

مقایسه تکنیک‌های تحلیل داده در پیش بینی میزان تولید نفت: مورد کاربردی میدان اهواز

محمدرضا مقدم

دکترای اقتصاد انرژی

mr_moghaddam@yahoo.com

تاریخ دریافت: ۱۳۸۶/۵/۱ تاریخ پذیرش: ۱۳۸۸/۲/۱۵

چکیده

این مقاله به توصیف و مقایسه پیش بینی‌های دو روش از بین روش‌های تحلیل داده‌ها، روش منحنی کاهش^۱ (DCE) با استفاده از روش رگرسیون و روش شبکه عصبی مصنوعی^۲ (ANN) می‌پردازد. نتایج به دست آمده مربوط به تولید حاصل از چاه‌های واقع بر میدان نفتی اهواز نشان می‌دهند که در طول دوره برآورد، برآزش روش شبکه عصبی از انطباق بهتری نسبت به روش رگرسیون (با استفاده از تکنیکهای اقتصادسنجی) برخوردار است، ولی در دوره پیش بینی تولید، با توجه به سناریوی انتخابی، پیش بینی روش شبکه عصبی بسیار متفاوت از روش رگرسیون است و نشان می‌دهد که تحلیلگران نباید برای تخمین تولید میادین نفتی تنها به یک روش خاص تکیه کنند. به هر حال این دو شیوه در سیستمی موسوم به "سیستم پشتیبانی تصمیم"^۳، DSS، برای کاربران امکان پیش بینی تولید یک میدان یا حتی یک چاه را فراهم می‌آورند. بنابراین، یک کارشناس میدان نفتی می‌تواند منحنی‌های مختلف مربوط به نرخ‌های تولید پیش‌بینی شده را مقایسه و مناسب‌ترین مدل را برای تصمیم‌گیری انتخاب نماید. به عبارت دیگر، معادلات (ریاضی) به کار رفته برای پیش بینی تولید یک میدان نفتی به گونه‌ای باید مدل سازی شوند که بتوانند مقادیر نسبتاً نزدیک به یکدیگر را به دست دهند.

طبقه‌بندی JEL : Q4

کلید واژه: پیش بینی میزان تولید نفت، میدان نفتی، روش شبکه‌های عصبی مصنوعی، روش منحنی کاهش، رگرسیون.

1 - Decline Curve Estimation.

2 - Artificial Neural Network.

3 - Decision Support System.

۱- مقدمه

پیش بینی میزان تولید میادین و چاه‌های نفتی دارای اهمیت بسزایی است. مهندسين نفت همواره به دنبال روشی ساده اما مطمئن برای پیش‌بینی و تخمین میزان تولید نفت برای یک دوره طولانی هستند. این تخمینها، از یک سو، مهندسين نفت را در تنظیم تعهدات تولید در برنامه‌های تولید روزانه و یا سالانه یاری می‌نمایند و از سوی دیگر، به مسئولین اقتصادی کشور در تنظیم بودجه‌های سالانه و یا برنامه‌های ۵ ساله و بلندمدت یاری می‌نمایند. فرآیندی که اغلب مهندسين مخزن در این رابطه به کار می‌گیرند "شبیه‌سازی عددی"^۱ است. این فرآیند بر اساس نتایج حاصل از آنالیز نمودارهای تولید انجام می‌گیرد. اما این فرآیند از لحاظ تکنیکی، مشکل و وقت‌گیر و از نظر نیروی انسانی صرف شده و داده‌های مورد نیاز تولید و ذخیره مخزن، هزینه‌بر است. در این مقاله ابتدا "سیستم پشتیبانی تصمیم"، DSS، بر اساس دو روش منحنی کاهش^۲ (DCE) و شبکه عصبی مصنوعی^۳ (ANN) معرفی می‌گردد. سپس با استفاده از مجموعه داده‌های تولید یک میدان نفتی نمونه (میدان نفتی اهواز) مدل پیش‌بینی تولید طراحی می‌گردد. مزیت روش‌های منحنی کاهش و شبکه عصبی مصنوعی، سهولت انجام کار با داده‌های چندبعدی است.

۲- معرفی روش‌های برآورد و پیش‌بینی تولید نفت

در ادبیات موضوع پنج روش سنتی و مرسوم جهت پیش‌بینی ذخیره نفت باقیمانده یک چاه نفتی وجود دارد^۴. این روش‌ها عبارتند از:

۱. روش قیاس^۵
۲. روش اندازه‌گیری حجم^۶ علوم انسانی و مطالعات فرهنگی
۳. روش موازنه مواد^۷
۴. روش برآزش منحنی کاهش^۸ و
۵. روش شبیه‌سازی ذخیره^۹

1- Numerical Simulation.
2 - Decline Curve Estimation.
3 - Neural Network.
4 - Fetkovich, 1980.
5 - By analogy.
6 - Volumetric.
7 - Material balance.
8 - Decline curve fitting.
9 - Reservoir simulation.

با وجود آن که تمامی ۵ روش عنوان شده می‌توانند برای پیش‌بینی میزان ذخیره قابل بازیافت از یک مخزن مورد استفاده قرار گیرند، معیذا هر روش به داده‌های مخصوص به خود نیازمند است، که مسلماً می‌تواند متفاوت با داده‌های مورد نیاز در روش‌های دیگر باشد. اما از آن‌جا که کلیه این روش‌ها می‌توانند به‌طور مستقل از یکدیگر به کار گرفته شوند، می‌توان از نتایج یک روش برای ارزیابی صحت و سقم نتایج حاصل از سایر روش‌ها استفاده کرد. در ذیل شاخص‌های اصلی هر یک از ۵ روش معرفی می‌شوند.

روش قیاس^۱: در این روش ابتدا میدان‌هایی با ویژگی‌های سنگ مخزن و سایر مشخصه‌های میدان مورد نظر شناسایی و سپس بر اساس داده‌های تولید آن میدان، تولید میدان مورد نظر تخمین زده می‌شود. علی‌رغم این‌که این روش سریع و کم هزینه است، ولی از دقت چندانی برخوردار نیست.

۱- روش اندازه‌گیری حجم^۲: در این روش تخمین نفت درجا با بهره‌گیری از حجم خالص مخزن و پارامترهای دیگری نظیر تخلخل، میزان اشباع هیدروکربور و ضریب بازیافت انجام می‌گیرد. این روش نسبتاً سریع بوده و به حداقل اطلاعات نیازمند است و می‌تواند در مراحل اولیه تولید مورد استفاده قرار گیرد. با این حال نتایج این روش به دلیل فرضیاتی در خصوص ضریب بازیافت می‌تواند خطاهای فاحشی داشته باشد.

۲- روش موازنه مواد^۳: در این روش اساس تخمین میزان نفت درجای اولیه، قانون بقای جرم است. این روش به اطلاعاتی نظیر فشار مخزن، تاریخچه تولید، خصوصیات سیال و سنگ مخزن نیازمند است و می‌تواند جهت محاسبه بسیاری از پارامترهای مخزن نظیر ضریب بازیافت و حجم کلاهدک گازی مورد استفاده قرار گیرد. از عیوب این روش حساسیت آن به تراوایی‌های نسبی و نیاز نسبتاً شدید به اطلاعات ورودی در مقایسه با سایر روش‌های موجود می‌باشد.

۳- روش برازش منحنی کاهش^۴: این روش تنها به داشتن اطلاعات تاریخی تولید نیازمند است و از هیچ‌گونه فرضیاتی راجع به اندازه و سایر پارامترهای مخزنی استفاده نمی‌کند. فرآیند تخمین یک منحنی کاهش، بسیار آسان و سریع است. در این روش تخمین‌هایی از تولید نسبت به زمان انجام می‌گیرد. نقطه ضعف این روش آن است که

1 - By analogy.

2 - Volumetric.

3 - Material balance.

4 - Decline curve fitting.

میدان و یا چاه مورد نظر بایستی تحت شرایط ثابتی تولید نماید و در صورت تغییر شرایط دیگر نمی‌توان این روش را به کار برد.

۴- روش شبیه سازی ذخیره^۱: این روش که به روش "مدل سازی مخزن" نیز معروف است اساساً همان حالت جامع و توسعه یافته روش "موازنه مواد" می‌باشد. این روش در مقایسه با روش‌های دیگر به حجم بسیار بالایی از داده‌های ورودی نیازمند است. قوت این روش در نظرگیری خصوصیات سیال و سنگ مخزن نواحی مختلف در تخمین است. با این حال نقطه ضعف این روش آن است که به هزینه و زمان قابل توجهی جهت انجام مطالعه و تهیه داده‌های مورد نیاز، احتیاج دارد. در حین به کارگیری این روش نیز می‌توان پارامترهای مورد استفاده را با توجه به داده‌های تاریخی تولید از چاه مورد نظر تنظیم، اصلاح و به روزآوری نمود تا بتوان به منحنی برازش شده بهتری دست یافت. با این حال به دلیل آن که اغلب دست‌یابی به تنها یک منحنی برازش شده امکان‌پذیر نیست لذا لازم است تا براساس قضاوت مهندسی تنها از داده‌های معقول و قابل اعتماد استفاده شود. علاوه بر این حتی هنگامی که یک منحنی محاط شده مناسبی نیز به دست آید، همواره این احتمال وجود دارد که فرضیاتی که در به دست آمدن این منحنی اعمال شده نقض شوند.

۳- روش برازش منحنی کاهش^۲

در اکثر تحقیقات در خصوص تخمین میزان ذخیره نفت و میزان تولید از یک مخزن، از روش تحلیل منحنی کاهش استفاده شده است. غالب تکنیک‌های موجود جهت آنالیز منحنی کاهش بر اساس مدل‌های تجربی می‌باشند^۳. یکی از مشکلات تکنیک فوق تشخیص و انتخاب فرم ریاضی مناسب برای توضیح چگونگی تولید از مخزن است. به علاوه هر یک از این فرم‌های ریاضی دارای نقاط قوت و ضعف متفاوتی نیز می‌باشند. به طور مثال، منحنی‌نمایی معمولاً میزان نفت ذخیره و نرخ تولید را بیش از میزان واقعی و منحنی هارمونیک، نرخ تولید را کم‌تر از میزان واقعی نشان می‌دهد. البته با استفاده از یک منحنی ساده نمی‌توان تولید یک مخزن را در سرتاسر دوره آن توصیف و پیش‌بینی نمود. برازش داده‌های تولید بر یک منحنی کاهش، خصوصاً زمانی که

1 - Reservoir simulation.

2 - Decline curve fitting method.

3 - Li & Horne, 2003.

داده‌های تاریخی کافی نیستند، دشوار است و ممکن است به پیش‌بینی‌های غیرقابل اطمینان و نادرست منجر گردد (El-Banbi and Wattenbarger, 1996). یکی از مثال‌های کاربردی استفاده از روش برازش منحنی کاهش تجربه لی و هارن^۱ است. آن‌ها در مطالعه خود از مخازن شکافدار طبیعی برای تحلیل داده‌های مربوط به تولید نفت استفاده کردند. در این مدل از رفتار و مکانیسم جریان سیال و تراوانی نسبی و فشار موئینگی استفاده شده است. طبق نتایج این مدل، بین نرخ تولید نفت، ضریب بازیافت نفت و یا میزان تولید انباشتی، بخصوص در اواخر دوره تولید از میدان، رابطه خطی وجود دارد.

مدل‌های پیش‌بینی در سیستم‌های پشتیبانی تصمیم می‌توانند با به‌کارگیری شبکه‌های عصبی و یا معادلات تقریب منحنی، تولید را مدل‌سازی نمایند. به‌طور معمول، با در اختیار داشتن یک مجموعه از داده‌ها می‌توان بیش از یک منحنی را برازش نمود و هدف از مدل‌سازی، یافتن منحنی‌ای است که کم‌ترین انحراف را از کلیه نقاط داده شده داشته باشد. در رگرسیون و روش حداقل مربعات^۲ (LS) فرض می‌گردد که بهترین منحنی، منحنی‌ای است که مجموع مربعات خطا کم‌ترین باشد. اکثر معادلاتی که در مطالعات مورد استفاده قرار می‌گیرند یا اساساً خطی بوده و یا قابل تبدیل به یک معادله خطی هستند و به شکل زیر می‌باشند:

$$\text{Linear: } p = \beta_a + \beta_1 t$$

$$\text{Logarithmic: } P = \beta_a + \beta_1 \ln(t)$$

$$\text{Exponential: } P = \beta_a e^{\beta_1 t}$$

$$\text{Harmonic: } P = (\beta_a / (1 + \beta_1 t))$$

ضرایب β_a و β_1 توسط هر بسته نرم افزار اقتصادسنجی، برای نمونه Econometric Views (Eviews) و یا MicroFit قابل تخمین هستند.

مطابق با ادبیات موضوع (Baker, Spenceley, Guo, & Schechter, 1998) تولید نفت از یک میدان نفتی، تابعی از متغیرهایی نظیر تعداد چاه‌های فعال به‌عنوان متغیر جایگزین سرمایه‌گذاری برای توسعه میدان، تولید انباشتی و ذخیره باقیمانده به‌عنوان ظرفیت تولید میدان، می‌باشد و به زبان ریاضی داریم:

$$q_t = f(w_t, r_{t-1}, q_{t-1})$$

1 - Li & Horne.

2 - Least Squares.

که در آن، q ، معرف میزان تولید سالانه به دست آمده از میدان یا مخزن، w_t ، تعداد چاه‌های فعال (در حال بهره برداری)، r_{t-1} ، ذخیره باقی مانده از دوره قبل و qc_{t-1} ، تولید انباشتی از دوره‌های قبل می‌باشند. t نیز معرف زمان است. به عبارت دیگر:

$$r_t = r_{t-1} - q_t$$

$$qc_{t-1} = qc_{t-2} + q_{t-1}$$

هم‌چنین، می‌توان به جای متغیر «تولید سالانه» از «متوسط تولید هر چاه: q/w » و یا «متوسط تولید روزانه هر چاه: $qdw = (q/w)/365$ » و به جای دو متغیر r و qc از «نسبت ذخیره باقی مانده به تولید انباشتی: r/qc » استفاده نمود. از این‌رو، ترکیب متغیرهای به دست آمده توابع متعددی را پیشنهاد می‌نماید، که می‌توان به موارد زیر اشاره کرد:

$$(q/w)_t = f(r_{t-1}/qc_{t-1})$$

$$(qdw)_t = f(r_{t-1}/qc_{t-1})$$

$$(qd)_t = f(r_{t-1}/qc_{t-1}, t)$$

$$(qdw)_t = f(r_{t-1}/qc_{t-1}, t)$$

انتظار می‌رود که ضریب مربوط به متغیر تولید انباشتی qc_{t-1} ، منفی، ضریب مربوط به متغیر r_{t-1} ، مثبت، ضریب مربوط به w_{t-1} ، مثبت و نهایتاً ضریب متغیر r_{t-1}/qc_{t-1} ، مثبت باشد. از بین فرم‌های تابعی ارائه شده، فرمی انتخاب و مورد تحلیل قرار می‌گیرد که دارای قدرت توضیح دهنده بالایی (ضریب تعیین معادله برآورد شده) و ضرایب معنی‌دار (بررسی آماره‌های t مربوط به هر ضریب) باشد.

۴- روش شبکه‌های عصبی مصنوعی

مدل‌های شبکه عصبی را نیز می‌توان برای یک سیستم پشتیبانی تصمیم "DSS" به کار برد. شبکه عصبی از الگوریتم‌های برازش منحنی استفاده می‌نماید. در یک مدل شبکه عصبی به جای آن که یک دسته معادلات حل شوند و از آن‌ها بهترین ضرایب به دست آیند، سعی می‌شود با اصلاح پارامترهای موجود در شبکه عصبی، خطای موجود در هر مرحله کاهش یابد. در این مطالعه برای ساختن شبکه‌های عصبی از الگوریتم پس انتشار خطا، back-propagation، که در نرم‌افزار Matlab تعبیه شده است استفاده می‌شود.


شبکه‌های عصبی مصنوعی (ANN) جزء دسته‌ای از سیستم‌های دینامیکی هستند که دانش نهفته در ورای داده‌ها را با پردازش داده‌های تجربی به ساختار شبکه منتقل

می‌کنند. در واقع این سیستم‌ها، بر اساس محاسبات بر داده‌های تجربی، قوانین کلی را فرا می‌گیرند. به همین دلیل به آن‌ها سیستم‌های هوشمند نیز می‌گویند. شبکه‌های عصبی مصنوعی دارای ویژگی‌هایی هستند که آن‌ها را در بعضی از کاربردها مانند تشخیص الگو در سیستم‌های غیرخطی و پیچیده از دیگر روش‌ها متمایز می‌نماید. این ویژگی‌ها عبارتند از:

۱- قابلیت آموزش: یعنی توانایی تنظیم وزن‌های شبکه با استفاده از داده‌های آموزشی و

۲- قابلیت تعمیم: یعنی پس از آموزش شبکه با استفاده از داده‌های آموزشی و تنظیم وزن‌های شبکه، شبکه قادر است یک ورودی آموزش داده نشده را بپذیرد و یک خروجی مناسب ارائه نماید.

نرون کوچک‌ترین واحد پردازش اطلاعات در شبکه‌های عصبی محسوب می‌شود. برای مثال، شکل ۱ ساختار یک نرون با n ورودی و یک خروجی را نشان می‌دهد.




شکل ۱- ساختار یک نرون با چند ورودی

بردار $x = (x_1, x_2, \dots, x_n)$ سیگنال‌های ورودی و اسکالر y سیگنال خروجی

نرون می‌باشند. میزان تأثیر x روی y با بردار وزنی $w = (w_1, w_2, \dots, w_n)$ مشخص می‌شود. در بسیاری از مواقع، در نظر گرفتن یک سیگنال ورودی دیگر با مقدار ثابت یک مفید خواهد بود که میزان تأثیر آن روی سیگنال خروجی با وزن b تعیین می‌شود. ورودی خالص به نرون که با net نمایش داده می‌شود با معادله ذیل تعریف می‌شود:

$$net := \sum_{i=1}^n w_i x_i + b$$

در این معادله، b جمله اریب (bias) نامیده می‌شود. پس از ورود سیگنال net به نرون، تابع تحریک یا تابع تبدیل f عمل می‌کند و سیگنال خروجی y با معادله $y = f(net)$ به دست می‌آید. وزن‌های w و b قابل تنظیم هستند و تابع تحریک b توسط تجربه مشخص می‌شود. بر اساس انتخاب f و نوع الگوریتم آموزش، وزن‌های w و b تنظیم می‌شوند. آموزش به این معنی است که w و b طوری تنظیم شوند که بتوانند رابطه بین سیگنال‌های ورودی و خروجی را به‌طور مناسبی توضیح دهند. شکل ۲، ساختار یک شبکه عصبی را (شامل لایه ورودی، لایه پنهان و لایه خروجی) نشان می‌دهد.



شکل ۲- ساختار یک عصبی

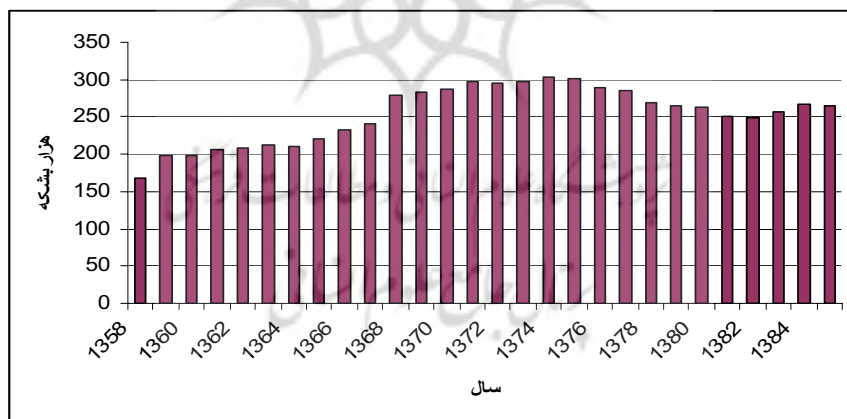
یکی از قابلیت‌های بسیار مهم شبکه عصبی، توانایی آموزش آن است. آموزش به این معنی است که شبکه عصبی به هنگام اعمال سیگنال ورودی و مشاهده پاسخ خود، رفتار خود را طوری تنظیم نماید که اگر در لحظه بعدی همان ورودی اعمال گردد، شبکه عصبی پاسخ مطلوب‌تری را ارائه دهد. این تنظیم رفتار توسط الگوریتم‌های

بازگشتی به نام الگوریتم‌های آموزش انجام می‌گیرد. برای آموزش شبکه عصبی باید از ابتدا نوع آموزش در مسأله مورد بحث مشخص شود. به‌طور کلی دو نوع آموزش وجود دارد: آموزش با ناظر و آموزش بدون ناظر. معمولاً برای آموزش شبکه‌های عصبی با ناظر یک تابع هزینه تعریف می‌شود و از مجموعه‌ای از داده‌های تجربی به نام داده‌های آموزشی برای تعیین وزن‌های شبکه استفاده می‌شود. در این نوع آموزش، وزن‌های شبکه به‌نحوی تنظیم می‌شوند که تابع هزینه بر اساس داده‌های آموزشی کمینه شود.

۵ - مقایسه نتایج دو روش برآورد

۵-۱- نتایج برآورد مدل با استفاده از تکنیک رگرسیون

نمودار ۱ میزان تولید سالانه میدان اهواز را طی دوره ۱۳۸۵-۱۳۵۸ نشان می‌دهد. طی این دوره با به‌کارگیری ۹۴ درصد چاه‌های موجود، میزان تولید به ۲۶۵.۲ میلیون بشکه رسیده است که به‌طور متوسط سالانه رشدی معادل ۰.۴۴ درصد را نشان می‌دهد. طی دوره مورد بررسی تعداد چاه‌های فعال از ۹۴ حلقه چاه در سال ۱۳۵۸ به ۲۶۳ حلقه در سال ۱۳۸۵ افزایش یافته است، که به‌طور متوسط سالانه ۳.۸۸ درصد رشد را نشان می‌دهد.




نمودار ۱- تولید سالانه میدان اهواز

جدول ۱ نتایج به دست آمده از برآورد فرم خطی ساده بین متغیرهای مدل را ارائه می‌دهد^۱. در مدل فوق، متغیر وابسته «تولید سالانه میدان اهواز» و متغیرهای توضیح‌دهنده (مستقل) تولید، «تولید انباشتی» و «تعداد چاه» می‌باشند. کلیه ضرایب در سطح اطمینان بیش از ۹۵ درصد معنی دار آماری هستند. ضریب تعیین تعدیل شده مدل ۶۵ درصد به دست آمده است که نشان دهنده این است که مجموعه متغیرهای توضیحی بیش از ۶۵ درصد از نوسانات تولید را توضیح می‌دهند. نمودار ۲ روند تولید سالانه و مقادیر شبیه سازی شده به دست آمده از مدل برآورد شده را طی دوره برآورد نشان می‌دهد. از آنجا که در مقاله حاضر، هدف مقایسه دو روش برآورد است، مجموع مجذورات خطا (SSR) این مدل (۱۲۷۸۵) با متناظر خود در روش شبکه عصبی مقایسه می‌گردد.

جدول ۱- معادله برآورد شده برای برآورد میزان تولید میدان اهواز

میدان اهواز				
متغیر وابسته: Q_ah				
روش برآورد: Least Squares				
Sample: 1358 - 1385				
observations: 28 Included				
متغیر	ضریب	انحراف معیار	آماره t	سطح معنی دار
C	126.9123	18.21040	6.969217	0.0000
W_AH	2.563423	0.553497	4.631321	0.0001
QC_AH (-1)	-0.050565	0.013416	-3.768936	0.0009
R-squared	0.673142	Mean dependent var		253.6321
Adjusted R-squared	0.646993	S.D. dependent var		38.06084
S.E. of regression	19.61332	Akaike info criterion		9.175938
Sum squared resid	12784.39	Schwarz criterion		9.318675
Log likelihood	-125.4631	F-statistic		25.74287
Durbin-Watson stat	1.773336	Prob(F-statistic)		0.000001

۱ - دلیل استفاده از ساده‌ترین زشکل تابعی بین متغیرها، مدل خطی ساده، این است که مطابق با هدف مقاله مقایسه بین دو روش برآورد بدون ورود به ویژگی‌های هر دو روش صورت پذیرد. بدیهی است اگر محقق بخواهد قدرت توضیح دهنده مدل اقتصادسنجی را به راحتی با معرفی اشکال تابعی مانند لگاریتمی، درجه دوم و ...، معرفی متغیرهای باوقفه، بررسی خصوصیات سری زمانی متغیرها و یا در مدل شبکه عصبی با تغییر نوع آموزش، افزایش دهد. در حالی که اطلاعات جانبی که روش اقتصادسنجی به محقق ارائه می‌دهد امکان تحلیلهای کمی مناسب‌تر و کامل‌تری به وجود می‌آید.



نمودار ۲- مقادیر واقعی و شبیه سازی شده تولید سالانه میدان

۵-۲- نتایج برآورد مدل با استفاده از تکنیک شبکه عصبی مصنوعی

تحقیقات بسیاری جهت تخمین و پیش‌بینی میزان نفت تولیدی با به‌کارگیری روش شبکه‌های عصبی مصنوعی (ANN) انجام پذیرفته است که به‌طور نمونه می‌توان به موارد زیر اشاره نمود:

- امین زاده و همکارانش (۱۹۹۹) از تکنیک ANN جهت تخمین پارامترهای مخزنی یک میدان نفتی که از داده‌های لرزه‌نگاری از راه دور به‌دست آمده بود، استفاده نمودند.

- هانگ و ویلیام^۱ با استفاده از تکنیک ANN توانستند مدلی برای تخمین میزان تخلخل و تراوایی حاصله از نمودارهای چاه طراحی نمایند. اگرچه اندازه‌گیری‌های انجام شده بر روی مغزه جهت ساخت نمونه‌های مرحله آموزش مدل مورد استفاده قرار نگرفتند، با این حال منحنی‌های پیش‌بینی شده بجز در مواردی چند، انطباق خوبی با مقادیر واقعی نشان داده‌اند.

1 - Huang & William, 1977.

- وانگ و تاگارت^۱ مدلی مشابه با مدل Huang & William ارائه نمودند. نتایج حاصله نشان داد که روش شبکه عصبی استاندارد نسبت به روش شبیه‌سازی، دارای میانگین مجذور خطای^۲ (RMSE) کم‌تری است. اما در عین حال در روش شبیه‌سازی، کمیت‌های آماری نظیر میانگین، انحراف معیار، ضریب تغییرات و مقادیر کمینه و بیشینه دقیق‌تر محاسبه می‌شوند. آنان معتقدند که از مهم‌ترین مراحل که باید به هنگام استفاده از تکنیک ANN در حل مسائل زمین‌شناسی مدنظر قرار گیرد آن است که داده‌ها بایستی پیش از استفاده مورد پالایش قرار گیرند.

- غربی و همکارانش (۱۹۹۹) مدلی را بر اساس شبکه عصبی جهانی طراحی نمودند و به‌عنوان آلترناتیوی برای پیش‌بینی خواص فشار-حجم-دما (PVT) مورد استفاده قرار داده‌اند. در این مطالعه مدل ANN ارائه شده دقت بالاتری را نسبت به سایر روش‌های همبستگی (Correlation) نشان داده است. مضافاً آن که نسبت به روش‌های دیگر دارای کم‌ترین میزان خطا، کم‌ترین میزان انحراف معیار و بالاترین ضریب همبستگی بوده است.

برای پیش‌بینی تولید میدان نفتی اهواز، یک شبکه عصبی کاملاً متصل به هم (یک لایه ورودی، یک لایه مخفی و یک لایه خروجی) با دو نرون در لایه ورودی متناظر با متغیرهای مستقل تابع تولید (تعداد چاه فعال و تولید انباشته) و یک نرون در لایه خروجی $f(x) = \frac{1}{1+e^{-x}}$ متناظر با متغیر وابسته میزان تولید، تابع همانی $f(x) = x$ به‌عنوان تابع تحریک نرون‌های لایه ورودی و تابع زیگموئید به‌عنوان تابع تحریک نرون‌های لایه مخفی و خروجی استفاده شده است.

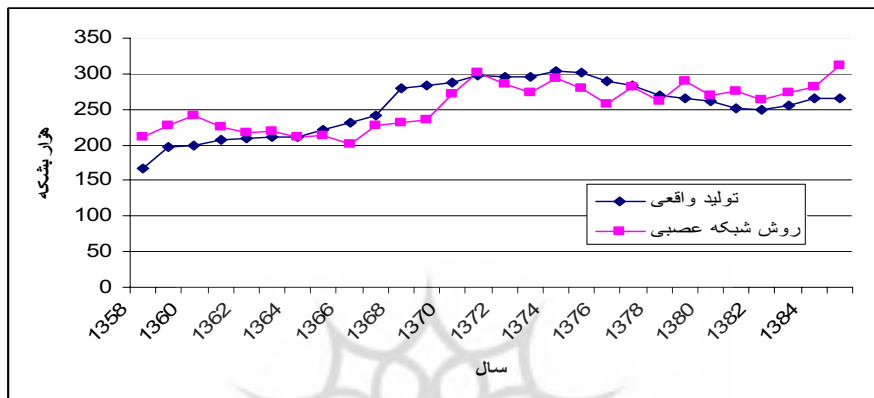
برای آموزش شبکه عصبی، تابع هزینه میانگین مربعات خطای بین مقادیر واقعی و مقادیر به‌دست آمده از شبکه عصبی و داده‌های آموزشی، اطلاعات موجود سال‌های ۱۳۵۸ تا ۱۳۸۵ در نظر گرفته شده‌اند. روش استاندارد برای کمینه شدن تابع هزینه و در نتیجه آموزش شبکه عصبی، الگوریتم پس انتشار (propagation Back) می‌باشد.^۳ نمودار ۳ نتایج برآورد تابع تولید (خطی ساده) بر اساس سناریوی فوق را نشان می‌دهد.

1 - Wong & Taggart, 1995.

2 - Root Mean Square Error.

۳ - با به‌کارگیری این الگوریتم پس انتشار و نتایج حاصل از شبیه‌سازی میزان تولید سالانه این میدان، مقادیر تولید برای دوره (۱۴۰۰ - ۱۳۸۶)، بر اساس سناریوی «دامه روند موجود»: رشد ۳.۸۸ درصدی تعداد چاه‌ها، پیش‌بینی می‌گردد.

مجموع مجدورات خطاهای این مدل ۶۸۱۸ به دست آمده است که در مقایسه با میزان همین شاخص برای روش رگرسیون "بسیار کوچک" است و نشان دهنده قدرت توضیح دهنده گی بالای مدل شبکه عصبی در طول دوره برآورد است.



نمودار ۳- مقادیر واقعی و شبیه سازی شده تولید سالانه میدان

۵-۳- پیش بینی تولید میدان (۱۴۰۰=۱۳۸۶) با استفاده از دو روش رگرسیون و شبکه عصبی

در این بخش پیش بینی تولید سالانه میدان طی یک دوره نسبتاً معقول، بر اساس سناریوی «ادامه روند موجود تعداد چاهها» یعنی با رشد متوسط ۳.۸۸ درصد در سال، انجام می پذیرد. مفروضات مدل عبارتند از:

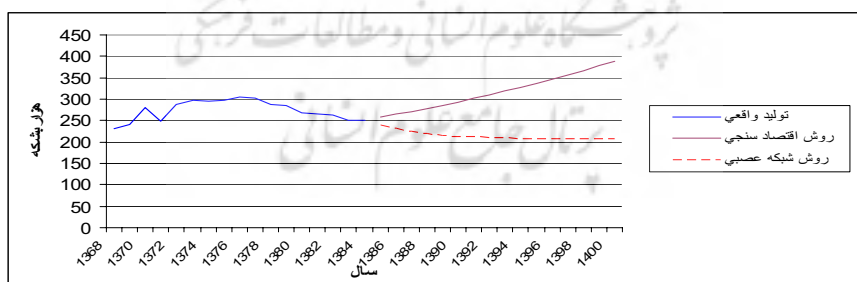
- حفر چاه به منزله سرمایه گذاری در میدان محسوب می شود.
- هیچ گونه تغییری در ضریب بازیافت میدان انجام نمی گیرد.
- در طول دوره پیش بینی میدان کماکان در نیمه عمری به سر می برد که در دوره برآورد مدل بوده است.
- چاه های حفر شده در دوره برآورد و پیش بینی مدل صرفاً چاه های توسعه ای بوده و هستند.

نمودار ۴ و جدول ۲ پیش بینی به دست آمده از دو روش رگرسیون (اقتصادسنجی) و شبکه عصبی مصنوعی را نشان می دهند. نتایج نشان می دهند که با حفظ نرخ رشد

۳/۸۸ درصد تعداد چاه‌های فعال، نرخ رشد تولید سالانه بر اساس منحنی تولید (روش رگرسیون) و شبکه عصبی به ترتیب ۱/۸ درصد و منهای ۱.۱ درصد خواهد بود.

جدول ۳ - میزان پیش بینی تولید طی دوره (۱۳۸۶-۱۴۰۰) (هزار بشکه)

سال	روش اقتصادسنجی	روش شبکه عصبی
۱۳۸۶	۲۶۵	۲۳۰
۱۳۸۷	۲۷۱	۲۲۴
۱۳۸۸	۲۷۹	۲۱۹
۱۳۸۹	۲۸۶	۲۱۵
۱۳۹۰	۲۹۴	۲۱۲
۱۳۹۱	۳۰۲	۲۱۱
۱۳۹۲	۳۱۰	۲۰۹
۱۳۹۳	۳۱۸	۲۰۸
۱۳۹۴	۳۲۷	۲۰۸
۱۳۹۵	۳۳۷	۲۰۷
۱۳۹۶	۳۴۶	۲۰۷
۱۳۹۷	۳۵۷	۲۰۷
۱۳۹۸	۳۶۷	۲۰۶
۱۳۹۹	۳۷۸	۲۰۶
۱۴۰۰	۳۸۹	۲۰۶
متوسط نرخ رشد دوره	٪ ۱.۸	- ٪ ۱.۱۳



نمودار ۴ - میزان پیش بینی تولید سالانه (۱۳۸۶-۱۴۰۰) طبق دو روش

۶- نتیجه‌گیری

در این مقاله دو روش تخمین (تابع اقتصادسنجی و شبکه عصبی مصنوعی) برای میدان اهواز به کار گرفته شده است. در مقایسه با برآورد دو روش ذکر شده، شبکه عصبی یک روند رو به پایین غیرمعمول را در انتهای دوره تولید میدان یا چاه نشان می‌دهد. یک راه حل برای مقابله با این پدیده، آموزش مجدد شبکه عصبی است تا بتوان از شدت کاهش تولید در پایان عمر میدان و یا چاه کاست. عدم وجود داده‌های کافی در مرحله آموزش باعث برآزش بیش از اندازه (over-fitting) می‌شود. می‌توان با انتخاب جهت عمل آموزش باید حداقل دارای یک دوره تولید سی ساله باشند. در غیر این صورت شبکه عصبی نمی‌تواند برون‌یابی مناسبی انجام دهد. خروجی‌های روش رگرسیون اطلاعات مفیدی در خصوص شناسایی فرم ریاضی تابع، آماره‌های مربوط به ضرایب و سایر شاخص‌های آماری ارائه می‌کنند، در حالی که شبکه عصبی برآزش مناسبی در طول دوره انجام می‌دهد هرچند برای پیش‌بینی نتایج کاملاً متفاوتی را در مقایسه با سایر روش‌های پیش‌بینی ارائه می‌کند. از این‌رو، توصیه می‌شود که مهندسين مخزن به‌منظور پیش‌بینی تولید میدان به یک روش اکتفا نکرده و روش‌های مختلف را به کار گیرند و معقول‌ترین نتیجه را برای برنامه‌ریزی آتی خود انتخاب نمایند.

فهرست منابع

- ۱- احمدیان، مجید، ۱۳۷۳، اقتصاد منابع پایان‌پذیر، مؤسسه مطالعات بین‌المللی انرژی، تهران.
- ۲- احمدیان، مجید، ۱۳۷۰، نظریه بازار و کاربرد آن برای منابع انرژی پایان‌پذیر - کاربرد نظریه کنترل، تهران.
- ۳- همتی، عبدالناصر، ۱۳۷۰، مدل‌های تحلیلی قیمت نفت، پایان‌نامه کارشناسی ارشد، دانشکده اقتصاد دانشگاه تهران.
- 4- Aminzadeh, F., Barhen, J., Toomarian, N.B. (1999), Estimation of reservoir parameter using a hybrid neural network. *Journal of Petroleum Science and Engineering* 24 (1), 49-56.
- 5- Baker, R.O., Spenceley, N.K., Guo, B., Schechter, D.S. (1998), Using an analytical decline model to characterize naturally fractured reservoirs. *SPE/DOE Improve Oil Recovery Symposium, Oklahoma, 19-22 April 1998 (SPE 39623)*.

- 6- El-Banbi, A.H., Wattenbarger, R.A. (1996), Analysis of commingled tight gas reservoirs. SPE Annual Technical Conference and Exhibition, 1996 (SPE 36736).
- 7- Fetkovich, M.J. (1980), Decline curve analysis using type curves. Journal of Petroleum Technology, 1065–1077.
- 8- Gharbi, R.B., Elsharkawy, A.M., Karkoub, M. (1999), Universal neural-network-based model for estimating the PVT properties of crude oil systems. Energy & Fuels 13, 454–458.
- 9- Hoel, Michael (1980), Resource Extraction When a Future Substitute has an Uncertain Cost”, Review of Economic Studies, PP. 637-644.
- 10- Huang, Z., William, M.A. (1997), Determination of porosity and permeability in reservoir Intervals by artificial neural network modeling, Canada. Petroleum Geoscience 3, 245–258.
- 11- John, E.G. (1998), Simplified curve fitting using spreadsheet add-ins, Intl. Journal of Engineering Education 14 (5), 375–380.
- 12- Kaufman, R. K, Cleveland, C. J, (2001), Oil Production in the Lower States: Economic, Geological, and Institutional Determinates”, The Energy Journal, Vol. 22, no. 1, PP. 27-49.
- 13- Li, K., Horne, R.N. (2003), A decline curve analysis model based on Fluid flow mechanisms, SPE western regional/AAPG pacific section joint meeting held in long beach, California, USA, 19–24 May 2003 (SPE 83470).
- 14- Morony John R., Douglas Bergm. (1999), “An Integrated Model of Oil Production”, The Energy Journal, Vol. 20, No.1 PP. 105-724.
- 15- Pesaran, M. H, (1988), An Econometric Analysis of Exploration and Extraction of Oil in the U. K. Continental Shelf, February, Working Paper, No. 471.
- 16- Walls, M. A, (1991)”, Modeling and Forecasting the Supply of Oil and gas, Resources for the Future, Washington DC.
- 17- Wong, P.M., Taggart, I.J. (1995), Use of neural network methods to predict porosity and permeability of a petroleum reservoir. AI Applied (2), 27–37.



پروہشگاہ علوم انسانی و مطالعات فرہنگی
پرتال جامع علوم انسانی