

3

Revisão Bibliográfica

3.1

Ajuste de Histórico

Segundo [6], o ajuste de histórico é definido como um processo de otimização que consiste em encontrar um conjunto de parâmetros do modelo de reservatório que minimiza a diferença entre valores calculados e valores observados, como pressão e taxas de produção de fluidos. Em [7] é encontrada uma definição formal que diz que o processo de ajuste de histórico consiste em determinar uma distribuição espacial R , que pode pertencer a \mathbb{R}^2 ou a \mathbb{R}^3 , e um conjunto de parâmetros de modelo P , tal que, dado o histórico O_h , $O_s - O_h \approx 0$, onde $O_s = f(R, P)$ é a saída do modelo simulado. Nesse contexto, R representa a malha de blocos do modelo de simulação e P representa os valores da propriedade de interesse em cada bloco. Em outras palavras, o problema do ajuste de histórico consiste em encontrar um zero para uma função de múltiplas variáveis que variam em função do tempo, função esta que é representada pelo simulador de reservatórios. Ainda segundo [7], sabe-se que a maior fonte de incertezas de um modelo de reservatório está na sua descrição geológica. Portanto, se for assumido que a sua descrição geológica é verdadeira, então o problema do ajuste de histórico se reduz à determinação do conjunto de parâmetros P do modelo.

As definições apresentadas, no entanto, não levam em consideração o fato de que uma solução que promove um bom ajuste entre as curvas de produção real e simulada, pode não ser a melhor solução para o problema do ajuste de histórico. Como se trata de um problema de otimização mal condicionado, no universo das soluções é possível encontrar várias que, apesar de proporcionarem bons ajustes entre as curvas de produção, não representam adequadamente a realidade do reservatório. Nessas situações, a boa aproximação entre as curvas de produção durante o ajuste de histórico pode não se repetir na etapa de previsão da produção ([2]). Assim, uma boa solução para o problema do ajuste de histórico deve considerar não apenas o melhor ajuste entre as curvas de produção, mas também a distribuição adequada dos parâmetros no modelo do

reservatório.

Essas características tornam o problema de otimização por trás do ajuste de histórico altamente complexo. Por isso, é necessário encontrar formas eficientes de tratar o problema, a fim de obter soluções satisfatórias. Segundo [8] e [2], o processo de ajuste de histórico pode ser realizado de pelo menos três maneiras diferentes: manual, automático e assistido.

3.1.1

Ajuste Manual

No ajuste manual, o critério para se estabelecer uma configuração adequada de parâmetros é totalmente empírico. Os ajustes são totalmente dependentes do especialista que, com base na sua experiência, tenta encontrar a melhor configuração para os parâmetros. Segundo [9], no procedimento de ajuste alteram-se os parâmetros individualmente, ou seja, caso a alteração em um não seja adequada, escolhe-se outro parâmetro para ser ajustado. Assim, todo o trabalho de acompanhamento das simulações e avaliação dos resultados a cada simulação é feito manualmente pelo especialista. Segundo [8], em muitas das vezes a experiência do especialista contribui para que boas soluções sejam encontradas num curto espaço de tempo, mas com o aumento do grau de complexidade do problema a obtenção dessas soluções tende a se tornar muito trabalhosa.

3.1.2

Ajuste Automático

O ajuste automático considera que todas as etapas do processo de ajuste de parâmetros são automatizadas e, portanto, a intervenção do especialista é mínima. Porém, segundo [9], o processo de ajuste é bastante complexo e dificilmente será automatizado em sua totalidade. As principais decisões devem continuar sendo tomadas com cuidado pelo especialista a fim de evitar respostas erradas e simulações desnecessárias.

3.1.3

Ajuste Assistido

Para [8], o ajuste assistido é a tentativa de unir as vantagens do ajuste manual e do ajuste automático. O ajuste assistido combina a automatização de determinadas partes do processo com as tomadas de decisões baseadas na experiência do especialista. Assim, enquanto as técnicas de otimização se encarregam de explorar melhor o espaço de soluções, o especialista tem

a liberdade de interferir no processo de otimização a fim de colaborar para a obtenção de resultados melhores.

Em [10] são apresentados alguns fluxogramas com atividades específicas que devem ser realizadas para o ajuste assistido. As instruções presentes nesses fluxogramas variam de acordo com as características particulares do reservatório em que o ajuste está sendo aplicado e também de acordo com as técnicas utilizadas para a realização do ajuste.

Em [10] é apresentado também um exemplo que ilustra como a participação do especialista durante o ajuste de histórico pode ser benéfica. Trata-se de um modelo de reservatório cujo ajuste manual se mostrou muito difícil. A cada ciclo de otimização foi efetuado algum tipo de intervenção do especialista, que permitiu que resultados melhores, em termos de função objetivo, fossem obtidos. O gráfico da Figura 3.1 mostra o comportamento da função objetivo e os dias indicados correspondem às intervenções.

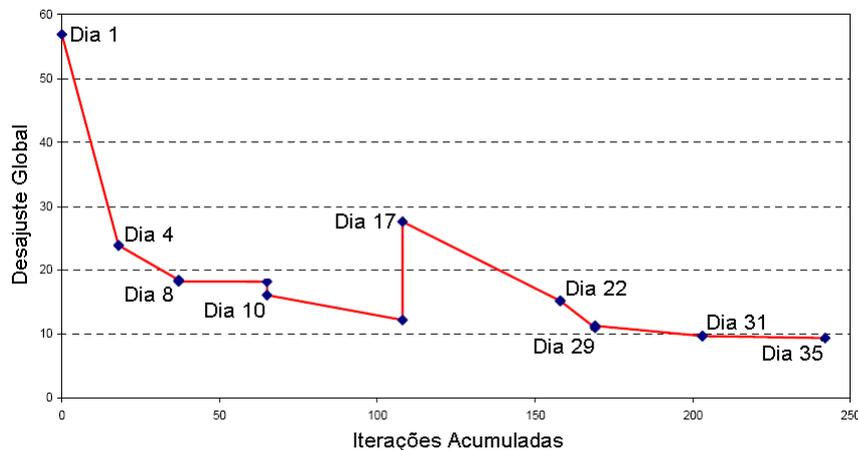


Figura 3.1: Progresso do ajuste de histórico assistido (*Adaptado de Schulze-Riegert e Ghedan, 2007*)

3.2

Abordagens para o Ajuste de Histórico

No ajuste de histórico, a busca pelos parâmetros do modelo de reservatório que minimizam a função objetivo exige que seja utilizada alguma técnica de otimização. A literatura especializada traz diversas técnicas que podem ser empregadas na busca por essa configuração ótima de parâmetros ([11], [12], [13]). O maior desafio consiste em modelar adequadamente o problema para que uma determinada técnica possa ser aplicada. Diante da diversidade de técnicas existentes, em [8] os métodos de otimização para o ajuste de histórico são divididos em dois grupos: métodos locais e métodos globais. No entanto,

neste trabalho é adotada uma classificação mais fragmentada que, além dos grupos citados, considera também os métodos baseados em Inteligência Computacional, os métodos baseados em linhas de corrente, os métodos estocásticos e as novas tendências. Vale destacar que essas divisões não são mutuamente exclusivas. Os Algoritmos Genéticos, por exemplo, pertencem ao grupo dos métodos globais, dos métodos baseados em Inteligência Computacional e ao grupo dos métodos estocásticos.

3.2.1 Métodos Locais

Nos métodos locais, a cada passo de simulação, os parâmetros envolvidos no processo de otimização são atualizados com base no cálculo do gradiente da função objetivo (métrica de erro) em relação a cada parâmetro. Métodos dessa natureza apresentam uma tendência natural de convergência para ótimos locais, o que limita a sua capacidade de explorar o espaço de soluções. Devido a essas características, esses métodos funcionam melhor como um mecanismo de ajuste fino de uma solução previamente encontrada. Alguns dos principais métodos de otimização desse tipo são: Descida por Gradiente, Gauss-Newton, Quasi-Newton e Levenberg-Marquardt.

O trabalho desenvolvido em [14] é uma das primeiras aplicações de métodos baseados em gradiente na otimização de propriedades em modelos de reservatórios. O trabalho utiliza o método de Newton para o ajuste dos parâmetros e, a fim de diminuir a quantidade de parâmetros a serem otimizados, o reservatório é dividido em regiões, de maneira que cada região apresenta um comportamento homogêneo para a propriedade de interesse.

Em [15] um método de regressão não linear é utilizado no estudo de dois casos. Na abordagem proposta, o reservatório é particionado através de uma análise denominada *gradzone*. Dada uma propriedade, essa análise é capaz de selecionar zonas no modelo do reservatório de maneira que, em cada zona, pode ser aplicado um multiplicador a todas as células. Dessa forma, em vez de assumir o mesmo valor em todas as células dentro de uma zona, a propriedade de interesse pode assumir valores diferentes, porém, seus valores relativos se mantêm constantes.

Em [16] é apresentada a aplicação de uma ferramenta semi-automática para ajuste de histórico que auxilia o especialista durante o processo. A otimização dos parâmetros é realizada por meio de um algoritmo denominado *dog-leg* que dá informações qualitativas e quantitativas importantes para o melhor ajuste dos parâmetros. O algoritmo combina os métodos de Gradiente Decrescente e de Gauss-Newton e tenta obter tanto robustez numérica quando

está longe da solução, quanto convergência rápida quando está perto da solução.

Em [17] é investigada uma abordagem que utiliza informações prévias do modelo geológico para auxiliar no processo de ajuste do modelo. Essas informações são obtidas a partir dos variogramas usados para simular as propriedades do reservatório. O variograma é um método geoestatístico que permite descrever quantitativamente a maneira como uma determinada propriedade está distribuída ao longo do reservatório. As informações fornecidas pelos variogramas, conjugadas com um método baseado em gradiente, são usadas tanto para selecionar os parâmetros mais sensíveis durante o processo de otimização, quanto para impor restrições geológicas aos modelos gerados.

Em [18] é proposto um método automático que ajusta os parâmetros geológicos do modelo. O método parte do princípio de que as maiores incertezas presentes no processo de ajuste estão na estrutura geológica do reservatório, ou seja, na sua geometria, e não em propriedades como permeabilidade e porosidade. Em reservatórios complexos, a geometria é um fator muito importante, uma vez que a justaposição de camadas influencia na transmissibilidade e as falhas influenciam no fluxo dos fluidos. Com base nisso, o método propõe a parametrização de objetos geométricos e a otimização desses parâmetros por meio de um algoritmo de Levenberg-Marquardt.

Em [19] e [20] é investigada a utilização dos métodos *forward* e adjunto para o cálculo das derivadas em métodos de otimização baseados em gradiente. A utilização da abordagem proposta não está restrita aos algoritmos clássicos de otimização e, para verificar sua abrangência, é utilizada em uma variante da análise *gradzone* para selecionar os parâmetros mais relevantes para o ajuste de histórico.

Todas essas abordagens têm em comum a utilização de algum método de otimização baseado em gradiente. Além da convergência prematura e da possibilidade de aprisionamento em mínimos locais, a utilização desses métodos se restringe a situações em que se tem acesso ao valor do gradiente. Isso dificulta a utilização dessas abordagens com simuladores comerciais, onde o gradiente é calculado internamente no código do simulador e, portanto, não está disponível para aplicações externas. O não acesso ao valor do gradiente pode ser contornado com a utilização de algum método capaz de estimar esse valor. Porém, o desempenho dessas abordagens passa a depender também da qualidade das estimativas.

3.2.2

Métodos Globais

Diferentemente dos métodos baseados em gradiente, durante o processo de otimização, os métodos globais levam em consideração apenas o valor da função objetivo e não necessitam do cálculo dos gradientes internos. Isso os tornam menos suscetíveis a ficarem presos em ótimos locais, porém o seu tempo de convergência costuma ser bem mais elevado que o tempo gasto pelos métodos baseados em gradiente. Devido a essas características, esses métodos são mais adequados para a busca de uma solução aceitável, que não necessariamente seja uma solução ótima, para um problema de otimização. Dentre os métodos de otimização desse tipo estão: Busca Direta, Algoritmos Genéticos, Estratégias Evolutivas e Recozimento Simulado (*Simulated Annealing*).

Em [21] e [22] é proposto um algoritmo que combina uma estratégia de busca direta com uma busca exploratória, que são realizadas em um espaço discreto de parâmetros. A busca direta é feita de forma linear no espaço de parâmetros e a busca exploratória tem a finalidade de indicar a direção e o sentido em que a busca direta deve ser realizada. Nessa proposta a busca direta está limitada às direções horizontal e vertical, mas em [23] é apresentada uma modificação que dá maior flexibilidade ao algoritmo, permitindo buscas diretas também na diagonal.

Em [24] é proposta uma heurística cuja finalidade é identificar o melhor ponto de partida para o algoritmo proposto em [21]. Para isso, é realizada uma amostragem inicial, a partir da qual é possível determinar a região mais promissora do espaço de parâmetros. Uma vez identificada, a busca é iniciada a partir dessa região.

Nas abordagens com busca direta, apesar de não haver a necessidade de calcular o gradiente da função objetivo, o funcionamento do método é semelhante a um método baseado em gradiente e, por isso, está sujeito às mesmas limitações já mencionadas. Mesmo que a amostragem inicial evite, o algoritmo ainda pode convergir precocemente para um mínimo local.

Em [4] é apresentado um estudo sobre a aplicação de computação evolutiva na indústria do petróleo, especialmente na área de E&P. São citados trabalhos que utilizam não apenas os Algoritmos Genéticos, mas também outras técnicas de Inteligência Computacional, em problemas que envolvem, por exemplo, caracterização de reservatórios, inversão sísmica e localização de poços.

Em [25] é apresentado um dos primeiros trabalhos que utiliza Algoritmos Genéticos para a otimização de propriedades em modelos de reservatórios. Nessa abordagem proposta, cada gene do cromossomo armazena os valores

de permeabilidade (horizontal e vertical) e de porosidade em uma célula do modelo, logo, um cromossomo descreve unicamente uma realização do modelo. Todavia, a abordagem apresenta limitações devido à simplicidade dos operadores genéticos empregados, que não impedem a geração de realizações do modelo que, embora ajustem o histórico, apresentam contrastes geológicos acentuados entre células vizinhas.

Em [26], [27] e [28] também são utilizados Algoritmos Genéticos para a caracterização de reservatórios. Contudo, para diminuir a quantidade de parâmetros a serem otimizados, em vez de representar todas as células do modelo, o cromossomo é composto por seis segmentos cujos genes codificam diferentes tipos de parâmetros do reservatório. Três dos segmentos utilizam representação real e têm estrutura multidimensional, enquanto os outros três utilizam representação binária e são unidimensionais. Os três segmentos multidimensionais representam, respectivamente, as propriedades porosidade, permeabilidade e fração de volume de óleo em determinadas células, denominadas pontos piloto, e também nas células em que os poços são completados. Os valores das propriedades nos outros pontos são obtidos por meio de interpolação geoestatística. Os outros três segmentos do cromossomo representam os parâmetros geoestatísticos, os parâmetros de falhas e fatores de *skin* dos poços. Os parâmetros geoestatísticos são usados nas simulações realizadas para estimar a propriedade nos pontos em que não é conhecida. Os parâmetros de falha são usados para calcular as transmissibilidades entre as possíveis falhas existentes no reservatório. Por fim, os fatores de *skin* são úteis para o cálculo das taxas de fluxo do poços.

A abordagem se mostra interessante por reduzir o tamanho do espaço de busca que deve ser explorado pelo algoritmo genético. Porém, a maneira como o cromossomo é modelado não garante a unicidade da solução, caso o modelo seja gerado por simulação sequencial. Isso significa que um mesmo cromossomo pode gerar modelos diferentes e, portanto, ter avaliações diferentes, o que pode comprometer o processo evolutivo.

Em [29] é proposta outra metodologia que integra Geoestatística e Algoritmos Genéticos para o ajuste de histórico. Inicialmente, é gerado um conjunto de realizações geoestatísticas de mapas de distribuição litológica, de porosidade e de permeabilidade. O cromossomo que modela a solução tem representação binária e codifica os seguintes parâmetros: os identificadores das realizações dos mapas de litofácies, de porosidade e de permeabilidade, a razão entre as permeabilidades vertical e horizontal e o expoente da equação de elevação de escala da permeabilidade horizontal. Os três primeiros parâmetros assumem valores inteiros dentro do intervalo do número de realizações estabelecido para

cada tipo de mapa. Os dois últimos assumem valores reais dentro de um intervalo discreto de valores estabelecidos para a razão entre as permeabilidades e para o expoente da equação.

Nessa metodologia, além da diminuição do espaço de busca, a unicidade da solução é mantida. No entanto, a codificação dos índices das realizações dos mapas e não das realizações em si, limita a atuação do operador de cruzamento, uma vez que há apenas recombinações entre os índices dos mapas e não entre os próprios mapas ao longo do processo evolutivo.

3.2.3

Métodos Baseados em Inteligência Computacional

Além dos métodos evolutivos, há também trabalhos que utilizam outras técnicas de Inteligência Computacional para auxiliar no ajuste de modelos de reservatórios. Em [30], por exemplo, é utilizada uma rede neural SOM (*Self Organizing Map*) para agrupar os blocos constituintes do reservatório em agrupamentos com comportamentos semelhantes. Essas semelhanças podem estar presentes tanto nas características geológicas quanto nas características estáticas e dinâmicas dos fluidos. A criação desses agrupamentos reduz a complexidade do problema e direciona a otimização para as regiões mais desajustadas. A utilização de multiplicadores, no entanto, força uma relação constante entre os valores dentro de uma região. Assim, o ajuste dos parâmetros pode se tornar mais difícil caso a relação entre os valores não seja a ideal.

Em [31] propõe-se a utilização de uma rede neural MLP (*Multi Layer Perceptron*) para prever os valores de algumas propriedades do reservatório que proporcionem um melhor ajuste do histórico. A partir de um modelo base, cuja simulação representa a produção real do reservatório, são gerados alguns modelos em que propriedades como permeabilidade e porosidade são modificadas. Assim, ao simular cada modelo modificado, obtém-se um histórico de produção diferente. Para treinar a rede neural, os dados de entrada são as diferenças entre a produção de fluidos nos modelos modificados e no caso base, em intervalos específicos. As propriedades modificadas, usadas para gerar as curvas de produção em cada modelo modificado, representam as respostas desejadas para os dados de entrada durante o treinamento da rede neural. A finalidade da rede neural é criar um mapeamento que relaciona as disparidades entre os valores de produção e os valores das propriedades. Assim, uma vez treinada e testada, aplica-se à rede um conjunto de entradas cujos valores representam diferenças aceitáveis entre as produções, e obtém-se como saída os valores das propriedades que proporcionam um bom ajuste de histórico.

Essa abordagem é adequada para modelos com propriedades homogêneas

ou modelos particionados em regiões homogêneas. Entretanto, em modelos mais complexos, as entradas da rede, definidas como a diferença entre os valores de produção, não têm informação suficiente para que a rede estabeleça um mapeamento correto entre elas e as propriedades do reservatório.

3.2.4 Métodos Baseados em Linhas de Corrente

Em [32] e [33] é utilizada a simulação por linhas de corrente como um subsídio para o ajuste de histórico dos campos Albacora Leste e Barracuda, cujos direitos de exploração são exercidos pela Petrobras. Segundo [32], a simulação por linhas de corrente complementa a simulação numérica tradicional, ou seja, a simulação por diferenças finitas, provendo informações como o volume poroso drenado por cada poço produtor, o volume poroso varrido por cada poço injetor e o volume de injeção recebido por cada poço produtor. As informações de volume poroso varrido e volume poroso drenado permitem a identificação das regiões de atuação de cada poço dentro do reservatório. Dessa forma, é possível segmentar o modelo e realizar o ajuste por região do reservatório. Tanto em [32] quanto em [33] o processo de ajuste consiste em encontrar o multiplicador mais adequado para cada região do reservatório. No primeiro caso, os multiplicadores foram determinados após interação com os geocientistas que trabalham diretamente no campo de Barracuda, enquanto no segundo, os multiplicadores foram obtidos por meio de uma ferramenta computacional de otimização.

A identificação de regiões por meio das linhas de corrente é uma alternativa interessante em relação à análise *gradzone* e ao particionamento manual adotado em [14]. Os parâmetros otimizados, porém, são os multiplicadores associados a cada região e, como mencionado, podem dificultar o ajuste caso a relação entre os valores não seja apropriada. O ajuste manual, por sua vez, limita a capacidade de exploração do espaço de busca dos multiplicadores.

3.2.5 Métodos Estocásticos

Até o momento, os trabalhos citados que conjugam Geoestatística com algum método de otimização, utilizam a Geoestatística tradicional. Todavia, a técnica tradicional pode não ser a mais apropriada para construir mapas em que o padrão de comportamento da propriedade de interesse é mais complexo como, por exemplo, os canais curvilíneos em um mapa de permeabilidade. Nesses casos, o uso da Geoestatística de Múltiplos Pontos, que é detalhada na Seção 4.1.3, pode proporcionar mapas mais realistas.

Em [34] e [35] é proposto o método de perturbação da probabilidade que, em vez de modificar diretamente os valores da propriedade nas células do modelo, altera as distribuições de probabilidade usadas para gerar o modelo. A perturbação da probabilidade, e não diretamente da propriedade, é uma alternativa interessante porque mantém a continuidade geológica do modelo. O processo de otimização se encarrega de encontrar o parâmetro de perturbação que permite a geração de realizações que melhor ajustam o histórico de produção. Para que modelos mais realistas sejam obtidos, as realizações são geradas por simulação sequencial usando o algoritmo *SNESIM* (*Single Normal Equation Simulation*), que é baseado em Geoestatística de Múltiplos Pontos. A mesma perturbação, porém, é imposta a todo o modelo, o que limita a aplicação do método a modelos geologicamente simples e com poucos poços.

Em [36], [37] e [38] o método de perturbação da probabilidade original é modificado para que possa ser aplicado a reservatórios mais complexos. Para a aplicação das perturbações, o modelo é dividido em regiões de acordo com a localização dos poços. Assim, ao longo do processo de ajuste, a perturbação é aplicada somente nas regiões dos poços cujo ajuste ainda não é satisfatório. Assim como no método original, as realizações também são geradas através do algoritmo *SNESIM*.

O algoritmo *SNESIM*, empregado em ambos os métodos de perturbação da probabilidade, se limita à simulação apenas de propriedades de natureza categórica como, por exemplo, mapas de fácies (arenito e folhelho). Portanto, não se aplica à simulação de propriedades contínuas como, por exemplo, mapas de permeabilidade e de porosidade.

Em [39] é proposto o método de deformação gradual, cujo princípio é a geração de novas realizações de um modelo através da suavização de realizações anteriores. Para isso, é introduzido um coeficiente de correlação entre a nova realização e a realização obtida no passo anterior. Para que esse princípio seja aplicado a propriedades contínuas, a solução proposta é gerar novas realizações como combinações lineares de dois modelos anteriores.

Em [40] combina-se o método de deformação gradual, a simulação de modelos com Geoestatística Multiponto, e a simulação por linhas de corrente. Enquanto a geoestatística se encarrega da geração de modelos mais realistas, a simulação por linhas de corrente define as zonas de influência dos poços, a fim de que as deformações graduais sejam aplicadas localmente.

A deformação gradual, no entanto, precisa partir de valores que estejam próximos da solução para que a convergência ocorra em um tempo razoável. Além disso, em modelos com continuidades geológicas em grande escala, como canais de permeabilidade, a continuidade do modelo pode ser danificada.

3.2.6 Novas Tendências

Todas as abordagens apresentadas até aqui, lidam com o ajuste de histórico de forma pontual. Diferentemente delas, em [41] o ajuste de histórico é tido como parte de um processo mais amplo, denominado gerenciamento de reservatório em malha fechada, ou ainda, gerenciamento de reservatório em tempo real. Nesse processo estão envolvidos o uso de modelos de reservatório e de sistema de produção em combinação com medições de produção e outros dados como, por exemplo, aqueles provenientes de análise sísmica. O interesse por trás dessa nova visão do problema, é poder atualizar continuamente os modelos à medida que novos dados são adquiridos. Contudo, para que essa abordagem seja viável, é necessário não só o desenvolvimento das técnicas de otimização e de aquisição de dados, mas também a integração adequada dessas técnicas.

Em [42] é proposto um procedimento combinado de otimização de válvulas e de ajuste de histórico. A abordagem prevê a atualização contínua do modelo geológico usando dados provenientes de sensores de fundo de poço. Evidentemente, a aplicação dessa abordagem depende da existência de sensores e de válvulas nos poços, o que não é a realidade da maioria dos poços que se encontram em operação. Ademais, os sensores atuais não fornecem diretamente as taxas de fluxo, que devem ser estimadas a partir da temperatura e da pressão. No entanto, é razoável assumir que no futuro os poços terão a tecnologia suficiente para que abordagens como essa sejam adotadas.