

5 Preparação dos Resultados

Tendo os especialistas, ou as equipes de avaliação de recursos não descobertos, chegado a uma conclusão sobre determinado *play* ou outra unidade geológica estes resultados devem ser combinados para gerar um único que represente o consenso ou, de alguma forma, o resultado mais recomendado.

Porém, podemos afirmar que a opinião de um grupo de especialistas seria melhor que a de um único? É claro, depende dos especialistas e de que forma suas opiniões serão combinadas e se será possível confiar nesta solução. Alguns estudiosos desenvolvem trabalhos a respeito da combinação destas informações (Loveridge, 2004).

Daneshkah (2004) comenta que o processo de eliciação de opiniões dos membros de um grupo realizado simultaneamente sem controle de interação entre eles pode ser mais propenso a erros e vieses. Isto porque a opinião de um avaliador pode ficar **ancorada** a de outro, deixando assim de expressar suas verdadeiras crenças.

Resultados individuais, geralmente, devem ser agregados para se obter um resultado com mais informação e de maior confiabilidade. Nas subseções a seguir serão tratadas as formas mais divulgadas e aplicadas de combinação de resultados (distribuições de probabilidades), são estas: a abordagem matemática, que é composta de métodos axiomáticos e do método bayesiano, e a abordagem comportamental.

A **confiança** pode ser aumentada pelos métodos de combinação de probabilidades subjetivas e isso deve se refletir em redução da variabilidade e/ou viés. A **validação** tem ligações com pelo menos dois aspectos, **discriminação** e

calibração. A discriminação pode ocorrer se os especialistas cujos julgamentos refletem maior conhecimento têm mais influência, sendo então mais pesadamente ponderado, estando em uma maioria, ou influenciando outros. Um grupo quando avalia a possibilidade de ocorrência de eventos pode ser afetado por um tipo de **efeito votação.** Este efeito ocorre quando os avaliadores mais célebres expõem suas opiniões e os demais aceitam e corroboram sem maiores críticas (Daneshkahi, 2004).

A discriminação afeta a calibração dos julgamentos individuais, conduzindo estes julgadores à subconfiança em seus resultados. Isto deve ser esperado em agregação de julgamentos. Outras situações podem afetar a calibração e, por isso tais situações e seus efeitos precisam ser determinados empiricamente para uma possível correção.

Clemen (1999) apresenta um estudo abrangente sobre combinação de opiniões de especialistas. Os aspectos mais relevantes por ele discutidos são apresentados a seguir.

5.1 Abordagem Matemática para Combinação de Probabilidades

Com a combinação das probabilidades subjetivas eliciadas de um especialista pretende-se melhorar a qualidade (principalmente, a confiabilidade) das probabilidades utilizadas em análises de decisões. Alguns métodos de agregação podem ser classificados como “matemáticos”, e existem muitos deles. O simples cálculo da média aritmética é um bom exemplo, de comportamento no qual os especialistas concordam em combinar suas opiniões em um único valor. Em alguns casos há uma interação controlada entre os especialistas, seguida por uma combinação matemática, formando assim um método misto.

Métodos mistos (parte comportamentais e parte matemáticos) são aplicados para inibir os efeitos negativos da interação de grupos, como personalidades dominantes, ou diferença entre status, mas devem reter o compartilhamento útil da informação.

Não é óbvio como a qualidade da probabilidade subjetiva e a calibração são particularmente afetadas pela combinação. **Coerência** aqui é tida como sendo a concordância com aspectos que não têm origem nos dados, mas que são imperativos decorrentes de considerações lógicas e de conhecimentos prévios. A coerência pode ser violada por métodos matemáticos de combinação e, por isso, ao se propor métodos matemáticos não baseados na teoria da probabilidade (que por si mesma garante coerência), é conveniente impor algumas propriedades que devem ser por eles satisfeitas, ou seja, impor certos axiomas.

Probabilidades subjetivas devem representar a **verdadeira opinião** do julgador, e isso deve ser assegurado para os indivíduos, tanto quanto possível, pelo processo de eliciação; mas não é uma consideração definitiva para combinar valores individuais. Isto é, apesar da opinião individual refletir o melhor julgamento possível para cada avaliador, o resultado final da combinação das opiniões dos integrantes do grupo não deve, necessariamente, refletir um consenso ou coincidir com o melhor julgamento de qualquer de seus membros.

Porém, ainda segundo Clemen (1999), observando somente as avaliações quantitativas, o resultado em grupo é geralmente apenas um pouco superior (cerca de 1/8 do desvio padrão) mais acurado que as avaliações individuais. Entretanto para a indústria do petróleo qualquer incremento em sua precisão pode representar significativo aumento do retorno da carteira de investimentos.

5.1.1 Métodos Axiomáticos

Os estudos mais antigos focavam, na maioria dos casos, métodos matemáticos de combinação de distribuições de probabilidades baseados em axiomas. O objetivo disso era obter métodos que gerassem resultados com certas propriedades desejadas.

O **método de combinação linear** possui muitos adeptos, pela sua forma simples de obter os resultados desejados. O modelo é apresentado a seguir:

$$p^* = \sum_{i=1}^n p_i \cdot w_i \quad \therefore \sum_{i=1}^n w_i = 1 \text{ e } w_i > 0, \forall i \quad (5.1.1)$$

Onde,

- n é o número de especialistas;
- p_i é a distribuição de probabilidade ou densidade de probabilidade apresentada pelo especialista i ;
- w_i é o peso atribuído à opinião do especialista;
- p^* é a distribuição de probabilidade ou densidade da combinação.

É possível observar que este método, muito utilizado em agregação de resultados, apresenta apenas uma média ponderada das opiniões dos especialistas e o peso w pode ser o nível de confiança atribuído ao especialista. Na prática atribuir pesos é extremamente complexo, pois envolve qualificar especialistas com diferentes tempos de atuação, diferentes escolas, ou seja, diferentes méritos e deméritos sem que o significado dos pesos seja muito claro. Outra observação importante é que o mesmo peso é dado para qualquer parte da distribuição fornecida pelo especialista. Por exemplo, suponhamos que um especialista sabidamente superestima as probabilidades de valores baixos, mas é bem calibrado nas estimativas de valores altos e outro especialista, ao contrário, subestima as probabilidades de valores altos, mas é bem calibrado para valores baixos. Como o peso é único para cada especialista, a combinação não resultará no melhor que se poderia ter dado que se sabe dessas características de cada um dos avaliadores.

Este método respeita um número considerável de axiomas (ver Clemen, 1999), entretanto, destaca-se na literatura, um axioma que só obtido com o uso deste tipo de combinação, que é a **propriedade de marginalização**. Expresso grosseiramente, este axioma exige que, dada as distribuições conjuntas de variáveis estimadas por especialistas, a distribuição marginal combinada de cada variável seja igual à distribuição marginal da combinação das estimativas multivariadas.

Outro método axiomático importante é o **método logarítmico de combinações** que é representado pela expressão abaixo:

$$p^* = \prod_i p_i^{w_i} \quad \therefore \sum_i w_i = 1 \text{ e } w_i > 0, \forall i \quad (5.1.2)$$

A soma dos pesos (w_i) deve ser igual a 1. A combinação no método logarítmico é a média geométrica ponderada das opiniões p_i , se os pesos são iguais a $(1/n)$. O axioma respeitado por este método é chamado de **Bayesianidade Externa**, o que quer dizer que a cada nova opinião dada; é possível recalcular a combinação com todas as opiniões, inclusive a nova, tendo resultado igual a realizar a ponderação entre a nova opinião e a combinação anterior.

Os métodos axiomáticos não consideram a calibração dos avaliadores. Estes métodos utilizam pesos (w_i) para tentar dar o valor adequado a opinião de cada avaliador. Geralmente, estes pesos são auto atribuídos ou escolhidos em consenso. A dificuldade neste processo é que geralmente em uma equipe existem diferentes graus de experiência e conhecimento entre os especialistas, o que pode levar a superestimação da avaliação de uns e subestimação de outros, que é um viés que deve ser evitado.

Nos métodos axiomáticos, independentemente dos w_i 's, um axioma fundamental é que sempre que todos os especialistas fornecem a mesma probabilidade, a probabilidade combinada deverá ser igual a probabilidade dada.

5.1.2 Métodos Bayesianos

Muitos autores defendem que para uma situação típica de análise de risco, um método bayesiano de atualização (combinação) de probabilidades é o método mais adequado (Clemen, 1999). O autor discute uma estrutura apresentada inicialmente por Morris (1974, 1977) estabelecendo um novo paradigma para agregação de informação de especialistas.

Inicialmente, supõe-se que o tomador de decisão tenha uma opinião inicial, uma probabilidade a priori definida por $p_0 = P(\theta)$, de que o evento θ ocorra. Naturalmente, a probabilidade complementar $1 - p_0 = P(\bar{\theta})$ representa a probabilidade a priori de que o evento θ não ocorra.

Se n especialistas emitem seu parecer sobre o acontecimento do evento, ou seja, determinam a probabilidade da ocorrência do evento (p_1, p_2, \dots, p_n) de interesse do tomador de decisão. Este deverá utilizar o Teorema de Bayes para atualizar a sua probabilidade a priori.

$$p^* = P(\theta | p_1, p_2, \dots, p_n) \therefore \frac{P(p_1, p_2, \dots, p_n | \theta) \cdot P(\theta)}{P(p_1, p_2, \dots, p_n)} \quad (5.1.3)$$

Segundo Clemen (1999), este esquema de atualização pode ser utilizado para inúmeros tipos de informações, desde combinações de pontos de previsão ou combinação de probabilidades individuais ou distribuições.

A abordagem bayesiana apresenta a difícil tarefa de obter a probabilidade conjunta dos especialistas dado que ocorra o evento, $P(p_1, p_2, \dots, p_n | \theta)$, que é necessária para obter a relação entre θ e (p_1, p_2, \dots, p_n) .

Nos últimos anos, o estudo da abordagem bayesiana vem crescendo, mas em aplicações reais a abordagem axiomática para combinações ainda é muito mais presente, principalmente pela praticidade. Entretanto, intuitivamente se percebe que a abordagem bayesiana é bem mais sensível aos vieses dos especialistas.

Na dificuldade de obter diretamente a expressão (5.1.3) outros modelos foram criados para agregação de probabilidades.

Para agregar p_i ($i = 1, 2, \dots, n$) usando o método Bayesiano, é mais simples expressar a combinação em termos de chances (chance é entendida como sendo a probabilidade de ocorrência sobre a probabilidade de não-ocorrência do evento) a posteriori de ocorrência de θ e tomando a expressão (5.1.3), o modelo apresenta-se da seguinte forma:

$$q^* = \frac{p^*}{1 - p^*} = \frac{P(\theta | p_1, p_2, \dots, p_n)}{P(\bar{\theta} | p_1, p_2, \dots, p_n)} = \frac{\frac{P(p_1, p_2, \dots, p_n | \theta) \cdot P(\theta)}{P(p_1, p_2, \dots, p_n)}}{\frac{P(p_1, p_2, \dots, p_n | \bar{\theta}) \cdot P(\bar{\theta})}{P(p_1, p_2, \dots, p_n)}} \quad (5.1.4)$$

Considerando independência entre os especialistas, temos:

$$q^* = \frac{p_0}{1 - p_0} \cdot \prod_{i=1}^n \frac{P(p_i | \theta)}{P(p_i | \bar{\theta})} \quad (5.1.5)$$

Onde,

- $P(p_i | \theta)$ é a probabilidade do especialista i dar a probabilidade p_i dado que o evento ocorreu;
- p_0 é a probabilidade a priori associada a impressão inicial do tomador de decisão sobre a ocorrência do evento;
- θ é o evento avaliado;
- q^* é a incerteza resultante em termos de chances.

Algumas observações podem ser feitas sobre o impacto da calibração do especialista sobre o valor da probabilidade a posteriori obtida através da abordagem bayesiana.

Para facilitar o entendimento das vantagens do método Bayesiano, define-se aqui o “avaliador bom” como aquele cujo histórico de previsões sobre um evento θ mostra que nas situações em que o evento θ ocorreu a frequência com que ele “disse” uma dada probabilidade foi tanto maior quanto maior foi essa dita probabilidade e quando θ não ocorreu, a frequência com que ele “disse” uma dada probabilidade foi tanto menor quanto maior foi essa dita probabilidade.

Um mau avaliador tem um histórico de previsões no qual a frequência de ele “dizer” uma dada probabilidade “dado que θ ocorre” é próxima à frequência de ele “dizer” esta mesma probabilidade “dado que θ não ocorre”, pois a sua opinião não será relevante e não trará nenhuma nova informação para a avaliação.

Finalmente, um avaliador sistematicamente tendencioso é aquele que a frequência das probabilidades em suas previsões sobre θ tem comportamento oposto ao do bom especialista. Apesar deste último trazer informações incorretas, elas passam a possuir um significado oposto ao previsto e esta opinião passa a ser útil na avaliação.

No exemplo que segue, é possível perceber que quando são utilizados especialistas bons, maus e tendenciosos em uma avaliação, ou somente avaliadores ruins, dado que houve consenso ($p_0 = p_1 = \dots = p_n$), a probabilidade a posteriori é próxima à obtida utilizando os métodos axiomáticos, que é próxima a probabilidade consensual. Deve-se perceber que este exemplo é um caso pouco comum, pois seria natural que o especialista enviesado fornecesse probabilidades baixas quando o bom especialista fornecer altas probabilidades.

Vejam os seguintes exemplos, ilustrando o caso supracitado:

Se pretende obter o risco geológico de um determinado *play*, dada a probabilidade a priori: $p_0 = 0,75$, emitida pelo chefe de avaliação, e a opinião dos avaliadores todas iguais a $p_i = 0,75$, calculamos a probabilidade p^* , como segue:

p_i	$P(p_1 \theta)$	$P(p_1 \bar{\theta})$	$P(p_2 \theta)$	$P(p_2 \bar{\theta})$	$P(p_3 \theta)$	$P(p_3 \bar{\theta})$
5%	10%	25%	18%	20%	38%	15%
25%	10%	23%	21%	22%	22%	16%
50%	15%	21%	18%	19%	16%	18%
75%	23%	16%	21%	22%	14%	23%
95%	42%	15%	22%	17%	10%	28%

Quadro 5.1 – Histórico das avaliações dos especialistas

Utilizando a expressão (5.1.5) temos:

$$q^* = \frac{0,75}{1 - 0,75} \cdot \frac{P(p_1 | \theta)}{P(p_1 | \bar{\theta})} \cdot \frac{P(p_2 | \theta)}{P(p_2 | \bar{\theta})} \cdot \frac{P(p_3 | \theta)}{P(p_3 | \bar{\theta})}$$

$$q^* = 3,0 \cdot \frac{0,23}{0,16} \cdot \frac{0,21}{0,22} \cdot \frac{0,14}{0,23} \Rightarrow q^* = 2,5057$$

Calculando p^* temos:

$$q^* = \frac{p^*}{1 - p^*} \Leftrightarrow p^* = \frac{q^*}{1 + q^*} \quad (4) \Rightarrow p^* = \frac{2,5057}{1 + 2,5057} = 0,71$$

Observando o caso de combinar probabilidades de grupos formados apenas por bons especialistas, na concordância entre as p_i 's, a probabilidade resultante (p^*) será maior que a probabilidade p_i quanto maior for esta última e será menor quanto menor for p_i .

Se somente avaliadores sistematicamente tendenciosos forem utilizados, a probabilidade a posteriori (p^*) será menor quanto maior se apresentar a probabilidade p_i e será maior quanto menor for p_i . Ou seja, para um avaliador que subestima sistematicamente as probabilidades de um evento a abordagem bayesiana promove uma correção elevando o valor da probabilidade resultante. De certa forma, isso equivaleria a um peso negativo nos métodos axiomáticos de combinação por ponderação, possibilidade esta, ignorada nesses métodos .

É razoável admitir que, nos dois casos acima, a abordagem bayesiana valoriza o histórico dos profissionais, ou seja, quanto mais o avaliador acerta ou erra a sua probabilidade estimada passa a ter um valor maior ou menor para a probabilidade a posteriori.

Um mau avaliador não acrescenta nenhuma nova informação para a definição da probabilidade da ocorrência do evento esperado, logo o uso de sua opinião não altera o valor probabilidade resultante.

5.2 Abordagem Matemática para Combinação de Distribuição de Probabilidades

Os métodos matemáticos são muito mais complexos de se executar quando se utilizam funções de densidades de probabilidade. O método de **combinação linear** passa então a ter seu uso ainda mais difundido, pois consiste em realizar a combinação linear entre distribuições apenas com algumas transformações nas escalas das distribuições para em seguida somá-las.

$$f(x)^* = \sum_{i=1}^n f(x) \cdot w_i \quad \therefore \sum_{i=1}^n w_i = 1 \text{ e } w_i > 0, \forall i \quad (5.2.1)$$

Os modelos bayesianos apresentam ainda mais complexidade, pois dependeriam de históricos para funções inteiras de densidade de probabilidade. O que, na prática, é muito difícil de obter.

Winkler (1981), entretanto, apresenta um método bayesiano para a combinação de distribuições normais, que pode ser facilmente estendido ao caso das distribuições lognormais.

Assumindo que foi eliciado de cada especialista uma distribuição normal do evento θ com média μ_i e variância σ_i^2 , a estimativa da média de θ é dada pelo vetor $\mu = (\mu_1, \dots, \mu_n)$, o que podemos também representar em termos do vetor de erros, $\xi = (\mu_1 - \theta, \dots, \mu_n - \theta)$, modelados em uma distribuição normal multivariada com vetor de médias $(0, \dots, 0)$ e matriz de covariância Σ .

Seja e um vetor coluna unitário e e' um vetor transposto unitário ambos de dimensão n . Para definir uma distribuição posterior de θ com média μ^* e variância σ^{2*} , tem-se:

$$\mu^* = \frac{e' \Sigma^{-1} \cdot \mu}{e' \Sigma^{-1} \cdot e} \quad (5.2.2)$$

$$\sigma^{2*} = \frac{1}{e' \Sigma^{-1} \cdot e} \quad (5.2.3)$$

Para ilustrar a aplicação deste modelo, suponha o seguinte exemplo: Dois avaliadores definiram que o volume de hidrocarbonetos em um *play* é distribuído lognormalmente que tendo seus parâmetros normalizados geram:

Param /Avaliador	i = 1	i = 2
μ	2	10
σ^2	1	1

Quadro 5.2 – Parâmetros da distribuição normal equivalente

Determina-se em seguida, a matriz de covariância das avaliações, e a sua inversa:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \rho \cdot \sigma_1 \cdot \sigma_2 \\ \rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{bmatrix}$$

$$\Sigma^{-1} = \frac{1}{\sigma_1^2 \sigma_2^2 \cdot (1 - \rho^2)} \cdot \begin{bmatrix} \sigma_2^2 & -\rho \cdot \sigma_1 \cdot \sigma_2 \\ -\rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_1^2 \end{bmatrix}$$

A média e a variância resultante para a combinação de duas distribuições são calculadas pelas expressões abaixo:

$$\mu^* = \frac{[1 \ 1] \cdot \begin{bmatrix} \sigma_2^2 & -\rho \cdot \sigma_1 \cdot \sigma_2 \\ -\rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_1^2 \end{bmatrix} \cdot \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}}{[1 \ 1] \cdot \begin{bmatrix} \sigma_2^2 & -\rho \cdot \sigma_1 \cdot \sigma_2 \\ -\rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_1^2 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix}} \cdot \frac{1}{\sigma_1^2 \sigma_2^2 \cdot (1 - \rho^2)} \quad (5.2.4)$$

$$\sigma^{2*} = \frac{1}{[1 \ 1] \cdot \begin{bmatrix} \sigma_2^2 & -\rho \cdot \sigma_1 \cdot \sigma_2 \\ -\rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_1^2 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix}} \cdot \frac{1}{\sigma_1^2 \sigma_2^2 \cdot (1 - \rho^2)} \quad (5.2.5)$$

Onde ρ é o coeficiente de correlação entre as distribuições normalizadas dos avaliadores. No caso de avaliação de recursos de petróleo, podemos supor que a opinião dos avaliadores possui forte correlação, ou seja, $\rho \geq 0,9$. No exemplo dado, os resultados são: $\mu^* = 6$ e $\sigma^{2*} = \frac{(1-\rho)}{2} = 0,95$, para $\rho = 0,9$.

5.3 Abordagem Comportamental

A abordagem comportamental trata da eliciação de probabilidades de grupos de modos não matemáticos: como interações presenciais, por videoconferências; recursos eletrônicos, ou compartilhamento de informações.

Os grupos podem chegar à conclusão da forma de distribuição de probabilidades de uma dada característica apenas através de conversas informais e um consenso ao final de um determinado período. Esta é forma mais simples de chegar a um resultado consensual. Entretanto, geralmente não é a melhor alternativa, pois pode gerar uma série de vieses. Por exemplo, a representação apenas da opinião dos especialistas mais reconhecidos sobre o assunto, ou a negociação para que dentro de cada avaliação determinado avaliador possa ter peso maior.

Clemen (1999) aponta que trabalhos de revisão em avaliação de confiança que concluem que as avaliações em grupo para tomadas de decisões são mais

confiantes que avaliações individuais e em muitos casos tornam-se superconfiantes. Por outro lado, grupos tendem a ter respostas melhores que indivíduos, entretanto, a solução particular do melhor indivíduo dentro de um grupo é geralmente melhor que a solução do grupo.

Para evitar o tipo de comportamento que geram resultados enviesados, existem diversas técnicas formais utilizadas para gerar resultados consensuais em processos de eliciação de probabilidades. Entre estes, um dos mais utilizados e mencionados na literatura é o **Método Delphi**, que será comentado na subseção a seguir.

5.3.1 O Método Delphi

O método Delphi é uma das abordagens mais antigas para a estruturação de avaliações em grupo e requer interação indireta através de um mediador. Normalmente, a escolha do método Delphi em detrimento de outras técnicas estatísticas de previsão se deve às características do estudo como, por exemplo, inexistência de dados históricos, a necessidade de uma avaliação por detentores de diferentes tipos e conhecimento, etc.

Apesar de existirem diferentes variações desta técnica, normalmente, cada especialista faz seu julgamento individual sobre o assunto, sem se identificar, com o auxílio de um formulário previamente preparado por um grupo de especialistas coordenados por um ou mais “facilitadores”. Novos formulários são elaborados e o ciclo se repete até que se chegue a um consenso ou se desista de obtê-lo. Uma vez respondidos, as suas respostas são organizadas e resumidas em relatórios. Em seguida, todos os avaliadores têm acesso aos relatórios e revisam os seus próprios formulários.

Segundo Wright e Giovinazzo (2000), o formulário deve conter um apanhado das informações mais relevantes conhecidas para a realização da avaliação. No caso da exploração de recursos não descobertos, onde se deseja prever a distribuição de probabilidades do volume de hidrocarbonetos, os

resultados de todos os testes geológicos realizados, pareceres prévios, e relatórios de campos análogos, quando existentes são importantes ferramentas de apoio.

O anonimato das respostas e a ausência de encontros pessoais são importantes, pois reduzem a influência da capacidade de persuasão de alguns avaliadores, diminui a relutância dos avaliadores em mudarem sua posição e diminui a influência de grupos majoritários sobre grupos minoritários.

Após cada rodada as respostas dadas pelos avaliadores são tratadas estatisticamente gerando a informação importante para uma reavaliação, associadas às estas informações quantitativas, quando possível, seguem as informações qualitativas associadas. A reavaliação em cada rodada deve ser realizada à luz das informações qualitativas e suas justificativas geradas na rodada anterior.

Wright e Giovinazzo (2000) lembram que as opiniões que divergem muito da tendência central do grupo devem ser justificadas com mais detalhes. Isto porque, para que o grupo possa sair da possível ancoragem é necessário que a nova resposta possa chamar atenção do grupo e convencê-lo.

É desejável uma decisão consensual após algumas rodadas, entretanto, raramente isto é possível. Para combinar as avaliações definitivas dos membros do grupo utilizam-se os métodos matemáticos. Um diagrama com os principais passos na execução da metodologia Delphi é mostrado no Anexo II, com ênfase na exploração de hidrocarbonetos.

5.4 Suporte

Schuenemeyer (2002) explicita que para que o processo de estimação de probabilidades seja bem sucedido, deve haver uma infra-estrutura que dê suporte aos avaliadores, como, no caso de avaliações de hidrocarbonetos, testes geológicos e geofísicos e estudos geoquímicos, além de dados bem organizados.

Além disso, o coordenador da equipe de avaliação deve estar sempre apto a executar as solicitações dos avaliadores que se relacionem com os

esclarecimentos de certos aspectos mal compreendidos do problema, ou *feedbacks* sobre a forma da distribuição que foi gerada a partir de seus resultados.

5.5 Avaliação do Processo (Validação dos Resultados)

É essencial que checagens sejam feitas durante o processo de avaliação para que os próprios avaliadores possam perceber se os resultados das análises estatísticas estão gerando as informações que imaginam e saber com isto se ajustes são necessários para a validação dos resultados (Schuenemeyer, 2002).

Dentre estas checagens, estão inclusas principalmente aquelas que possam resultar em alguma incoerência física, como por exemplo, os tamanhos dos depósitos dos hidrocarbonetos e os volumes associados a eles.

É sensato também comparar os resultados com os de campos análogos já explorados. Grandes distorções devem rigorosamente analisadas e justificadas. Avaliar também a sensibilidade das características eliciadas no resultado final e verificar quais exercem maior influência é, também, uma medida positiva.

Após a publicação dos resultados finais, é importante que se critique o trabalho, o que dificilmente ocorre na exploração de recursos de petróleo. Este tipo de reavaliação poderia levar anos até que se confirmem ou não as distribuições eliciadas. Entretanto, o grupo aprenderia com isto e poderia gerar um histórico preciso para consultas por outros.

De qualquer forma, uma revisão do processo de avaliação através dos formulários utilizados e as anotações geradas é útil. Schuenemeyer (2002) sugere que esta revisão seja realizada entre 1 e 3 meses depois de finalizada a avaliações. Para que as ancoragens sejam desfeitas. E afirma que os participantes deveriam discutir sobre o trabalho e definir onde melhorias poderiam ser implementadas.

A participação dos avaliadores após o processo de avaliação é pouco provável pela escassez de mão de obra qualificada para realizar avaliações nesta área, em muitos casos o avaliador antes de concluir um trabalho começa a pensar em outro para o qual já foi solicitado.