

Referências Bibliográficas

AISSANI, N.; BELDJILALI, B.; TRENTESAUX, D. Dynamic scheduling of maintenance tasks in the petroleum industry: A reinforcement approach. **Engineering Applications of Artificial Intelligence**, v. 22, p. 1089–1103, 22 2009.

AITOKHUEHI, I. **Real-Time Optimization of Smart Wells**. Stanford University, Petroleum Engineering. [S.l.]. 2004.

ALMEIDA, A. D. C. **Aproximador de Função para Simulador de Reservatórios Petrolíferos Utilizando Técnicas de Inteligência Computacional e Projeto de Experimentos Fatoriais Fracionado**. Pontifícia Universidade Católica do Rio de Janeiro. MSc. Master. 2008.

ALMEIDA, A. D. C. **Aproximador de Função para Simulador de Reservatórios Petrolíferos: Utilizando Técnicas de Inteligência Computacional e Projeto de Experimentos Fatoriais Fracionado**. Pontifícia Universidade Católica do Rio de Janeiro. Msc. 2008.

ALMEIDA, A. D. C.; VELLASCO, M. R.; PACHECO, M. A. C. **Aproximador de Função para Simulador de Reservatórios Petrolíferos de uma Alternativa de Desenvolvimento Utilizando Técnicas de Inteligência Computacional**. Conferência Nacional em Inteligência Computacional Aplicada à Indústria de Petróleo. Rio de Janeiro: [s.n.]. 2007. p. 1-6.

BADGWEL, T. A.; QIN, S. J. Review of Nonlinear Model Predictive Control Applications. In: KOUVARITAKIS, B.; CANNON, M. **Nonlinear Predictive Control: Theory and Practice**. London: IEE Control Engineering, v. 61, 2001. Cap. 1, p. 3-32.

BELLMAN, R. **Dynamic Programming**. New Jersey: Princeton University Press, Princeton, 1957.

BERTSEKAS, D. P. **Dynamic Programming and Optimal Control**. Belmont: Athena Scientific, v. II, 1995. ISBN 1-886529-13-2.

BERTSEKAS, D. P. **Dynamic Programming and Optimal Control**. Belmont: Athena Scientific, v. I, 1995. ISBN 1-886529-12-4.

BERTSEKAS, D. P. **Dynamic Programming and Optimal Control**. 3th Edition. ed. Massachusetts: Athena Scientific, v. I, 2005.

BERTSEKAS, D. P.; TSITSIKLIS, J. N. **Neuro- Dynamic Programming**. Massachusetts: Athena Scientific , 1996.

BISHOP, C. **Neural Network for Pattern Recognition**. [S.l.]: Oxford University Press Inc, 1995.

CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. New York: Springer, 1999.

CAMPOS, S. R. V. et al. **Right Time Decision of Artificial Lift Management for Fast Loop Control**. Intelligent Energy Conference and Exhibition. Amsterdam: SPE 99956. 2006. p. 1-12.

CHEN, C.-T. **Linear Systems Theory and Design**. Third. ed. New York: Oxford University Press, 1999.

CHEN, Y.; OLIVER, D. S.; ZHANG, D. Efficient Ensemble-Based Closed-Loop Production Optimization. **Society of Petroleum Engineers Journal**, p. 634-645, December 2009.

CMG. IMEX. **Advanced Oil/Gas Reservoir Simulator Version 2000 User's Guide**. Computer Modelling Group LTD. Calgary: [s.n.], 2000.

CRICHLLOW, H. B. **Modern Reservoir Engineering: A Simulation Approach**. New Jersey: Prentice-Hall, 1977.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals, and Systems**, IV, n. 4, December 1989. 303-314.

DAVIS, A. M. **Software Requirements: Objects, Functions and States**. 2nd Edition. ed. NJ: Prentice Hall, 1993.

DAYAN, P. The Convergence of TD(λ) for General λ . **Machine Learning**, v. VIII, p. 341-362, 1992.

DOSTÁL, Z. **Optimal Quadratic Programming Algorithms: With Applications to Variational Inequalities**. New York: Springer, 2009.

DOYA, K. Reinforcement learning in continuous time and space. **Neural Computation**, v. 12, n. 1, p. 219-245, 2000.

ERNST, D. et al. Model Predictive Control and Reinforcement Learning as two Complementary Frameworks. **International Journal of Tomography and Statistics**, v. 6, n. S07, p. 122-127, Summer 2007. ISSN 09729976.

ERNST, D. et al. Reinforcement Learning Versus Model Predictive Control: A comparison on a Power System Problem. **IEEE Transactions on Systems, Man, and Cybernetics-Part B**, New York, v. 39, n. 2, p. 517-529, April 2009. ISSN 1083-4419.

F. CAMACHO, E. F.; BORDONS, C. **Model Predictive Control**. London: Springer, 1999.

FALETTI, L. A. **Sistema Híbrido de Otimização de Estratégias de Controle de Válvulas de Poços Inteligentes sob Incertezas**. Pontifícia Universidade Católica do Rio de Janeiro. PhD. 2007.

FEITOSA, R. Q. et al. **Classificação de Expressões Faciais Utilizando Redes Neurais Back Propagation e RBF**. WORKCOMP'99. São José dos Campos: [s.n.]. 1999. p. 69-76.

FIGUEIREDO, K. **Novos Modelos Neuro-Fuzzy Hierárquicos com Aprendizado por Reforço para Agentes Inteligentes**. Pontifícia Universidade Católica do Rio de Janeiro. PhD. Thesis. 2003.

FIGUEIREDO, K. **Reinforcement Learning**. Pontifícia Universidade Católica de Rio de Janeiro DEE. Curso Tópicos Avançados. 2008.

GAMMA, E. et al. **Design Patterns: Elements of Reusable Object-Oriented Software**. Illustrated Edition. ed. [S.l.]: Addison-Wesley Professional, 1994.

GAWEDA, A. E. et al. **Model Predictive Control with Reinforcement Learning for Drug Delivery in Renal Anemia Management**. Proc. of the 28th IEEE EMBS Annual International Conference. New York: IEEE. 2006. p. 5177-5180.

GERHARDUS TEN HAGEN, S. H. **Continuous State Space Q-Learning for Control of Nonlinear Systems**. Universiteit van Amsterdam. Amsterdam: PhD Thesis. 2001.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Reading: Addison-Wesley, 1989.

GUYAGULER, B. **Optimization of Well Placement and Assessment of Uncertainty**. Stanford University. PhD. Thesis. 2002.

HAYKIN, S. **Redes Neurais**. 2ª Edição. ed. Porto Alegre: Bookman, 2007.

HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer Feedforward Networks are Universal Approximators. **Neural Networks**, v. II, n. 5, 1989.

HOWARD, R. A. **Dynamic Programming and Markov Processes**. Cambridge: The M.I.T. Press, 1960.

ICA. ANEPI-CI: ANÁLISE ECONÔMICA DE PROJETOS DE E&P SOB INCERTEZA DE CAMPOS INTELIGENTES. ICA - Departamento de Engenharia Elétrica - PUC/Rio. Rio de Janeiro, p. 1-257. 2007.

JAAKKOLA, T.; JORDAN, M. I.; SINGH, S. P. On the convergence of stochastic iterative dynamic programming algorithms. **Neural Computation**, v. VI, n. 6, p. 1185-1201, 1994.

JADBABAIE, A.; YU, J.; HAUSER, J. **Stabilizing Receding Horizon Control of Nonlinear Systems: A Control Lyapunov Function Approach**. Proceedings of the 1999 American Control Conference. San Diego, California: IEEE. 1999. p. 1535-1539.

JANG, J.-S. R.; SUN, C. T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence**. [S.l.]: Prentice-Hall, 1997.

JANG, J.-S. R.; SUN, C.-T. Neuro-Fuzzy Modeling and Control. **Proceedings of IEEE**, v. 83, n. 3, March 1995.

JANSEN, . J. D. et al. **Closed-Loop Reservoir Management**. SPE Reservoir Simulation Symposium. The Woodlands, Texas: [s.n.]. 2009. p. 1-18.

KAELBLING, L. P.; LITTMAN, M. L.; MORRE, A. W. Reinforcement Learning: A Survey. **Journal of Artificial Intelligence Research**, v. 4, p. 237-285, 1996.

KIRK, D. E. **Optimal Control Theory: An Introduction**. New Jersey: Prentice-Hall, 1970.

LAABIDI, K.; BOUANI, F.; KSOURI, M. Multi-criteria optimization in nonlinear predictive control. **Mathematics and Computers in Simulation**, Amsterdam, v. 76, n. 5-6, p. 363–374, January 2008. ISSN 0378-4754.

LENNOX, B.; MONTAGUE, G. Neural Network Control of a Gasoline Engine with Rapid Sampling. In: KOUVARITAKIS, B.; CANNON, M. **Nonlinear Predictive Control: Theory and Practice**. London: IEE Control Engineering, v. 61, 2001. Cap. 12, p. 245-257.

MARQUARDT, D. W. An Algorithm For Least-Square Estimation of Nonlinear Parameters. **Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431-441, June 1963. ISSN 0036-1399.

MARRECO, J. D. M. **Otimização Dinâmica Sob Condição de Incerteza na Produção de Petróleo**. UFMG - CEPEAD. [S.l.].

MATARIĆ, M. J. **Reward Functions for Accelerated Learning**. Machine Learning: Proceedings, Eleventh International Conference. San Francisco: [s.n.]. 1994. p. 181-189.

MELO, B. **Controle Reativo**. Inteligencia Computacional Aplicada DEE PUC-RIO. Rio de Janeiro, p. 14. 2008.

MESSER, B. **Projeto de Poços Multilaterais em Reservatórios de Petróleo Otimizados por Algoritmos Genéticos**. Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro. Msc Thesis. 2009.

MICROSOFT..NET Framework Conceptual Overview. **MSDN**, 2009. Disponível em: <<http://msdn.microsoft.com>>. Acesso em: 27 Novembro 2009.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.

MOHAGHEGH, S. Neural Network: What It Can Do for Petroleum Engineers. **Journal of Petroleum Technology**, p. 42, January 1995. ISSN 1930-0220.

MOHAGHEGH, S. Virtual-Intelligence Applications in Petroleum Engineering: Part I - Artificial Neural Networks. **Journal of Petroleum Technology, Distinguished Author Series**, p. 64-72, September 2000. ISSN 0149-2136.

MOHAGHEGH, S. D. Recent Developments in Application of Artificial Intelligence in Petroleum Engineering. **Journal of Petroleum Technology, Distinguished Author Series**, p. 86-91, April 2005. ISSN 0149-2136.

MORARI, M.; LEE, J. H. Model predictive control: past, present and future. **Computers and Chemical Engineering**, Co. Clare, v. 23, n. 4, p. 667-682, May 1999. ISSN 0098-1354.

NEGENBORN, R. R. **Multi-Agent Model Predictive Control with Applications to Power Networks**. Delft University of Technology. Dutch: PhD. Thesis. 2007. (978-90-5584-093-9).

NEGENBORN, R. R. et al. **Experience-Based Model Predictive Control Using Reinforcement Learning**. Proceedings of the 8th TRAIL Congress – A World of Transport, Infrastructure and Logistic. Rotterdam: Delft University Press. 2004. p. 1-17.

NEGENBORN, R. R. et al. **Learning-Based Model Predictive Control for Markov Decision Processes**. Proceedings of the 16th IFAC World Congress. Prague: Elsevier. 2005. p. 1-7.

NIKOLAOU, M.; CULLICK, A. S.; SAPUTELLI, L. **Production Optimization: A moving Horizon Approach**. Netherlands: SPE 99358. 2006.

NIV, Y. Reinforcement Learning in the Brain. **Journal of Mathematical Psychology**, v. 53, n. 3, p. 119-194, June 2009. ISSN 0022-2496.

OGATA, K. **Ingenieria de Control Moderna**. Cuarta. ed. Madrid: Prentice Hall, 2003.

PUTERMAN, M. L. **Markov Decision Processes: Discrete Stochastic Dynamic Programming**. New Jersey: Wiley & Sons, Inc, 2005.

RAWLINGS, J. B. Tutorial overview of model predictive control. **IEEE Control System Magazine**, v. 20, p. 38-52, 2000.

RIEDMILLER, M. **Application of sequential reinforcement learning to control dynamical systems**. In Proceedings of the IEEE International Conference on Neural Networks. [S.l.]: [s.n.]. 1996. p. 167 - 172.

RUBINSTEIN, R. Y. **Simulation and the Monte Carlo Method**. [S.l.]: John Wiley & Sons, 1981.

SAPUTELLI, L. A. B. **Self-Learning Reservoir Management an Application of Model Predictive Control for Continuous Oilfield Optimization**. University of Houston. Houston. PhD Thesis. 2003.

SAPUTELLI, L. et al. **A Critical Overview of Artificial Neural Network Applications in the Context of Continuous Oil Field Optimization**. SPE Annual Technical Conference and Exhibition. San Antonio: SPE 77703. 2002.

SAPUTELLI, L.; NIKOLAOU, M.; ECONOMIDES, M. J. **Self-Learning Reservoir Management**. SPE Annual Annal Technical Conference an Exhibition. Denver: SPE 84064. 2003. p. 534-547.

SARMA, P. **EFFICIENT CLOSED-LOOP OPTIMAL CONTROL OF PETROLEUM RESERVOIRS UNDER UNCERTAINTY**. STANFORD UNIVERSITY. Stanford. PhD Thesis. 2006.

SARMA, P. et al. Efficient real-time reservoir management using adjoint-based optimal control and model updating. **Computational Geosciences**, v. 10, n. 1, p. 3-36, March 2006. ISSN 1573-1499.

SCHOKNECHT, R.; RIEDMILLER, M. **Using Reinforcement Learning For Engine Control**. ICANN 99. Ninth International Conference on Artificial Neural Networks. [S.l.]: [s.n.]. 1999. p. 329 - 334.

SOLOWAY, D.; HALEY, P. J. **Neural Generalized Predictive Control**. Proceedings of the 1996 IEEE International Symposium in Intelligent Control. Dearborn: IEEE. 1996. p. 277-281.

SOMMERVILLE, I. **Engenharia de Software**. 6ª Edição. ed. São Paulo: Pearson, 2004.

STONE, M. Cross-validation choice and assessment of statistical prediction. **Journal of the Royal Statistical Society**, v. B36, p. 111-133, 1974.

STONE, M. Cross-validation: A review. **Mathematische Operationsforschung Statistiken**, v. 9, p. 127-139, 1978.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. Massachusetts: MIT Press Cambridge, 1998.

TALAVERA, A. G. L. et al. **Controle Preditivo com Aprendizado por Reforço para Produção de Óleo em um Reservatório**. Simpósio Brasileiro de Automação Inteligente. Brasília: SBA. 2009.

THOMAS, J. E. **Fundamentos de Engenharia de Petróleo**. 2da. ed. Rio de Janeiro: Interciência, Editora, 2001. 85-7193-099-6.

TUPAC, Y. J. V. **Rotamento Adaptativo em Redes de Comunicação de Dados por Reinforcement Learning**. Pontifícia Universidade Católica do Rio de Janeiro. Msc. 2000.

TÚPAC, Y. J. V. **Sistema Inteligente de Otimização de Alternativas de Desenvolvimento de Campos Petrolíferos**. Pontifícia Universidade Católica do Rio de Janeiro. PhD. Thesis. 2005.

TUPAC, Y.; TALAVERA, A. **Sistemas e Modelos Inteligentes Aplicados a Reservatórios com Tecnologia de Malha Fechada para a Exploração e Produção de Petróleo e Gás: Controle Reativo**. Relatório 4. ICA: Laboratório de Inteligência Computacional Aplicada - PUC\Rio. Rio de Janeiro, p. 27. 2009.

WANG, C.; GAOMING, L.; REYNOLDS, A. C. Production Optimization in Closed-Loop Reservoir Management. **Society of Petroleum Engineers Journal**, p. 506-523, September 2009.

WATKINS, C. J. C. H. **Learning from Delayed Rewards**. Cambridge University. PhD. Thesis. 1989.

WEISS, G. (Ed.). **Multiagent Systems:** A Modern Approach to Distributed Artificial. Cambridge: The MIT Press, 1999.

YETEN, B. **Optimum Deployment of Nonconventional Wells.** Stanford University. PhD. 2003.

Apêndice

Neste apêndice são mostradas algumas informações referidas ao simulador de reservatórios IMEX utilizado neste trabalho.

O Simulador IMEX

A corporação CMG: *Computing Modelling Group* (CMG. IMEX, 2000) desenvolveu um pacote de aplicações para simulação de reservatório: simulador *black-oil* IMEX, simulador de injeção de gás, editor de malhas para simuladores CMG, gerador de relatórios, visualizador da malha de reservatório em 2D e 3D, e graficador de curvas de resultados. O mais importante destes produtos para este trabalho é o IMEX.

IMEX é um simulador *black-oil* (de três fases que leva em consideração a gravidade e efeitos capilares. O IMEX suporta configurações de *grid* cartesiana, cilíndrica e com profundidade e espessura variáveis. Desta forma é possível mapear as configurações de campos em 2D e 3D.

O IMEX foi programado em FORTRAN 77 e pode ser executado sob diferentes plataformas: mainframes IBM, CDC, CRAY, Honeywell, DEC, Prime, Gould, Unisys, Apollo, SUN, HP, FPS, IBM-PC 486, e família Intel Pentium.

Características do IMEX

O simulador IMEX pode ser executado em três modos: explícito, implícito ou adaptativo. Estes modos, referem-se à forma como são resolvidas as equações não-lineares do modelo de fluxo. No caso de modo explícito, o passo de tempo utilizado deve ser sempre menor que o máximo valor de passo que mantenha a estabilidade do sistema. No modo implícito, é necessário resolver um sistema de equações não lineares a cada passo, podendo ser escolhidos passos maiores. O modo explícito é vantajoso quando as variações dos estados são lentas e não são feitos muitos cálculos, enquanto que o modo implícito é necessário quando existem muitas variações nos estados e fica necessário resolver sistemas de

equações. O modo adaptativo permite escolher entre a solução implícita ou explícita segundo a característica das variações dos estados do sistema.

Geralmente, na malha, só um pequeno número de blocos deve ser tratado de forma totalmente implícita, pois a maioria dos blocos pode ser tratada de forma explícita. Este procedimento é bastante proveitoso para problemas onde só existem grandes fluxos nas proximidades dos poços (efeito *cone*) ou em reservatórios estratificados com camadas bem finas. Utilizando o modo adaptativo o tratamento de forma totalmente implícita é feito apenas onde for necessário, obtendo-se uma grande economia no esforço computacional requerido.

O IMEX suporta também as opções de dupla porosidade e dupla permeabilidade as quais permitem o tratamento de reservatórios com fraturas, onde as fraturas são modeladas como duas partes com porosidade primária e secundária. Já pela dupla permeabilidade é possível modelar a comunicação de fluidos entre as duas partes definidas na fratura.

O simulador IMEX usa uma rotina de solução baseada em eliminação de *Gauss* incompleta, isto serve como um acondicionamento dos dados antes de aplicar o método GMRES (*Generalized Minimum Residual*) que é um método iterativo que permite minimizar a norma do resíduo baseado na geração dos espaços de *Krilov*. Em conjunto, o acondicionamento dos dados e o método GMRES permitem diminuir o custo computacional e os requerimentos de memória quando o número de equações a resolver é muito grande.

Uso do IMEX

Neste simulador a comunicação com o usuário é efetuada através de arquivos de entrada e saída. O usuário deve criar um arquivo texto de entrada (formato .DAT) que contém: a configuração da malha, informação geológica, tipo de fluxo de óleo, condições iniciais, métodos numéricos, lista de poços, entre outras coisas. O simulador, após a execução, fornece os valores de saída em um grupo de arquivos. Esse fluxo de informações é apresentado no seguinte gráfico:




Figura 55 Arquivos de entrada e saída do IMEX

O Arquivo .DAT é imprescindível, uma vez que este arquivo contém todas as informações que definem a configuração completa da reserva a ser simulada. A informação contida no arquivo .DAT está classificada em 7 tipos de dados:

Tabela 7 – Tipos de dados existentes no arquivo .DAT

Tipos de dados usados no arquivo .DAT
1. Dados de controle de Entrada e Saída
2. Dados de descrição do reservatório
3. Propriedades das componentes
4. Dados de Rochas e Fluidos
5. Condições Iniciais
6. Informação sobre os métodos numéricos
7. Informação dos poços e dados recorrentes.

Se a simulação for com recorrência, deverá existir o arquivo .RRF e a entrada seguinte deve estar composta pelo conjunto de arquivos .DAT, .IRF, .MRF e .RRF da última execução.

Os arquivos .OUT e .IRF contêm os resultados globais da simulação, isto é, valores de óleo, gás, água etc. O arquivo .IRF contém o índice dos resultados e o arquivo .OUT armazena os resultados numéricos em si.

Comando INCLUDE

Neste trabalho, os únicos dados a serem alterados do ponto de vista do simulador de reservatório são os relacionados aos poços (informação dos poços e dados descritos na **Tabela 7**).

O comando `*INCLUDE` permite ao simulador quebrar a leitura seqüencial do arquivo de entrada.DAT primário para começar a leitura de um arquivo secundário. Uma vez finalizada a leitura do segundo arquivo (*EOF is reached*), continua-se com a leitura a partir da linha seguinte a que continha o comando `*INCLUDE`. O formato do comando é o seguinte: `*INCLUDE 'arquivosec'`

Este comando facilita a alteração de algumas partes do arquivo .DAT sem afetar o resto. Como mencionado acima, no trabalho proposto precisam ser alterados apenas os dados relacionados aos poços; portanto o arquivo .DAT deve conter um comando `*INCLUDE xxxxxx.dat` no momento que se começa a definição dos poços no campo. Deste modo, os dados de definição de poços (tipo de poços, locações, geometria, parâmetros físicos, restrições, tempos de alterações de válvulas) estarão definidos no arquivo secundário xxxxxx.dat. Com esta estratégia, as mudanças dadas pelo processo de otimização serão fornecidas em um arquivo pequeno, ao invés de se precisar re-criar arquivos .DAT completos.

O Aplicativo Results Report

Todos os resultados da simulação são armazenados em arquivos .OUT e .IRF, sendo que a maioria destes resultados não é necessária para se obter a curva de produção do campo. O aplicativo *results report* (CMG. IMEX, 2000) permite escolher apenas os dados necessários de acordo com a aplicação, servindo como um gerador de relatórios.

No problema em questão precisa-se dos seguintes valores:

- Óleo acumulado em superfície no grupo de poços produtores do campo;
- Gás acumulado em superfície no grupo de poços produtores do campo;
- Afluência de água em superfície no grupo de poços produtores do campo;

- Taxa de Produção de óleo, gás e água em condições de superfície do campo.

Portanto, ao se usar o *results report* com um *script* adequado às necessidades do trabalho, obtém-se os valores acima de forma resumida e legível pelo módulo que calcula o Valor Presente Líquido.

Arquivos Utilizados

A seguir será mostrado os arquivos .dat utilizados neste trabalho: arquivos que descrevem os reservatórios e os poços das alternativas (include.dat).

```
*****
**      Modelo sintético com 3 camadas
*****

*****
** ARQUIVOS DE ENTRADA PARA OS RESTART
**
**FILENAMES *OUTPUT
**          *INDEX-IN '$IRF_FILE'
**          *MAIN-RESULTS-IN '$MRF_FILE'
**          *INDEX-OUT
**          *MAIN-RESULTS-OUT

*INCLUDE 'fileNames.txt'
** *FILENAMES *INDEX-IN 'AVALHOR_IN.irf'
**          *INDEX-OUT
**          *MAIN-RESULTS-IN
**          *MAIN-RESULTS-OUT

*****

*****
** SECAO 1: CONTROLE DE ENTRADA E SAIDA
*****

*TITLE1 'Reservatorio linear 3 camadas'

** CHAMA A RODADA DE RESTART
** Substituir o Tag por *RESTART #TSTEP

** Definição se usa restart ou não
**-----
*INCLUDE 'restart.txt'

*INUNIT *MODSI
*OUTUNIT *MODSI

**WSRF *WELL 1    ** Resultados de poço a cada timestep
**WSRF *GRID 1    ** Resultados de malha a cada timestep

*OUTPRN *WELL *BRIEF
*OUTPRN *GRID *NONE
```

```

*OUTPRN *TABLES *NONE
*OUTPRN *RES *NONE
*OUTSRF *WELL *ALL
*OUTSRF *GRID *SW *SO *PRES

*WRST
**WRST    *TIME    ** Grava os registros de RESTART a cada *TIME ou
*DATE

*****
** SECAO 2: DESCRICAO DO RESERVATORIO
*****

*GRID *CART 40 11 3
*KDIR *DOWN
*DI *CON 50
*DJ *CON 50
*DK *CON 10
*DTOP 440*2000
*NULL *CON 1
*POR *CON 0.20
*PERMI *KVAR
    500
    800
    1200
*PERMJ *KVAR
    500
    800
    1200
*PERMK *KVAR
    50
    70
    120

** Folhelhos entre as camadas 1-2 e 2-3
*TRANSK *IJK 1:40 1:11 1 0.0
*TRANSK *IJK 1:40 1:11 2 0.0
*TRANSK *IJK 1:40 1:11 3 0.0

*CPOR 1.0E-5
*PRPOR 300

*****
** SECAO 3: PROPRIEDADE DOS COMPONENTES
*****

*MODEL *BLACKOIL
*TRES 80.0

** Dados PVT
**PVT *BG 1
**      p      Rs      Bo      Bg      VisO      VisG
** kgf/cm2  m3/m3  m3/m3STD  m3/m3STD  cp      cp
    1.03      0.16      1.0745      3.5200E-01  9.22      5.5317E-03
    7.02      1.32      1.0780      5.1805E-02  8.65      1.1304E-02
   13.01      2.59      1.0819      2.7583E-02  8.10      1.7093E-02
   19.00      3.91      1.0860      1.8774E-02  7.60      2.3519E-02
   24.99      5.28      1.0901      1.4190E-02  7.14      3.0841E-02
   30.98      6.68      1.0944      1.1380E-02  6.72      3.9209E-02
   36.97      8.10      1.0988      9.4819E-03  6.34      4.8760E-02
   42.96      9.55      1.1032      8.1149E-03  5.99      5.9634E-02
   60.92     14.00      1.1168      5.6336E-03  5.14      1.0166E-01
  400.00     281.26      1.3732      1.0000E-03  0.50      8.0812E+00

```

*DENSITY *OIL 850
 *DENSITY *WATER 1000.0
 *GRAVITY *GAS 0.60

*CO 1.1772E-04
 *CVO 1.9980E-02

*BWI 1.0
 *CW 1.0E-05
 *REFPW 100.0
 *VWI 1.0
 *CVW 0.0

 ** SECAO 4: PROPRIEDADES ROCHA-FLUIDO

 *ROCKFLUID

*RPT 1

*SWT

*Sw	krw	krow	Pcow
0.20	0.00000	0.8000	0.
0.22	0.00048	0.7373	0.
0.25	0.00300	0.6480	0.
0.28	0.00768	0.5645	0.
0.30	0.01200	0.5120	0.
0.33	0.02028	0.4381	0.
0.35	0.02700	0.3920	0.
0.38	0.03888	0.3277	0.
0.40	0.04800	0.2880	0.
0.43	0.06348	0.2333	0.
0.45	0.07500	0.2000	0.
0.48	0.09408	0.1549	0.
0.50	0.10800	0.1280	0.
0.53	0.13068	0.0925	0.
0.55	0.14700	0.0720	0.
0.57	0.16428	0.0541	0.
0.60	0.19200	0.0320	0.
0.62	0.21168	0.0205	0.
0.65	0.24300	0.0080	0.
0.70	0.30000	0.0000	0.

*SLT *SMOOTH *PLAW 2.000 2.000 1.0
 0.20 0.90 0.00
 1.00 0.00 0.80

 ** SECAO 5: CONDICOES INICIAIS

 *INITIAL

*VERTICAL *BLOCK_CENTER *WATER_OIL_GAS
 *REFDEPTH 2000
 *REFPRES 250
 *DWOC 3000
 *DGOC 0
 *PB *CON 78.0

 ** SECAO 6: CONTROLE DOS METODOS NUMERICOS

 *NUMERICAL

*AIM *STAB

```
*NCUTS 10
*DTMIN 0.0010
*DTMAX 365
```

```
*****
** SECAO 7: DEFINICAO DOS DADOS DE POCO E DADOS RECORRENTES
*****
*RUN
*DATE 2004 1 1
```

```
*GROUP 'INJETOR1' *ATTACHTO 'INJETORES'
*GROUP 'PRODUCER1' *ATTACHTO 'PRODUTORES'
*GROUP 'PRODUTORES' *ATTACHTO 'FIELD'
*GROUP 'INJETORES' *ATTACHTO 'FIELD'
```

```
*****
** POCO INJETOR - COMPLETACAO INTELIGENTE
*****
*WELL 1 'INJ1' *ATTACHTO 'INJETOR1'
*INJECTOR MOBWEIGHT 'INJ1'
*INCOMP *WATER
```

```
*INCLUDE 'taxav1.txt'
```

```
**OPERATE *MAX *STW 150
**OPERATE *MAX *BHP 400
```

```
*GEOMETRY *K 0.100 0.37 1.0 0
*PERF *GEO 'INJ1'
1 6 1 1.0
```

```
*WELL 2 'INJ2' *ATTACHTO 'INJETOR1'
*INJECTOR MOBWEIGHT 'INJ2'
*INCOMP *WATER
```

```
*INCLUDE 'taxav2.txt'
```

```
**OPERATE *MAX *STW 150
**OPERATE *MAX *BHP 400
```

```
*GEOMETRY *K 0.100 0.37 1.0 0
*PERF *GEO 'INJ2'
1 6 2 1.0
```

```
*WELL 3 'INJ3' *ATTACHTO 'INJETOR1'
*INJECTOR MOBWEIGHT 'INJ3'
*INCOMP *WATER
```

```
*INCLUDE 'taxav3.txt'
```

```
**OPERATE *MAX *STW 150
**OPERATE *MAX *BHP 400
```

```
*GEOMETRY *K 0.100 0.37 1.0 0
*PERF *GEO 'INJ3'
1 6 3 1.0
```

```
*****
*****
```

```
** POCO PRODUTOR - COMPLETACAO INTELIGENTE
```

```
*****
*WELL 4 'PROD1' *ATTACHTO 'PRODUCER1'
```



```

*PRODUCER 'PROD1'
*OPERATE *MAX *STL 400 *CONT *REPEAT
*OPERATE *MIN *BHP 78 *CONT *REPEAT
*GEOMETRY *K 0.100 0.37 1.0 0
*PERF *GEO 'PROD1'
    40  6  1  1.0
    40  6  2  1.0
    40  6  3  1.0
*****
** ===== **
**          ALTERAÇÃO DO PRIMEIRO PARÂMETRO DE OPERAÇÃO          **
** ===== **
*INCLUDE 'alter.txt'

*PERF *GEO 'PROD1'
*INCLUDE 'Completions.txt'

** Definição do próximo passo de tempo (TIME)
** -----
*INCLUDE 'ProxTime.txt'

```