

کاربرد محاسبات نرم جهت بهینه‌سازی انتخاب مته با استفاده از هوش مصنوعی و الگوریتم‌های ژنتیک

حسین مصطفوی*، مدیریت اکتشاف شرکت ملی نفت

اطلاعات مقاله

تاریخ ارسال نویسنده: ۹۵/۱۱/۰۳

تاریخ ارسال به داور: ۹۵/۱۱/۰۴

تاریخ پذیرش داور: ۹۵/۱۲/۱۸

چکیده

مهندسان حفاری قبل از شروع یا حین حفاری یک چاه جدید با چالش‌های زیادی مواجه می‌شوند. متغیرهای زیادی وجود دارد که با سخت‌افزار و عملیات‌های روزانه مرتبط بوده و با پیشرفت حفاری برای آنها برنامه‌ریزی شده و تنظیم می‌گردند. از این متغیرها، انتخاب مته یکی از مهم‌ترین ملاحظات جهت برنامه‌ریزی و طراحی چاه جدید است. اگرچه از آنجا که عوامل مختلف عملکرد مته روابط پیچیده‌ای با خواص سازند، طراحی بدنه‌ی مته و متغیرهای عملیاتی دسته‌بندی درخور مته کار سختی است. هدف اصلی روش پیشنهاد شده عبارت است از ارزیابی شرایط فعلی سیستم حفاری جهت بهینه‌سازی کلی کارآیی حفاری و کاهش احتمال فرسایش زود هنگام مته‌ی حفاری.

روش مرسوم انتخاب مته بیشتر بر اساس تجربه‌ی حفاری در میدان یا روابط ریاضی‌ای است که بیشتر بر پایه‌ی عملکرد مته‌های مشابه در چاه‌های آفست به‌دست آمده‌اند. آشکار است که این روابط پیچیده بین متغیرها را نمی‌توان در یک معادله‌ی ساده‌ی ریاضی بیان کرد. ثابت شده که در اینچنین موارد پیچیده‌ای به کارگیری هوش مجازی و شبکه‌های عصبی مصنوعی (ANNها) در فهم روابط پیچیده‌ی بین متغیرها بسیار ارزشمند است.

در این مطالعه دو مدل مناسب با استفاده از ANNها توسعه داده شده است. مدل اول انتخاب مناسب مته بر اساس ROP مطلوب و بر اساس متغیرهای حفاری مشخص انجام می‌شود. مدل دوم از متغیرهای حفاری مناسب، که خود از طریق روند بهینه‌سازی به‌دست آمده‌اند، استفاده کرده تا مته‌ای که حداکثر ROP ممکن را نتیجه می‌دهد بیابد. در این میان، الگوریتم ژنتیک (GA) مثل یک دسته از روش‌های بهینه‌سازی برای توابع پیچیده، استفاده می‌شود. توابع رابطه‌ی مورد استفاده برای پیش‌بینی انواع مته و متغیرهای حفاری بهینه در شبکه‌های آزمایشی حاصل به‌ترتیب برابر با ۰/۹۵ و ۰/۹ هستند.

مؤلف معتقد است که روش پیشنهاد شده، موقعیت‌های جدیدی برای بهینه‌سازی زمان واقعی و برای حفاری میدانی ایجاد کند که می‌توان آنها را به‌طور مؤثری در محدوده‌ی عملیات‌های حفاری موجود اعمال کرد.

واژگان کلیدی:

حفاری، محاسبات نرم، انتخاب مته، الگوریتم ژنتیک

مقدمه

و با در نظر گرفتن تمامی هزینه‌های عملیاتی اندازه‌گیری شود. مقایسه‌ی قیمت فروش دو مته روش ارزیابی معتبری نیست. یکی از پیچیده‌ترین و پرطرفدارترین روش‌های انتخاب مته شبکه‌های عصبی مصنوعی (ANNها) است؛ چراکه تمامی متغیرهای مهم حفاری و سازند را در نظر می‌گیرد و می‌توان از آن به‌عنوان ابزاری برای انتخاب مته استفاده کرد.

شبکه‌های عصبی از عناصر ساده‌ای تشکیل شده‌اند که موازی با هم کار می‌کنند. این عناصر از شبکه‌های عصبی بیولوژیکی الهام می‌گیرند. مانند چیزی که در طبیعت یافت می‌شود، تابع شبکه بیشتر توسط اتصالات بین عناصر تعیین می‌شود. می‌توانیم یک شبکه‌ی عصبی را طوری پرورش دهیم تا یک کار خاص را به‌وسیله‌ی تنظیم مقادیر اتصالات (وزنها) بین عناصر انجام دهد. معمولاً شبکه‌های عصبی طوری تنظیم شده یا پرورش یافته‌اند که یک ورودی خاص

فرآیند حفاری یک حفره در زمین نیازمند استفاده از مته‌های حفاری است. قطعاً مته‌ها اساسی‌ترین ابزار مورد استفاده برای مهندسان حفاری است و انتخاب مناسب‌ترین مته یکی از مشکلات اساسی و بزرگی است که همیشه با آن روبرو هستند. انتخاب مته‌ی مناسب می‌تواند نقش قابل‌توجهی در افزایش ROP و در نتیجه کاهش هزینه‌های روزانه‌ی حفاری داشته باشد.

انواع مختلفی از مته‌ها برای موقعیت‌های مختلف در طول عملیات حفاری تولید شده‌اند. برای مهندسان حفاری دانستن مسائل بنیادی در طراحی مته و روش‌های مختلف انتخاب مته جهت فهم کامل تفاوت بین مته‌های موجود مهم است. انتخاب مته‌ی حفاری یکی از مهم‌ترین جنبه‌های برنامه‌ریزی چاه است. بهینه‌سازی مته به عوامل زیادی مثل نوع سازند، میزان جهت‌دار بودن چاه، متغیرهای حفاری، خواص گل و ... بستگی دارد. بازده مته باید با واحد هزینه بر فوت

* نویسنده‌ی عهده‌دار مکاتبات (mostafavi.hossein@gmail.com)

در این فرمول ماتریس وزن، ماتریس ورودی، بایس و تابع انتقال است. وزن‌ها و بایس‌ها در فرآیند تعلیم تنظیم می‌شوند. اکثریت روش‌های حل ANN با نظارت تعلیم داده شده‌اند. در این حالت، خروجی ANN با خروجی واقعی مقایسه می‌شود. وزن‌ها و بایس‌ها که معمولاً در شروع به صورت تصادفی انتخاب شده‌اند، به وسیله تابع یادگیری طوری تنظیم می‌شوند که در بازگشت بعدی تطابق بهتری بین خروجی مطلوب و واقعی ایجاد کنند. تابع یادگیری طوری عمل می‌کند که خطاهای موجود تمام عناصر پردازش را به حداقل برسانند. در طول فرآیند تعلیم، بهبود وزن‌ها و بایس‌ها با اعمال همان داده‌های ورودی ادامه می‌یابد تا وقتی دقت شبکه مناسب شود [۱].

۲- توسعه مدل

در مطالعه حاضر، یک شبکه سه لایه با خوراک پیش‌رونده توسعه داده شده که شامل لایه‌های ورودی، مخفی و خروجی است. در میان ۲۰۰۰ داده‌ی فیلتر شده‌ی موجود که از ۹ چاه آفست مختلف جمع‌آوری شده‌اند [۲]، ۶۰ درصد از آنها برای تعلیم، ۲۰ درصد برای فرآیند اعتبارسنجی و ۲۰ درصد باقیمانده جهت آزمایش نتایج حاصل برای مته مدل شده و توابع ROP استفاده شده‌اند. مته‌های حفاری در توابع مدل برای ANN از انجمن بین‌المللی پیمانکاران حفاری (IADC) استخراج شده‌اند [۳].

برای اولین فرآیند مدل‌سازی مته‌ی مناسب بر اساس ROP مطلوب انتخاب شده است. در این مدل، اندازه‌ی مته، سطح جریان‌ی کلی (TFA)، عمق شروع، عمق خروج، بازه‌ی حفاری، وزن روی مته (WOB)، سرعت چرخش رشته‌ی حفاری (RPM)، ROP، نرخ گردش گل، فشار، مقاومت فشاری میانگین سازند (USC) و وزن گل (MW) به‌عنوان ورودی برای ANN و مته‌های IADC به‌عنوان خروجی در نظر گرفته شده‌اند. جدول ۱- لیستی از بازه‌های متغیرهای مورد استفاده و شکل ۳- نمودار مقاطع تعلیم واقعی و خروجی‌های پیش‌بینی شده توسط ANN با ثابت رابطه‌ی برابر ۰/۹۶ را نشان می‌دهند. سپس داده‌های آزمایشی در ANN وارد شده و نتایج در شکل ۴- نشان داده شده است. بنابراین می‌توانیم با به‌کارگیری متغیرهای خاص عملیات حفاری مته را طوری انتخاب کنیم که ROP مطلوب را نتیجه دهد. در این روش تمامی متغیرهای غالب در عملکرد مته برای مدل‌سازی تابع مته IADC مورد توجه قرار گرفته تا انتخاب مناسب مته را ممکن کند. متغیرهای حفاری مورد استفاده از سوابق مته‌ها به دست آمده؛ به‌جز رابطه‌ی IKU که جهت مقاومت فشارشی میانگین سازند استفاده می‌شود. رابطه‌ی IKU طبق رابطه‌ی ۲- بیان می‌شود:

$$C_0 = 0.77 * \left(\frac{304.8}{\Delta t} \right)^{2.93} \quad (2)$$

که در آن C_0 مقاومت فشارشی میانگین سازند بر حسب Mpa و Δt بر حسب $\frac{ms}{ft}$ مدت زمان جابجایی است که از لاگ صوتی به دست

یک خروجی هدف خاص را نتیجه دهد. بنابراین شبکه‌ی مذکور بر اساس مقایسه‌ی خروجی با هدف تنظیم می‌شود تا وقتی خروجی با هدف مطابقت پیدا کند. معمولاً بسیاری از این‌گونه جفت‌های ورودی/هدف برای پرورش یک شبکه‌ی عصبی مورد نیاز هستند. یکی از قوی‌ترین مشخصه‌های شبکه‌های عصبی توانایی آنها در یادگیری و عمومی کردن یک دسته داده‌ی تعلیمی است. آنها طوری از مقاومت‌ها/وزن‌های اتصالات بین عصب‌ها استفاده می‌کنند که خروجی‌های نهایی درست به دست آیند.

در این میان از الگوریتم‌های ژنتیک (GAها) جهت بهینه‌سازی متغیرها در مدل پیشنهاد شده توسط ANN‌ها استفاده می‌شود. الگوریتم‌های ژنتیک دسته‌ای از روش‌های بهینه‌سازی هستند که در توابع پیچیده به کار می‌روند و کاربردهای گسترده‌ای دارند. GA یک الگوریتم جستجوی اتفاقی (استوکستیک) است که در بهینه‌سازی‌های چندهدفه قابل استفاده بوده و می‌تواند ناسازگاری‌های بین اهداف را در نظر بگیرد. در این مطالعه تلاش شده دو مدل با استفاده از شبکه‌های عصبی و الگوریتم ژنتیک توسعه یابد. مدل اول مته‌ی بهینه را بر اساس متغیرهای حفاری، خواص سازند (مقاومت فشرده‌گی نامحدود UCS) و نرخ حفاری (ROP) پیش‌بینی می‌کند. به‌علاوه در مدل دوم مته‌ی حفاری بهینه بر اساس بهینه‌سازی متغیرهای حفاری (وزن روی مته WOB، نرخ چرخش رشته‌ی حفاری بر اساس دور بر دقیقه RPM، نرخ تزریق پمپ GPM، سطح کل جریان مته TFA و فشار لوله‌ی ایستاده SPP) و حداکثر ROP قابل دستیابی پیش‌بینی می‌کند.

۱- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANNها) واحدهای پردازش با توزیع موازی حجیمی هستند که به‌عنوان نورون شناخته می‌شوند. این نورون‌های ساده خصوصیات عملکردی مشخص مشترکی با نورون‌های بیولوژیکی دارند (شکل ۱-).

شبکه‌های عصبی قادر به یادگیری هستند تا سیستم‌های مختلف را تشخیص داده، دسته‌بندی کرده و عمومی‌سازی کنند. اینها مدل‌هایی هستند که با استفاده از داده‌ها پیش‌روی می‌کنند و از روی مثال‌هایی که به آنها داده می‌شود یاد می‌گیرند. یک شبکه‌ی عصبی معمولی شامل سه لایه‌ی نورون‌ها (ورودی)، مخفی و خروجی است که در شکل ۲- نشان داده شده است. یک نورون مقادیر ورودی را که در وزن‌های مربوط به اتصالات ضرب شده‌اند دریافت می‌کند و آنها را با یک مقدار به نام بایس جمع کرده، به یک تابع انتقال تحویل می‌دهند تا نتایج حاصل شود. در کل، خروجی نورون زدر لایه‌ی k را می‌توان از رابطه‌ی ۱- محاسبه کرد [۱].

$$x_{jk} = F_k \left(\sum_{i=1}^{N_{k-1}} W_{ijk} x_{i(k-1)} + b_{jk} \right) \quad (1)$$

می آید.

نتیجه گیری

خروجی‌ها به خوبی با هدف‌ها مطابقت داشته و مقادیر R برای مدل‌های اول و دوم به ترتیب بیشتر از ۰/۹۵ و ۰/۹۳ است. حتی اگر نیاز به نتایج دقیق‌تری باشد می‌توان موارد زیر را انجام داد:

- مقادیر اولیه برای وزن‌ها و بایس‌ها را با مقادیر حاصل جایگزین کرده و دوباره تلاش نمود
- تعداد نورون‌های مخفی را افزایش داد
- تعداد بردارهای تعلیم را افزایش داد
- اگر اطلاعات مناسب‌تری موجود باشد تعداد ورودی‌ها را افزایش داد
- یک الگوریتم تعلیم دیگر را امتحان کرد

در این مورد پاسخ شبکه قانع کننده بوده و می‌توان شبیه‌سازی را به کار برد تا از این شبکه برای ورودی‌های جدید استفاده گردد. در توسعه‌ی یک مدل ANN جهت تولید نتایج منطقی، وقتی خطای اعتبارسنجی افزایش یافت، تعلیم متوقف شد. شکل ۷- نتایج حاصل از مدل متی IADC را تصدیق می‌کند.

تعلیم و آزمایش نمودارهای خطاهای تعلیم، خطاهای اعتبارسنجی و خطاهای آزمایش را تولید می‌کنند که در شکل ۸- نشان داده شده‌اند. همچنین شکل‌های ۱۰ و ۹ به ترتیب فرآیند تعلیم، اعتبارسنجی و آزمایش مدل ROP و خطاهای مربوط را نشان می‌دهند. در این دو مدل، نتایج منطقی هستند؛ چرا که مربع خطای نهایی کوچک است. خطاهای آزمایش و خطاهای اعتبارسنجی خصوصیات مشابهی دارند و هیچ خطای قابل توجهی در برآزش رخ نداده است.

جهت بررسی نتایج متی‌های IADC مدل ANN یک دسته متغیر نمونه و متی پیش‌بینی شده توسط IADC که با این مورد سازگار باشد آزمایش شده است (جدول ۳). نتایج حاصل، مدل IADC که توسط ANN به دست آمده را تأیید می‌کند.

جهت اعتبارسنجی مدل دوم حاصل از ANN (تابع ROP) روند کلی مشاهده شده برای فرآیند بهینه‌سازی در چهار قسمت چاه نشان‌دهنده‌ی کاهش ROP با افزایش عمق است که دلیل آن افزایش میانگین مقاومت فشارشی با افزایش عمق است. انتخاب متی سخت‌تر در اثر افزایش مقاومت فشارشی در قسمت چهارم چاه، کاملاً با نتایج بهینه‌سازی تولید شده توسط الگوریتم ژنتیک سازگاری دارد.

در برخی قسمت‌ها به دلیل عدم انتخاب متی مناسب برای مقاومت فشارشی سازند در چاه‌های آفست نتایج بهینه‌سازی ROP نسبت به سه قسمت دیگر کمتر است. برای رسیدن به ROP بیشتر باید متی‌های سخت‌تری به کار برد. در این قسمت بر اساس جدول ۴ باید متی مشخص شده توسط سری‌های هفت یا هشت IADC استفاده شود. زیرا مقاومت فشارشی تک‌محوری

در قسمت بعد بهینه‌سازی انتخاب متی بر اساس رسیدن به حداکثر ROP تحقیق شده است. در گام نخست یک شبکه‌ی عصبی مصنوعی که ساختار و داده‌هایی شبیه مدل قبلی دارد توسعه داده شده است. تفاوت این مورد آنست که متی IADC به عنوان یک ورودی برای ANN در نظر گرفته شده؛ در حالی که ROP هدفی است که باید بهینه‌سازی شود. شکل‌های ۵ و ۶ مربوط به تعلیم و آزمایش هستند. همان‌طور که مشاهده می‌شود خطوط برآزش داده شده در نمودار متقاطع خروجی‌های شبکه در مقابل هدف‌های تعلیم و ورودی‌های آزمایش دقت زیادی برای تابع ROP دربر دارند.

بر اساس پروفایل چاه، بهینه‌سازی انتخاب متی برای چهار قسمت مختلف چاه انجام شده است. امکان تغییر برای چهار فرآیند بهینه‌سازی، تغییرات متغیرهای قابل تغییر مثل WOB، RPM، TFA، نرخ گردش گل و فشار ایجاد شده است. در حالی که اندازه‌ی متی و مقاومت فشارشی میانگین سازند باید ثابت نگه داشته شود. گستره‌های قابل تغییر و مقادیر متغیرهای ثابت در قسمت‌های مختلف چاه در جدول ۲- نشان داده شده‌اند.

در نهایت به کارگیری حداکثر ROP‌های حاصل از طریق الگوریتم ژنتیک در فرآیند بهینه‌سازی ممکن است اشتباهاتی در انتخاب متی ایجاد کند که به دلیل عدم تمیزکاری مناسب چاه است. تمیزکاری چاه را می‌توان از طریق محاسبه‌ی حداقل نرخ و سرعت مورد نیاز جریان گل برای انتقال خرده‌های حفاری به سطح و مقایسه‌ی آن با مقادیر پیشنهاد شده توسط الگوریتم ژنتیک در هر قسمت از چاه اعتبارسنجی کرد. این احتمال با استفاده از روابط زیر بحث می‌شود [۴].

$$V_{\min} = V_{\text{cut}} + V_{\text{slip}} \quad (۳)$$

که در آن:

$$V_{\text{cut}} = \frac{1}{[1 - (\frac{D_{\text{pipe}}}{D_{\text{hole}}})^2 * (0.685 + \frac{17.82}{ROP})]} \quad (۴)$$

$$V_{\text{slip}} = ESV * C_{\text{angle}} * C_{\text{size}} * C_{\text{mw}} \quad (۵)$$

که در آنها:

$$C_{\text{angle}} = 0.0365 * \theta_{\text{angle}} - 0.0002 \theta_{\text{angle}}^2 - 0.2 \quad (۶)$$

$$C_{\text{size}} = -1.02 * D_{50\text{cut}} + 1.27 \quad (۷)$$

$$C_{\text{mw}} = 1 - 0.333 * (\rho_{\text{mud}} - 8.65) \quad (۸)$$

$$ESV = 0.0052 * \mu_a + 3.1 \quad \mu_a > 55 \text{cp} \quad (۹)$$

$$ESV = 0.02 * \mu_a + 3.26 \quad \mu_a < 55 \text{cp} \quad (۱۰)$$

■ در مدل دوم با دست کاری الگوریتم ژنتیک در بهینه سازی، تابع ROP مدل سازی شده که با ANN به دست آمده مقدار بهینه ی ROP و سایر متغیرهای مربوطه (یعنی RPM، WOB، TFA، نرخ جریان و فشار گل) برای قسمت های مختلف چاه تعیین شدند. در نهایت از بین تمامی متها، متهای که بیشترین ROP را نتیجه می داد توصیه شد.

Nomenclature:

ANNs: Artificial Neural Networks شبکه های عصبی مصنوعی
 GAs: Genetic Algorithms الگوریتم های ژنتیک
 ROP: Rate of Penetration نرخ نفوذ
 RPM: Revolution Per Minute دور بر دقیقه
 TFA: Total Flow Area سطح کل جریان
 UCS: Unconfined Compressive Stress تنش فشارشی نامحدود
 WOB: Weight on Bit وزن روی مت
 Δt : Travel Time, $\mu s/ft$ زمان جابجایی
 C_o : Formation average compressive strength, Mpa مقاومت میانگین فشارشی سازند
 D_{hole} : Hole Diameter, Inch قطر چاه
 C_{ang} : Correction Factor for Angle (Dimensionless) عامل تصحیح برای زاویه (بی بعد)
 C_{size} : Correction Factor for Cutting Size (Dimensionless) عامل تصحیح برای اندازه ی خرده ها (بی بعد)
 C_{MW} : Correction Factor for Mud Weight (Dimensionless) عامل تصحیح برای وزن گل (بی بعد)
 D_{50cut} : Mean Cutting Size, Inch اندازه ی میانگین خرده ها
 ESV: Uncorrected Velocity, ft/sec سرعت تصحیح نشده
 V_{slip} : Slip Velocity, ft/sec سرعت لغزش
 F_k : Transfer Function in ANNs تابع انتقال در شبکه های عصبی مصنوعی
 B_{jk} : Bias in ANNs Structure بایس در ساختار شبکه های عصبی مصنوعی
 W_{ijk} : Weight in ANNs Structure وزن در ساختار شبکه های عصبی مصنوعی

حدود ۱۴۰/۳ مگا پاسکال است. به علاوه وقتی متی حفاری سازگار با این ROP استفاده شود ممکن است به کارگیری متغیرهای حفاری برای رسیدن به حداکثر ROP مشکلاتی ایجاد کند. در واقع بررسی حداکثر WOB و RPM مجاز برای هر مت ضروری است. اگر مقدار بهینه ی هر متغیر حفاری در بازه ی جدول دسته بندی متها وجود نداشته باشد، نتایج منطقی نبوده و باید گزینه ی دوم اعتبارسنجی شود.

در نهایت بر اساس معادلات ۳- تا ۱۰ [۴] اعتبارسنجی تمیزکاری در قسمت اولیه ی چاه نشان می دهد که حداقل سرعت جریان برای تمیزکاری چاه باید حدود ۲/۷ فوت بر ثانیه باشد؛ در حالی که سرعت حاصل پیشنهاد شده برای جریان در فرآیند بهینه سازی حدود ۳/۸ فوت بر ثانیه است. بنابراین مشکلی در خصوص انتخاب مت در قسمت اول چاه با استفاده از ROP و جریان پیشنهاد شده با نتایج بهینه سازی وجود ندارد. محاسبات مشابه اعتبارسنجی، نتایج را در دیگر قسمت های چاه نیز نشان می دهد.

با استفاده از الگوریتم ژنتیک به عنوان ابزاری قدرتمند در فرآیند بهینه سازی، در هر قسمت از چاه ROP برای هر مت بهینه سازی شده است. همان طور که قبلاً نشان داده شد بازه های ورودی برای متغیرهای ثابت و متغیر در قسمت های مختلف چاه متفاوت هستند.

این اختلاف ها با در نظر گرفتن تفاوت در هندسه ی چاه و محدودیت های جریان گل جهت حفظ تمیزکاری در چاه و ممانعت از فوران آن بررسی می شوند. جدول ۵- نتایج تمام چهار قسمت چاه را نشان می دهد. در نهایت متی انتخاب شده ای که بهترین ROP و سایر متغیرها مثل TFA، RPM، WOB، نرخ جریان گل و فشار را نتیجه می دهد در جدول ۶- نشان داده شده است. اما وقتی انتظار داریم ROP با استفاده از متی به دست آید که در بازه ای پایین تر از ROP حداکثر دوم (که از متی دومی به دست می آید و از فرآیند بهینه سازی انتخاب شده اند) قرار دارد باید موقعیت را بررسی کرد تا بتوان تصمیمی مناسب گرفت.

■ در مدل نخست با استفاده از تابع IADC، متی، مدل سازی شده و با استفاده از متغیرهای متی حفاری، متی مناسب بر اساس ROP مطلوب انتخاب گردید.

منابع

- [1] Beale M. H., Hagan M. T. and Demuth H. B., 2010, Neural Network Toolbox 7 User's Guide, The MathWorks Inc., 951 Pages.
- [2] N.I.S.O.C, 2010, Daily Report, Drilling Management.
- [3] Drill Bit Classifier, World Oil, 2006.
- [4] Mirhaj, S. A., Shadizadeh, S. R., Fazaelizadeh, M., 2007, Cutting removal simulation for deviated and horizontal wellbores, SPE Middle Oil and Gas Show Paper 10544, Bahrain, 11-14, March.
- [5] Magarini, P., Lanzetta, C., Galletta, A., 1999, Overpressure Evaluation Manual, ENI Agip Division.