۰/۲۸۹۶
	QSFR	۲۲	۰/۶۶۹۴	۰/۲۶۳۹
پژوهش فعلی	LIV	۳	۱	۰/۳۱۹۱

با توجه به مقادیر ارائه شده در جدول ۱۱ نیز می‌توان نتیجه گرفت که مدل LIV دارای بیشترین مقدار RMSE در مقایسه روش‌های ذکر شده است. همچنین مدل LIV در مقایسه با دیگر تکنیک‌های مدل‌سازی از دقت بیشتر و تعداد متغیرهای ورودی کمتری برخوردار است که این سبب سادگی مدل و کاهش بار محاسباتی در مدل‌سازی می‌شود. به عنوان نمونه میزان افزایش دقت مدل (شاخص RMSE) بدست آمده توسط روش LIV نسبت به مدل‌های PLS و DiPLS به ترتیب ۹۸/۱۸ ٪ و ۹۷/۶٪ گزارش شده است.

جدول ۱۱. شاخص‌های عملکردی مدل‌های حسگر نرم فرآیند تنسی ایستمن برای پیش‌بینی غلظت جزء E

نویسنده	نوع مدل	تعداد متغیرهای ورودی	R^2	RMSE
دانگ و کین [۳۱]	PLS	۳۳	–	۰/۹۵۹۰
	DiPLS	۳۳	–	۰/۷۴۱۸
پژوهش فعلی	LIV	۳	۰/۹۷۳۹	۰/۰۱۷۴

٦- نتیجه‌گیری

در این پژوهش طراحی حسگر نرم داده محور به منظور پیش‌بینی کیفیت در فرآیند تنسی ایستمن بر مبنای روش شناسایی تفسیر پذیر داده و تکنیک مدل‌سازی وابسته به حالت مورد بررسی قرار گرفت. حسگر نرم پیشنهادی با استفاده از تکنیک متغیر سودمند محلی (LIV) ارائه گردیده است. این تکنیک علاوه بر اینکه ساختاری ساده دارد و نسبت به سایر روش های مدلسازی به تعداد متغیرهای ورودی کمتری نیازمند است، قابلیت شناسایی متغیرهای تأثیرگذار بر روی متغیرهای هدف را نیز داراست. ساختار مدل حسگر نرم مبتنی بر LIV در بخش آموزش مدل معیارهای اطلاعاتی بیزین (BIC) و آکائیک (AIC) را برای غلظت جزء A به ترتیب ۸/۷۹ و ۲۱/۴۳ گزارش نمود. همچنین معیارهای اطلاعاتی بیزین (BIC) و آکائیک (AIC) برای ساختار مدل LIV منتخب در پیش‌بینی جزء E به ترتیب ۱۴/۷۰ و ۲۷/۳۴ بدست آمد. مدل حسگر نرم ارائه شده به منظور پیش‌بینی غلظت جزء A توانست با سه متغیر به عنوان ورودی مدل و خطای RMSE، ۰/۳۱۹۱ متغیر غلظت را پیش‌بینی نماید. مقدار خطای پیش‌بینی (RMSE) برای غلظت جزء A در مدل LIV نسبت به مدل‌های کمینه مربعات جزئی (PLS)، رگرسیون ترکیبی تدریجی (SFR) و رگرسیون ترکیبی تدریجی وابسته به کیفیت (QSFR) با اختلاف جزئی به ترتیب ۴/۲۳٪، ۹/۲۴ ٪ و ۱۷/۲۹ ٪ بیشتر می‌باشد درصورتی‌که تعداد متغیرهای ورودی مدل LIV نسبت به مدل‌های ذکر شده به میزان ۸۵٪ کاهش یافته است.

مدل حسگر نرم ارائه شده به منظور پیش‌بینی غلظت جزء E توانست متغیر خروجی را با سه متغیر ورودی مدل حسگر نرم و خطای RMSE، ۰/۰۱۷۴ پیش‌بینی کند. همچنین مقدار خطای پیش‌بینی (RMSE) برای غلظت جزء E را نسبت به روش‌های کمینه مربعات جزئی (PLS) و کمینه مربعات جزئی درونی پویا (DiPLS) به ترتیب به میزان ۹۸/۱۸٪ و ۹۷/۶٪ کاهش داده است. مدل‌های حسگر نرم ارائه شده بر مبنای روش LIV توانستند در شرایطی که مجموعه داده‌های فرآیند حاوی مقادیر از دست رفته باشند، متغیر هدف را با عملکرد مطلوب پیش‌بینی کنند.

مراجع

[1] Fortuna L., Graziani S., Rizzo A., Xibilia M.G., Soft sensors for monitoring and control of industrial processes, *Springer*, *New York*, pp. 2-5, 2007.

[2] Khatibisepehr S., Huang B., Domlan E., Soft sensor solutions for control of oil sands processes. *The Canadian Journal of Chemical Engineering*, Vol. 91. pp., 1416-1426, 2013.

[3] Khatibisepehr S., Bayesian Solutions to Multi-Model Inferential Sensing Problem, *University of Alberta*, Doctor of Philosophy, 2013.

[4] Li H., Yu D., Braun J., A review of virtual sensing technology and application in building systems, *HVAC&R Research*, Vol. 17, no. 5, pp. 619–645, 2011.

[5] Kadlec P., Gabrys B., Strandt S., Data-driven soft sensors in the process industry, *Computers and Chemical Engineering*, Vol. 33, pp. 795–814, 2009.

[Downloaded from joc.kntu.ac.ir on 2026-02-08]
[DOI: 10.61186/joc.17.1.77]

[6] Kaneko H., Arakawa M., Funatsu K., Development of a new soft sensor method using independent component analysis and partial least squares, *AIChE Journal*, Vol. 55, pp. 87–98, 2009.

[7] Sliskovic D., Grbic R., Hocenski Z., Methods for plant data-based process modeling in soft sensor development, *Automatika*, Vol. 52, pp. 306–318, 2011.

[8] Jang J.-S.R., Sun C.-T., Mizutani E., Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence, *Prentice-Hall Upper Saddle River, NJ, USA*, 1997.

[9] Kaneko H., Funatsu K., Adaptive soft sensor based on online support vector regression and Bayesian ensemble learning for various states in chemical plants. *Chemometrics and Intelligent Laboratory Systems*, Vol. 137, pp. 57-66, 2014.

[10] Young P.C., Recursive estimation and time-series analysis, *Second ed*., *Springer, New York*, 2011.

[11] Sadeghi J., Modelling and control of non-linear systems using State-Dependent Parameter (SDP) models and Proportional-Integral-Plus (PIP) control method, *Lancaster University*, Doctor of Philosophy, *United Kingdom*, 2006.

[12] Tavakoli Dastjerd F., Sadeghi J., Shahraki F., Khalilipour M.M., Bidar B., Soft sensor design using multi-state dependent parameter methodology based on generalized random walk method, *IEEE Sensors Journal*, Vol. 22, No.8, pp. 7888-7901, 2022.

[۱۳] بیدار، ب.، طراحی حسگر نرم داده محور به منظور پیش‌بینی برخط کیفیت محصول در برج‌های تقطیر به روش پارامتر وابسته به متغیر حالت، دانشگاه سیستان و بلوچستان، پایان نامه دکتری، ۱۳۹۶.

[۱۴] نعیمی ف.، طراحی حسگر نرم افزاری داده محور به منظورپیش‌بینی برخط کیفیت نفت‌خام در واحد نمک‌زدایی/ آب‌زدایی به روش پارامتر وابسته به متغیرحالت، دانشگاه سیستان و بلوچستان، پایان نامه کارشناسی ارشد، ۱۳۹۷.

[۱۵] هادی‌زاده، گ.، طراحی حسگر نرم داده‌محور به منظور پیش‌بینی کیفیت در فرآیند ناپیوسته صنعتی تولید رزین پلی‌استر، دانشگاه سیستان و بلوچستان، پایان نامه کارشناسی ارشد، ۱۳۹۹.

[16] Gharehbaghi H., Sadeghi J., A novel approach for prediction of industrial catalyst deactivation using soft sensor modeling, *Catalysts*, Vol. 6, pp. 93-109, 2016.

[17] Bidar B., Sadeghi J., Shahraki F., Khalilipour M.M., Data-driven soft sensor approach for online quality prediction using state dependent parameter models, *Chemometrics and Intelligent Laboratory Systems*, Vol. 162, pp. 130-141, 2017.

[18] Bidar B., Khalilipour M.M., Shahraki F., Sadeghi J., A data-driven soft-sensor for monitoring ASTM-D86 of CDU side products using local instrumental variable (LIV) technique, *Journal of the Taiwan Institute of Chemical Engineers*, Vol.84, pp. 49-59, 2018.

[19] Bidar B., Shahraki F., Sadeghi J., Khalilipour M.M., Soft sensor modeling based on multi-state-dependent parameter models and application for quality monitoring in industrial sulfur recovery process, *IEEE Sensors Journal*, Vol.18, No.11, pp. 4583-4591, 2018.

[20] Roja Parvizi Moghadam, Jafar Sadeghi, Farhad Shahraki, Soft sensor model for monitoring and online control based on a dynamic model and local instrumental variable technique, *International Journal of Modelling, Identification and Control*, Vol.39, No.3, pp. 192-203, 2021.

[21] Downs J.J., Vogel E.F., A plant-wide industrial process control problem, *Computers and Chemical Engineering*, Vol. 17, pp. 245-255, 1993.

[22] Ge Z., Song Z., A comparative study of just-in-time-learning based methods for online soft sensor modeling, *Chemometrics and Intelligent Laboratory Systems*, Vol. 104, pp. 306-317, 2010.

[23] Grbic R., Sliskovic D., Kadlec P., Adaptive soft sensor for online prediction and process monitoring based on a mixture of Gaussian process models, *Computers and Chemical Engineering*, Vol. 58, pp. 84–97, 2013.

[24] Yuan X., Ge Z., Song Z., Soft sensor model development in multiphase/multimode processes based on Gaussian mixture regression, *Chemometrics and Intelligent Laboratory Systems*, Vol. 138, pp. 97-109, 2014.

[25] He Y., Geng Z., Zhu Q., Data driven soft sensor development for complex chemical processes using extreme learning machine, *Chemical Engineering Research and Design* Vol.102, pp. 1–11, 2015.

[26] Dong Y., Qin S., Regression on dynamic PLS structures for supervised learning of dynamic data, *Journal of Process Control*, Vol. 68, pp. 64–74, 2018.

[27] Qin Y., Zhao C., Huang B., A new soft-sensor algorithm with concurrent consideration of slowness and quality interpretation for dynamic chemical process, *Chemical Engineering Science*, Vol. 199, pp. 28-39, 2019.

[28] Guo F., Wei B., Huang B., A just-in-time modeling approach for multimode soft sensor based on Gaussian mixture variational autoencoder, *Computers and Chemical Engineering*, Vol. 146, pp.107230, 2021.

[29] Zhang T., Zhang Sh., He F., Quality prediction and sensitivity analysis of fine chemical products based on support matrix machine, *Chemometrics and Intelligent Laboratory Systems*, Vol. 231, pp.104716, 2022.

[30] Li Zh., Jin H., Dong Sh., Qian B., Yang B., Chen X., Semi-supervised ensemble support vector

[Downloaded from joc.kntu.ac.ir on 2026-02-08]

[DOI: 10.61186/joc.17.1.77]

[36] Russell E.L., Chiang L.H., Braatz, R.D., Fault detection in industrial processes using canonical variate analysis and dynamic principal component analysis. , *Chemometrics and intelligent laboratory systems*, Vol. 51, pp. 81–93, 2000.

[37] Andersen C.M., Bro R., Variable selection in regression-a tutorial, *Journal of Chemometrics*, Vol. 24, pp. 728-737, 2010.

[38] Reunanen J., Overfitting in making comparisons between variable selection methods, *The Journal of Machine Learning Research*, Vol. 3, pp. 1371-1382, 2003.

[39] Findley D. F., Counterexamples to parsimony and BIC, *Annals of the Institute of Statistical Mathematics*, Vol. 43, pp. 505-514, 1991.

[40] Giraud C., Introduction to High-Dimensional Statistics: *Taylor & Francis*, 2014.

[41] Aho, K., Derryberry D., Peterson T., Model selection for ecologists: the worldviews of AIC and BIC, *Ecology*, Vol. 95, pp. 613-636, 2014.

[42] Akaike H., Information theory and an extension of the maximum likelihood principle, in Selected Papers of Hirotugu Akaike, *Springer*, pp. 199-213, 1998.

[43] Sá M., Joaquim P., Applied statistics using SPSS, STATISTICA, MATLAB and R, *Second ed*., *Springer-Verlag*, *Berlin*, *Heidelberg*, 2007.

regression based soft sensor for key quality variable estimation of nonlinear industrial processes with limited labeled data, *Chemical Engineering Research and Design*, Vol. 179, pp.510-526, 2022.

[31] Yu F., Xiong Q., Cao L., Yang F., Stable soft sensor modeling based on causality analysis, *Control Engineering Practice*, Vol. 122, pp.105109, 2022.

[32] Wang Y., Jin H., Chen X., Wang B., Yang B., Qian B., Online-Dynamic-Clustering-Based Soft Sensor for Industrial Semi-Supervised Data Streams, *Sensors*, Vol.23, No.3, PP. 1520, 2023.

[33] Shen b., Yao L., Yang Z., Ge Z., Mode Information Separated β-VAE Regression for Multimode Industrial Process Soft Sensing, *IEEE Sensors Journal*, Vol. 23, No. 9, pp. 10231-10240, 2023.

[34] Kusolsongtawee T., Kheawhom S., Olaru S., Bumroongsri P., Development of a Data-Driven Soft Sensor for Multivariate Chemical Processes Using Concordance Correlation Coefficient Subsets Integrated with Parallel Inverse-Free Extreme Learning Machine, *Engineering Journal*, Vol.27, No.6, 2023.

[35] Yin S., Gao X., Karimi H., Zhu X., Study on Support Vector Machine-Based Fault Detection in Tennessee Eastman Process, *Abstract and Applied Analysis*, *Hindawi*, 2014.

[Downloaded from joc.kntu.ac.ir on 2026-02-08]

[DOI: 10.61186/joc.17.1.77]