



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학박사 학위논문

서포트벡터머신과 채널정보교정법을  
이용한 앙상블스무더의 특성화 성능 개선

**Improvement of ensemble smoother using support vector  
machine and channel information update**

2018 년 8 월

서울대학교 대학원

에너지시스템공학부

정 형 식

## 초 록

앙상블스무더(ensemble smoother, ES)는 저류층 특성화에 자주 사용되는 기법 중 하나로 전역교정을 수행하여 효율적인 최적화가 가능하다. ES를 이용한 성공적인 특성화를 위해서는 몇 가지 가정을 전제로 한다. 모델들의 평균이 참값에 근사해야 하며 저류층의 인자가 정규분포를 따라야 한다. 채널저류층은 높은 비균질성과 암상간의 큰 물리적 특성 차이로 인해 이와 같은 가정을 만족시키기 어렵다.

본 연구에서는 성공적인 채널저류층 특성화를 위해 초기 지질모델 선택기법(initial geological model selection scheme, IGMSS), 이산코사인변환법(discrete cosine transform, DCT), 채널정보교정법을 ES와 통합하여 제시한다. IGMSS에서는 차원축소를 통해 주어진 모델들을 이차원 평면에 도시하고 이를 서포트벡터머신(support vector machine)을 통해 분류한다. DCT는 모델의 핵심경향을 추출하여 전반적인 채널패턴을 파악하며 잡음을 제거한다. 또한 채널정보교정법을 통해 암상비율과 암상의 평균 로그유체투과율을 교정하며 저류층 인자의 이분분포를 유지한다.

제안방법을 간단한 2차원, 복잡한 2차원, 3차원, 총 3개의 필드에 적용하였다. 제안방법은 불확실성이 높거나 교정해야 할 인자가 많은 경우에도 채널연결성 및 패턴을 성공적으로 파악하고 또한 신뢰할만한 미래거동예측결과를 제공했다. 따라서 제안방법은 저류층 운영 중에 필요한 합리적 의사결정에 도움을 줄 수 있다.

주요어: 앙상블스무더, 초기 지질모델 선택기법, 서포트벡터머신, 채널정보교정법, 이산코사인변환법, 채널저류층

학 번: 2013-21026

# 목 차

초 록.....	i
목 차.....	ii
List of Tables.....	iv
List of Figures.....	v
1. 서론 .....	1
2. 채널저류층의 특성화 .....	15
2.1 양상불기반기법 .....	15
2.2 초기 지질모델 선택기법 .....	20
2.3 채널저류층 특성화를 위한 역산기법.....	30
3. 제안방법의 적용결과 .....	39
3.1 간단한 2차원 채널저류층 .....	44
3.2 복잡한 2차원 채널저류층 .....	60
3.3 3차원 채널저류층.....	77
4. 결론.....	96

참고문헌.....	100
ABSTRACT.....	107

## List of Tables

Table 3.1 Summary on simulation setup for 6 cases.....	41
Table 3.2 Channel information (Field 1).....	45
Table 3.3 Well locations and operating conditions (Field 1).....	46
Table 3.4 Petrophysical parameters for simulation (Field 1).....	46
Table 3.5 Channel information (Field 2).....	61
Table 3.6 Well locations and operating conditions (Field 2).....	62
Table 3.7 Petrophysical parameters for simulation (Field 2).....	63
Table 3.8 Channel information (Field 3).....	78
Table 3.9 Well locations and operating conditions (Field 3).....	79
Table 3.10 Petrophysical parameters for simulation (Field 3).....	80

## List of Figures

Figure 1.1 Procedure of static and dynamic data integration.....	2
Figure 2.1 Comparison between EnKF and ES.....	19
Figure 2.2 An example of generating a geological model for the research.....	22
Figure 2.3 Dimensionality reduction by projection .....	23
Figure 2.4 Scree plot of eigenvalues.....	25
Figure 2.5 An example of 400 models projected in 2D plane by MDS.....	26
Figure 2.6 Classification using SVM.....	28
Figure 2.7 Overall procedure of the IGMSS with actual examples.....	29
Figure 2.8 Example of DCT application on a channel reservoir model.....	33
Figure 2.9 An example of CDF mapping: histogram and CDF of prior parameter and posterior parameter.....	36
Figure 2.10 Overall procedures of the proposed inverse scheme.....	38
Figure 3.1 Comparison between the cases.....	40
Figure 3.2 Various TIs for Field 1, Field 2, and Field 3.....	43
Figure 3.3 Log permeability field and histogram of the reference (Field 1).....	45

Figure 3.4 WOPR predictions of all cases (Field 1).....	50
Figure 3.5 WWCT predictions of all cases (Field 1).....	51
Figure 3.6 FOPT and FWPT predictions for all cases (Field 1).....	53
Figure 3.7 Average log permeability fields of all cases (Field 1).....	55
Figure 3.8 Log permeability fields and their histograms of two ensemble members of each case (Field 1).....	57
Figure 3.9 Channel information distribution for Case 1, 2, 5, and 6 (Field 1).....	59
Figure 3.10 Log permeability field and histogram of the reference (Field 2).....	61
Figure 3.11 WOPR predictions of all cases (Field 2).....	66
Figure 3.12 WWCT predictions of all cases (Field 2).....	67
Figure 3.13 FOPT and FWPT predictions for all cases (Field 2).....	69
Figure 3.14 Average log permeability fields of all cases (Field 2).....	72
Figure 3.15 Log permeability fields and their histograms of two ensemble members of each case (Field 2).....	74
Figure 3.16 Channel information distribution for Case 1, 2, 5, and 6 (Field 2).....	76
Figure 3.17 Log permeability field and histogram of the reference (Field 3).....	77



Figure 3.18 WOPR predictions of all cases (Field 3).....	82
Figure 3.19 WWCT predictions of all cases (Field 3).....	83
Figure 3.20 WBHP predictions of all cases (Field 3).....	85
Figure 3.21 FOPT and FWPT predictions for all cases (Field 3).....	87
Figure 3.22 Average log permeability fields of all cases (Field 3).....	90
Figure 3.23 Log permeability fields and their histograms of two ensemble members of each case (Field 3).....	93
Figure 3.24 Channel information distribution for Case 1, 2, 5, and 6 (Field 3).....	95

# 1. 서론

석유는 온도, 압력, 조성에 따라 기체 또는 액체로 존재하는 자연발생의 탄화수소 혼합물이다. 석유공학은 이러한 석유를 자원으로 이용하기 위한 탐사, 개발, 생산, 수송에 관련된 전반적인 지식을 다룬다. 석유자원의 개발을 위한 E&P(exploration and production) 사업은 다른 사업에 비해 투자규모가 크고 사업기간이 길다. 또한 기술적, 경제적 불확실성은 사업을 더욱 어렵게 한다. 따라서 석유의 개발 및 생산 과정에서 올바른 의사결정은 사업의 성패를 좌우하는 매우 중요한 요소이다.

올바른 의사결정을 위해서는 석유를 포함한 지하 내 유체의 거동을 예측할 수 있어야 하며, 이를 위해 신뢰할 수 있는 저류층모델을 만들어야 한다. 저류층이란 원유가 매장되어 있는 지하매질이며 신뢰성 있는 저류층모델을 구축하는 과정을 저류층 특성화라고 한다. Figure 1.1은 저류층 특성화의 과정을 보여준다.

저류층 특성화는 정적자료 및 동적자료를 통합하여 수행한다. 정적자료는 지질정보, 코어자료, 유정시험, 로깅자료 등을 통해 획득할 수 있으며 시간에 따라 변하지 않는 유체투과율과 공극률 등을 의미한다. 이러한 정적자료는 지구통계기법을 통해 통합되어 초기 지질모델을 생성하는데 이용된다. 하지만 제한된 정적자료만을 이용하여 만들어진 초기 지질모델은 그 불확실성이 매우 크다. 따라서 저류층 운영 시 유정에서 측정되는 생산이력 또는

공저압력(bottom-hole pressure, BHP) 등 시간에 따라 변화하는 동적자료를 통합하여 초기모델을 갱신해야 한다. 이러한 과정을 히스토리매칭(history matching)이라 한다. 이를 통해 동적자료와 지질모델의 생산 예측값 사이의 오차를 줄여, 보다 신뢰성 있는 저류층모델을 얻고 불확실성을 줄일 수 있다. 이는 개발과 생산에 필요한 운영과 관리를 합리적으로 수행하도록 돕는다.

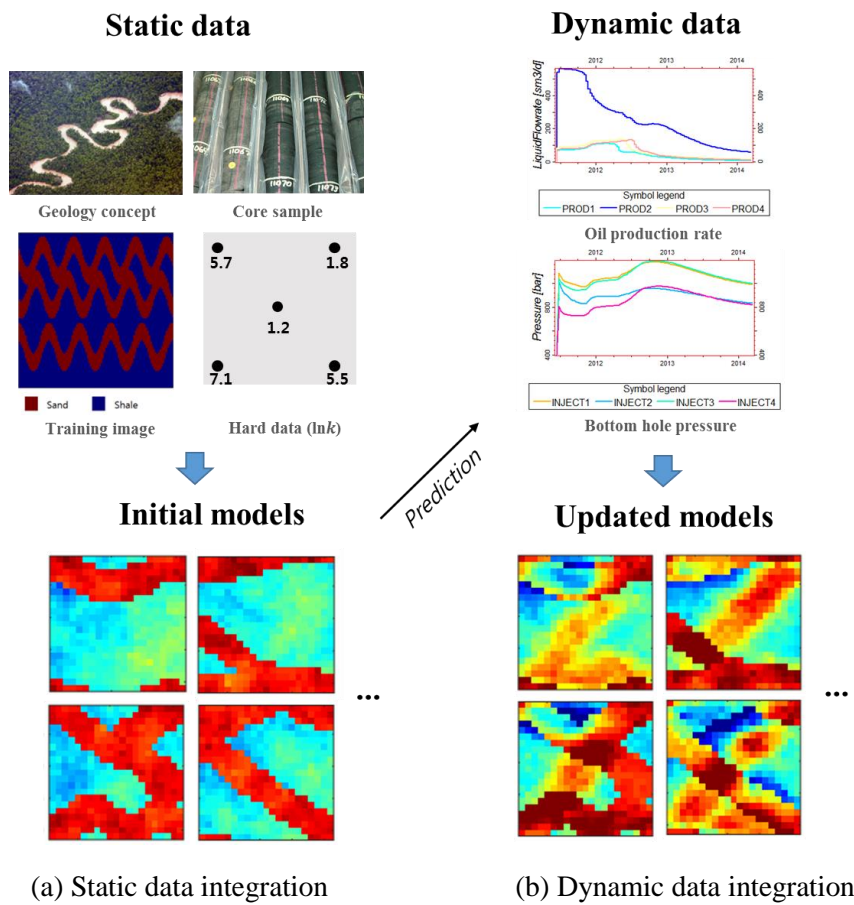


Figure 1.1 Procedure of static and dynamic data integration

본 연구에서는 히스토리매칭을 위한 최적화 기법으로 앙상블기반기법(ensemble-based method)을 사용한다. 이는 등가의 확률을 가진 다수의 해집합을 이용하는 방법으로, 하나의 해가 아닌 다수의 지질모델을 이용하므로 불확실성을 평가할 수 있다는 장점이 있다.

앙상블칼만필터(ensemble Kalman filter, EnKF)는 Evensen(1994)이 처음 제안한 방법으로 Nævdal 등(2002)이 가상 저류층의 유체투과율 분포 분석에 사용한 이래 석유공학분야에서 가장 많이 쓰이는 앙상블기반기법 중 하나이다. EnKF는 관측자료가 얻어지는 시점마다 모델을 갱신하기 때문에 실시간 교정이 가능하지만 시뮬레이션 시간이 오래 걸린다는 단점이 있다. 이러한 한계를 극복하기 위해 Van Leeuwen과 Evensen(1996)은 앙상블스무더(ensemble smoother, ES)를 제안하였다. ES는 관측시점에 상관없이 모든 관측자료를 사용하여 한번에 전역교정을 수행한다. 따라서 EnKF와 비교하여 시뮬레이션 시간이 비교적 빠르지만 교정신뢰도가 떨어진다는 단점이 있다. 두 방법은 모두 수학적으로 명확하며 다른 전위 시뮬레이터와 쉽게 결합할 수 있는 유연한 적용성으로 석유공학, 해양학, 기상학 등 다양한 분야에서 사용되고 있다.

EnKF와 ES는 교정수식을 유도하는 과정에서 몇 가지 가정을 전제로 한다. 등가의 확률로 생성된 모델의 수는 충분히 크고 서로 독립이어야 한다. 또한 모델의 평균이 참값에 근사하며 그 인자가 정규분포를 따라야 한다. 위의 가정을 만족하는 역산문제는

신뢰할만한 특성화 결과를 보여주었다(Nævdal *et al.*, 2002; Gu and Oliver, 2004, 2006). 하지만 가정들을 만족하지 못하는 경우 오버슈팅(overshooting)과 필터발산(filter divergence) 등의 문제가 발생하여 그 결과를 신뢰하기 어렵다(정승필, 2008; Shin *et al.*, 2010; Jung and Choe, 2012; Lee *et al.*, 2013a, 2013b, 2014, 2016; 이경복, 2014; 조홍근, 2016; Jo *et al.*, 2017; Jung *et al.* 2017a, 2017b).

오버슈팅은 교정된 저류층 인자값이 비정상적으로 큰 경우를, 언더슈팅은 반대로 굉장히 작은 경우를 의미한다. 이는 EnKF나 ES가 수식에 의해서 인자를 교정하기 때문에 다양한 모델인자에 적용될 수 있는 반면, 교정되는 인자의 물리적인 특성을 고려할 수 없기 때문에 발생하는 현상이다. 필터발산은 서로 다른 초기모델들이 잘못된 하나의 저류층모델로 수렴하는 경우이다. 이 경우 앙상블들이 서로 비슷해지기 때문에 추정오차공분산이 작아지게 되고 새로운 관측자료를 통해 교정을 수행하여도 모델갱신이 불가능하다.

저류층을 구성하는 암상, 퇴적의 종류와 형태 등은 저류층의 거동에 큰 영향을 미친다. 대부분의 경우 유체투과율, 공극률 등의 물성값은 가까운 위치에서 유사한 값을 가지며 변화한다. 하지만 강이나 하천을 따라 사암이 퇴적된 곳은 주변부에 퇴적된 세일로 인해 채널(channel)을 형성하며 연결성, 연속성, 패턴 등의 뚜렷한 특징을 갖는다. 이 경우 채널에서는 높은 유체투과율, 세일에서는 낮은 유체투과율을 갖게 되고 물성값이 급격하게 변하여

유체거동에 큰 차이를 보인다.

이러한 채널저류층(channel reservoir)은 다양한 퇴적환경에서 형성되어 전세계에 널리 분포하며 석유생산에서 중요한 위치를 차지하고 있다. 단적인 예로 세계에서 두 번째로 큰 매장량을 가지고 있는 Bragan field와 북미에서 가장 큰 매장량을 가지고 있는 Prudhoe bay field의 또한 채널저류층을 포함하고 있다. 따라서 채널저류층을 올바르게 특성화하여 생산거동을 예측하는 것은 매우 중요한 작업이다.

본 연구에서 대상으로 하는 채널저류층은 사암과 셰일, 두 암상으로 이루어져 유체투과율, 공극률 등의 저류층인자가 정규분포가 아닌 이봉분포를 따른다. 또한 복잡한 사암연결성으로 인한 비균질성이 매우 크다. 하지만 초기모델을 생성할 때는 제한된 정적자료만을 이용하기 때문에 지질학적 불확실성이 매우 크며 이 경우 모델의 평균이 참값에 근사하지 못해 신뢰성 있는 초기모델을 얻기 힘들다.

위와 같은 채널저류층의 특징은 EnKF와 ES의 가정을 위배하여 성공적인 저류층 특성화를 어렵게 만든다. 따라서 성공적인 채널저류층 특성화를 위해서는 실제 참조필드와 가까운 지질모델들을 선택하여 역산기법에 사용하는 것이 중요하다. 제한적인 초기데이터만으로 신뢰성 있는 모델을 선택하는 것은 매우 어렵지만 채널저류층 특성화를 위해 초기앙상블을 선택 혹은 디자인하는 연구는 활발하게 이루어져왔다.

Peters 등(2011)은 역산을 위한 초기모델의 선택을 위해 다차원척도법(multi-dimensional scaling, MDS)를 사용하였다. 그들은 모델간의 비유사성을 오일생산량, 워터컷, BHP 등의 예측값 차이로 정의하고 실제 관측값과 비슷한 양상블들을 선별하였다. Jung 등(2017b)은 실제 관측값과 모델 예측값의 상대오차를 통해 모델을 선별하고 선별된 모델들을 공분산 지역화를 이용하여 특성화하였다. 또한 Kim 등(2017)은 물생산량의 관측값과 예측값의 오차를 통해 모델을 선택하고 선택된 모델의 평균필드를 추가 정적자료로 사용하여 모델을 재생성하는 연구를 수행하였다.

위의 연구들에서는 실제 저류층과 비슷한 생산거동을 보이는 모델들이 비슷한 채널연결성과 유체투과율 분포를 보일 것이라고 가정한다. 이 가정은 합리적으로 보이나 이 가정만으로는 지질학적 유사성을 보장할 수 없다. 생산거동의 유사성이 곧 지질학적 유사성을 의미하지는 않기 때문이다. 따라서 지질학적인 특성을 고려하지 않고 모델을 선별하는 것은 안정적인 특성화 결과를 보장할 수 없다.

Lee 등(2013a, 2013b)은 채널저류층의 암상이 같은 경우, 같은 유체투과율값을 가진다고 가정한 후, 각 모델간의 비유사성을 Hausdorff 거리로 정의하고 MDS를 이용하여 2차원 평면에 도시하였다. 이 후, 모델들을 K평균 군집화(K-means clustering)를 통해 분류한 다음 가장 참조모델과 거동이 비슷한 군집만을 이용하여 역산을 수행하였다. Kang 등(2017) 및 Kang과 Choe(2017a,

2017b)는 주성분분석(principal component analysis, PCA)과 K평균 군집화를 결합하여 앙상블기반기법을 위한 좋은 초기모델을 선택하고자 하였다.

위의 연구들은 초기모델 선택 시, 생산거동의 유사성과 지질학적 유사성을 동시에 고려하여 초기모델의 평균이 참값과 다른 경우에도 오버슈팅과 필터발산의 문제를 성공적으로 해결하였다. 하지만 그들의 연구는 K평균 군집화 자체가 가지는 무작위성 때문에 안정적인 특성화 결과를 보장할 수 없다.

Nejadi 등(2015)은 EnKF의 교정과정에 모델 재생성과정을 추가하였다. 미리 정해진 교정횟수가 지나면 교정된 모델의 평균을 새로운 앙상블을 생성하기 위한 확률지도(probability map)로 활용하여 모델을 재생성한 후 이를 다시 EnKF를 통해 최종 교정하였다. Lee 등(2017)은 히스토리매칭된 암상분포 확률지도를 이용하여 암상모델을 재생성하는 방법을 제안하였다. 그들은 MDS와 K평균 군집화를 이용하여 모델들을 군집화하고 실제 관측값과 가장 유사한 거동을 보이는 군집을 선택하여 이들의 평균을 모델 재생성에 활용하였다. 이 과정을 반복하여 역산기법을 이용하지 않고 참조필드와 비슷한 채널경향을 가지는 모델들을 생성하고자 하였다.

위의 연구들에서는 모델 재생성을 통해 특성화를 수행하거나 혹은 특성화 성능을 개선시켰다. 하지만 복잡한 모델링 과정을 반복적으로 수행하기 때문에 계산시간이 오래 걸린다는 단점이



있다.

서포트벡터머신(support vector machine, SVM)은 서로 다른 분류에 속한 데이터 간의 간격이 최대가 되는 초평면(hyperplane)을 찾고 이를 기준으로 데이터를 구분하는 기법이다. 이 방법은 통계학습이론에 기반하고 있으며 최근 석유공학분야에서 활발하게 사용되었지만 주로 탄성과 신호처리에만 국한되어 활용되었다. SVM을 특성화에 적용하려는 시도들은 있었지만 주로 지역적인 유체투과율 분포(Al-Anazi and Gates, 2010)나 로깅으로부터 획득한 코어의 유체투과율(Gholami et al., 2012)을 파악하는 데에만 사용되었다.

본 논문에서는 PCA와 SVM을 결합한 새로운 초기 지질모델 선택기법(initial geological model selection scheme, IGMSS)을 제안한다(Jung et al., 2018). PCA를 통해 각 모델의 차원을 낮춰 계산효율을 높이면서도 잡음을 제거하여 주요 채널연결성만을 파악할 수 있도록 한다. 이 후 각 모델간의 비유사성을 유클리디안 거리(Euclidean distance)를 이용하여 계산한 후, MDS를 이용하여 2차원 평면에 도시한다. 즉 주요특징은 보존하면서 모델의 차원을 낮추어 모든 모델들을 2차원 평면에 도시한다. 이 후, 2차원 평면에 있는 모델들을 대상으로 SVM을 수행한다. 이 때 SVM은 유정별 오일생산량(well oil production rate, WOPR) 오차를 기준으로 학습시킨다. SVM으로 분류된 모델들 중, WOPR의 오차가 낮은 범주에 속하는 모델들을 선택하며 초기모델의 30% 이하가 될

때까지 위의 과정을 반복한다.

제안된 IGMSS은 아래와 같은 특징을 갖는다. 첫 번째로 모델의 차원을 축소하여 2차원 평면에 도시한다. PCA를 통해 중요한 정보의 손실을 최소화하면서 차원을 축소하고 또 주요한 특징을 추출한다. 이렇게 차원축소된 모델들을 가시화하기 위해 MDS를 이용하여 2차원 평면에 나타낸다. 이렇게 두 단계의 차원축소방법을 결합하여 계산효율을 높이고 주요 특징을 더 효과적으로 보존할 수 있다.

두 번째로 모델의 선택에 군집화기법이 아닌 분류기법을 사용한다. 기존의 논문들에서는 K평균 군집화를 사용하여 초기 앙상블을 선택하고자 하였다. 하지만 K평균 군집화는 매번 군집화의 결과가 달라지는 임의성 때문에 안정적인 특성화 결과를 제공할 수 없다. 이는 실제 현장에서 필드를 특성화하는 데에 큰 단점으로 작용한다. 본 논문에서는 임의성 없이 안정적인 결과를 제공하는 분류기법 중에 하나인 SVM을 사용하여 모델을 분류하고 선택한다.

물론 너무나 큰 초기 불확실성이 존재하여 생성된 초기모델이 참값을 포함할 수 없다면 IGMSS 또한 좋은 결과를 제공하기 어렵다. 이러한 극단적인 경우가 아니라면 다양성을 고려하여 많은 수의 모델을 생성하고 제안된 IGMSS를 이용하여 모델을 선택하는 과정은 모델의 평균이 참값에 가까워야 한다는 EnKF와 ES의 가정을 만족시키도록 도와준다.

하지만 여전히 채널저류층의 이봉분포 특성으로 인해 정규분포

가정은 만족시키지 못한다. 또한 이봉분포의 채널저류층을 앙상블기반기법으로 특성화하면 교정된 저류층인자가 정규분포를 따르게 되는데, 실제 채널저류층은 이봉분포를 가지기 때문에 사암연결성 등 채널저류층의 특징을 보존하지 못한다(Shin et al., 2010; Jo et al., 2017; Jung et al., 2017a). 따라서 채널저류층의 경우 좋은 초기앙상블을 선택한 후에도 적절한 특성화 방법을 사용하는 것이 필요하다.

채널저류층의 유체투과율 분포를 특성화하기 위한 연구로 다양한 모수화방법이 제안되었다. 모수화방법은 유체투과율을 채널의 특성을 잘 표현하는 다른 변수로 변환하여 교정을 수행한 후, 다시 역변환을 통해 유체투과율값으로 환원하는 방법이다.

Lorentzen 등(2012)은 채널필드를 모수화하기 위해 LSF(level set function)의 기법을 제안하였다. 그들은 각 격자에서 채널경계에 이르는 최소 유클리디안 거리를 계산한 후 이를 변수화하고 암상에 따라 양수와 음수로 구분하였다. 계산된 거리변수는 EnKF를 통해 교정되고 교정된 변수들은 다시 암상필드로 역변환된다. 이들은 생산이력의 오차를 줄이는데에는 성공했으나 저류층모델의 인자값이 참조필드와 상이하여 미래생산량은 성공적으로 예측하지 못하였다.

Jarfarpour와 Mclaughlin(2008)은 데이터 압축을 위해 이산코사인변환(discrete cosine transform, DCT)을 EnKF와 결합하였다. DCT는 이미지 등의 정보를 이산적인 코사인함수의 계수로

변환하여 나타내는 방법으로 차원축소에 이용될 수 있다. 주요한 채널특성을 나타내는 계수만 사용하여 특성화를 수행함으로써, 행렬계산의 효율을 높이고 잡음을 제거하여 특성화 성능을 향상시켰다. 그들은 채널의 이봉분포를 유지하는데에는 실패하여 세밀한 채널특성은 보존하지 못했지만 전체적인 채널연결성은 확보할 수 있음을 증명하였다(Jarfapour and Maclaughlin 2007, 2009). Jarfapour(2011)는 또한 이산웨이블릿변환(discrete wavelet transform)을 EnKF와 결합하는 방법을 제시하였다. 유동반응에 대한 민감도와 사전정보를 이용하여 주요한 계수를 선정하였으며 이들만을 이용하여 특성화를 수행하였다. 하지만 DCT를 사용한 연구와 마찬가지로 불량조건문제(ill-posed problem)에서 미세한 특징을 파악하지 못했다.

Kim 등(2016a, 2016b)은 이러한 문제를 해결하기 위해 사암과 셰일의 비율을 보존할 수 있는 암상비율보존법을 DCT와 함께 EnKF에 결합하였다. 그들은 채널을 사암과 셰일, 두 가지의 암상으로 구분하고 그들의 비율을 매 교정마다 보존하였다. 이 방법을 통해 전체적인 채널특성을 보존하는데 성공하였으며 신뢰할만한 미래생산량 예측을 보여주었다. 하지만 그들은 각 모델의 암상비율을 참조필드의 암상비율로 사용한 한계가 있다.

Shin 등(2010)은 정규분포를 따르지 않는 필드를 특성화하기 위해 비모수접근법(non-parametric approach)을 제안하였다. 그들은 정규분포변환(normal score transformation, NST)를 사용하여 변수를

정규분포화 시킨 후 EnKF를 통해 교정된 변수를 다시 역정규분포변환(inverse NST)을 통해 복원하였다. 이를 통해 EnKF의 정규분포 가정을 충족시켰으며 성공적인 특성화 결과를 보여주었다. Zhou 등(2011, 2012) 또한 채널 대수층의 전도도를 특성화하기 위해 NST와 inverse NST를 EnKF와 결합하였다. 이들은 이분분포를 유지하여 불확실성을 성공적으로 정량화하고 특성화 성능을 향상시켰다.

위의 두 방법은 참조필드의 확률분포를 알고있다고 가정하지는 않았지만, inverse NST를 통한 누적분포함수(cumulative distribution function, CDF) 맵핑과정에서 초기양상블의 분포를 그대로 사용했다는 단점이 있다. 이는 초기양상블의 채널특성이 참조필드와 다를 경우, 안정적인 특성화 결과를 보장할 수 없다는 한계가 있다.

채널저류층의 유체투과율을 모수화하여 특성화 성능을 개선시키는 연구뿐 아니라, 채널의 특징을 변수화하여 이를 양상블기반기법을 통해 교정하고자 하는 연구들도 활발히 진행되어 왔다(Agbalaka and Oliver, 2011; Luo et al., 2015).

Sebacher 등(2013)은 3개의 암상으로 이루어진 합성필드를 특성화하였다. 그들은 유정에서의 암상은 알고 있다고 가정한 후, 점점 거리가 멀어질수록 그 암상이 나타날 확률이 떨어진다는 아이디어에 착안하여 각 암상에 대한 확률지도를 생성하였다. 또한 암상의 분포 및 비율에 영향을 주는 절단변수를 정의하고 이를 EnKF를 통해 교정하였다. Astrakova 등(2015)은 TPG(truncated pluri-

Gaussian) 모델을 사용하여 암상의 공간적 분포를 표현하였다. 그들은 노드의 개수와 위치 등 절단지도를 구성하는 다양한 변수들을 최적화하여 암상모델을 특성화하였다. Astrakova와 Oliver(2015)는 3차원의 여러 개의 암상으로 이루어진 TPG 모델을 내부점법(interior-point method)과 반복 앙상블스무더를 이용하여 히스토리매칭했다. 절단모델을 이용하는 위의 세 가지 연구는 앙상블기반기법과 결합하여 암상을 교정하기는 용이하지만 채널의 구조와 특성을 표현하기 어렵다는 단점이 있다.

Sebacher 등(2015)는 채널저류층을 특성화하는 새로운 방법을 제안했다. 그들은 다수의 채널필드를 생성한 후, 각 격자에서 암상이 나타나는 비율을 주변부확률로 정의하고, 확률밀도함수를 계산하였다. 이 후, 각 격자 확률밀도함수의 무게 중심을 계산하고 이를 변수값으로 하여 교정을 수행하였다. Jo 등(2017)과 Jung 등(2017a)은 채널정보를 정의하고 이를 상태벡터에 추가하여 교정하는 채널정보교정법을 제안했다. 이들은 교정된 유체투과율의 이분분포를 유지하기 위해, 교정된 채널정보를 활용한 CDF 맵핑을 사용하였다. 이들의 연구는 채널의 패턴을 정확히 파악하였으며 미래생산거동도 성공적으로 예측하였으나 EnKF에 기반을 두고 있어 계산시간이 오래 걸린 단점이 있다.

본 연구에서는 채널저류층 특성화를 위한 역산기법으로 ES와 DCT 그리고 채널정보교정법을 결합한다. DCT를 적용하여 차원을 축소하고 이를 채널정보와 함께 ES를 통해 교정한다. 이 후 역

DCT를 통해 유체투과율의 분포로 환원시킨 후, CDF 맵핑을 수행하여 유체투과율 분포를 이봉분포로 변환한다.

본 연구의 제안방법은 신뢰할 수 있는 채널저류층 특성화를 위해 여러 기법을 통합한다: IGMSS, ES, DCT, 채널정보교정법. 초기의 불확실성을 고려하여 다양한 모델을 생성한 후 IGMSS를 통해 좋은 앙상블을 선택한다. 하지만 채널저류층의 높은 비균질성과 복잡한 고유특징 때문에 신뢰성 있는 초기모델을 사용하더라도 추가적인 역산이 필요하다. 따라서 ES와 DCT, 그리고 채널정보교정법을 결합한 역산기법으로 계산시간을 단축시키고 채널의 연결성, 연속성, 패턴 등을 보존한다. 채널의 특징을 올바르게 예측하는 것은 미래생산거동 및 불확실성 또한 적절하게 평가할 수 있도록 도와준다.

본 논문은 총 4장으로 구성된다. 1장에서는 현재까지 수행되어 온 연구들의 한계를 파악하고 본 연구의 필요성과 목적을 제시한다. 2장에서는 본 연구의 기반이 되는 기존기법인 EnKF와 ES 등의 앙상블기반기법, PCA, MDS, SVM, DCT 등과 함께 본 연구에서 새롭게 제안하는 IGMSS와 채널정보교정법에 대해서 설명한다. 3장은 제시된 기법들이 적용된 연구결과를 보여준다. 총 3개의 채널저류층에 대하여 검증을 수행하였으며 간단한 2차원 저류층, 복잡한 2차원 저류층, 그리고 3차원 저류층에 대한 결과를 보일 것이다. 4장에서는 연구결과들을 정리하고 연구결론을 언급한다.

## 2. 채널저류층의 특성화

EnKF 및 ES는 저류층 특성화를 위해 자주 사용되는 방법 중 하나이다. 하지만 기존연구들을 통해 증명되었듯이 채널저류층의 경우 앙상블기반기법 자체만으로는 연결성, 연속성, 패턴 등의 고유한 특징을 성공적으로 특성화할 수 없다. 따라서 본 연구에서는 ES와 함께 IGMSS, DCT 그리고 채널정보교정법 등을 적용하며 이들의 사용목적과 원리 및 효과를 본 장에서 설명한다.

### 2.1 앙상블기반기법

#### 2.1.1 앙상블칼만필터

EnKF는 앙상블기반기법으로, 불확실성을 가진 다수의 모델을 생성하고 예측값과 참조모델의 실제 관측값 사이의 추정오차공분산(estimated error covariance,  $C_y^p$ )을 최소화하는 동적자료통합기법이다(Evensen, 1994). 이 때 다수의 모델을 앙상블이라고 하며, 각 모델은 식 (2.1)과 같이 상태벡터로 표현할 수 있다.

$$y_k = \begin{bmatrix} m_k^s \\ m_k^d \\ d_k \end{bmatrix} \quad (2.1)$$



여기서,  $m_k^s$  는 시간에 따라 변하지 않는 저류층의 석유물리적 특성들인 정적인자를 의미한다. 암석 내 빈 공간의 비율인 공극률과 유체가 얼마나 잘 흐를 수 있는지를 나타내는 유체투과율 등이 대표적이다.  $m_k^d$ 는 시간에 따라 변하는 동적인자로 저류층 압력이나 물, 오일, 가스 포화도 등을 의미한다.  $d_k$ 는 해당 정적, 동적인자를 가지는 저류층을 대상으로 전이 시뮬레이션을 수행했을 때 유정에서의 예측되는 생산거동을 의미한다. 각 변수의 아래첨자  $k$ 는 시점을 의미한다.

EnKF는 예측과 교정, 두 단계로 구성된다. 예측단계에서는 저류층 시뮬레이터를 활용하여 저류층의 거동을 예측한다. 대표적인 전위 시뮬레이터로 Schlumberger 社의 ECLIPSE 100과 ECLIPSE 300 그리고 CMG 社의 IMEX와 GEM 등이 있다. 본 연구에서는 블랙오일모델을 기반으로 하여 ECLIPSE 100을 사용하였다. 식 (2.2)는 예측단계를 설명한다.

$$\begin{bmatrix} m_{k+1}^d \\ d_{k+1} \end{bmatrix} = f(m_k^s, m_k^d) \quad (2.2)$$

여기서,  $f(\cdot)$ 는 전이모델을 의미하며 현재 저류층의 정적인자( $m_k^s$ )와 동적인자( $m_k^d$ )를 대입하여 다음 시점의 저류층의 동적인자( $m_{k+1}^d$ )와 예측값( $d_{k+1}$ )을 얻는다.

교정단계에서는 식 (2.3)과 같이 칼만게인(Kalman gain,  $K$ )를 이용하여 정적인자를 교정한다.  $K$ 는 식 (2.5)로 정의된  $C_y^p$ 를

최소화하도록 정의되며 식 (2.4)와 같이 표현된다.

$$y_k^a = y_k^p + K(D_k - Hy_k^p) \quad (2.3)$$

$$K = C_y^p H^T (H C_y^p H^T + C_D)^{-1} \quad (2.4)$$

$$C_Y^p = \frac{1}{N_e - 1} \sum_{i=1, j=1}^{N_e} (y_i^p - \bar{y}^p)(y_j^p - \bar{y}^p)^T \quad (2.5)$$

여기서, 윗첨자  $p$  와  $a$  는 각각 교정 전(priori)과 교정 후(assimilated)를 뜻한다.  $D_k$ 는 물생산량, 오일생산량, BHP 등과 같이 유정에서 측정되는 실제 관측값행렬이며,  $H$ 는 1과 0만으로 구성된 측정행렬연산자(measurement matrix operator)로 상태벡터에서 예측값을 추출한다.  $N_e$  는 전체 앙상블의 수를 의미하며  $C_D$  는 관측오차공분산(measurement error covariance)을 의미한다.


식 (2.3)에서 확인할 수 있듯이, 관측값인  $D_k$ 와 상태벡터들의 예측값인  $Hy_k^p$ 의 차이가 클수록 기존의 상태벡터는 크게 교정된다. 이는 예측값이 관측값과 다를수록 해당 저류층모델이 실제 저류층과 다를 가능성이 높다는 가정을 기반으로 한다.

식 (2.4)에서  $C_Y^p$ 는 각 상태벡터들이 평균값으로부터 얼마나 벗어나 있는가를 나타내는 지표로  $K$ 는 이를 최소화한다. 따라서 교정을 수행할수록  $C_Y^p$ 는 작아지고 모델들은 평균값에 가까워지며 서로 유사해진다. 이는 모델의 평균이 참값에 근사해야 한다는


EnKF의 가정을 잘 보여주며, 본 가정을 통해 초기모델의 중요성을 확인할 수 있다.

### 2.1.2 앙상블스무더

ES는 EnKF와 같은 앙상블기반기법으로 EnKF의 높은 계산시간 요구를 해소하기 위하여 제안되었다(van Leeuwen and Evensen, 1996). 기본적으로 EnKF와 동일한 가정을 사용하며 예측과 교정에 사용되는 수식 또한 동일하다. 즉 식 (2.2), (2.3), (2.4), (2.5)는 ES에서도 그대로 사용할 수 있다. 두 기법의 차이는 관측자료를 이용하는 방식이다. EnKF는 관측값이 존재하는 시점마다 교정을 실시하여 모델을 갱신한다. 하지만 ES는 관측시점에 상관없이 모든 관측자료를 사용하여 단 한 번 교정하며, 이를 전역교정이라 한다. Figure 2.1은 EnKF와 ES의 전반적인 과정을 비교하여 보여준다.  $N$ 은 관측자료가 존재하는 시점의 총 수를 의미한다.



(a) EnKF



(b) ES

Figure 2.1 Comparison between EnKF and ES

식 (2.6)은 ES의 상태벡터이며 하나의 모델이 모든 시점의 관측값을 포함한다. 교정횟수가 한 번이므로 계산시간이 빠르고 앙상블기반기법의 가정에 맞지 않는 저류층에 적용할 때 가정의 위반횟수가 적다는 장점이 있다(Skjervheim *et al.*, 2011; 이경복, 2014). 본 연구에서는 ES를 기반으로 한 새로운 특성화 기법을 제시한다.

$$y = \begin{bmatrix} m_k^s \\ m_k^d \\ d_1 \\ \vdots \\ d_N \end{bmatrix}, \quad t = 1, \dots, N \quad (2.6)$$

## 2.2 초기 지질모델 선택기법

생성된 모델들의 평균이 참값에 근사해야 한다는 ES 및 EnKF의 가정으로 인해 좋은 초기 저류층모델, 즉 지질모델을 선택하는 것은 성공적인 특성화에 중요한 요소이다. 좋은 모델을 선택하고 생성하기 위한 연구는 활발히 진행되어왔지만 채널저류층 고유의 연결성, 연속성, 패턴 등의 특징에서 오는 높은 비균질성으로 인해 적절한 방법을 선택하는 데에는 어려움이 있다.

본 연구에서는 두 가지 지구통계기법을 교차사용하여 이봉분포를 가지는 다수의 초기 저류층모델을 만든 후, PCA와 MDS를 통해 차원을 축소하고 SVM을 통해 학습된 모델을 이용하여 나머지 모델들을 분류, 선택하는 통합기법을 제안한다.

### 2.2.1 초기 지질모델 생성

초기 지질모델은 코어자료, 로깅자료, 탄성파탐사자료 등을 지구통계기법으로 통합하여 생성한다. 두점지구통계 기법의 경우 베리오그램(variogram)으로 정의되는 공간정보를 이용하며 단일 저류암으로 구성된 저류층모델을 생성하는데 주로 사용된다(최종근, 2013). 순차 가우스 시뮬레이션(sequential Gaussian simulation, SGS)이 대표적인 두점지구통계 기법이다.

두 개 이상의 저류암으로 구성되어 특정 패턴을 나타내는 저류층은 다점지구통계 기법을 이용하여 암상분포를 생성할 수 있다(최종근, 2013). 이 경우 공간분포는 베리오그램이 아닌 트레이닝

이미지(training image, TI)로 표현된다. TI는 탄성파탐사의 결과, 지질학적 개념, 위성 및 항공 사진 등 주변의 지질정보를 통합하여 만든 지질학적 개념도이다. 이러한 TI를 이용하는 다점지구통계의 대표적인 방법으로는 SNEsim(single normal equation simulation)이 있다.

본 연구에서는 SGS와 SNEsim을 결합하여 400개의 초기모델을 생성하였다. 즉 SNEsim을 이용하여 채널저류층의 사암과 셰일의 암상분포를 생성하고 채널의 특성을 표현하였다. 각 암상에서의 유체투과율 분포는 SGS의 결과를 이용함으로써 각 암상이 로그정규분포를 따르도록 하였다. Figure 2.2는 본 연구에서 사용한 지질모델의 생성방법의 예를 보여준다.

Figure 2.2a는 사암과 셰일, 두 가지의 암상으로 이루어진 암상 모델을 나타낸다. 하지만 실제 필드의 경우 각 암상 내에서도 유체투과율의 변화가 있으며 이를 반영하기 위해 사암과 셰일의 유체투과율 필드를 생성하였다(Figures 2.2b and 2.2c). 이 후 암상 모델에서 각 암상에 해당하는 격자의 유체투과율값을 해당 SGS 필드에서 가져와 최종모델(Figure 2.2d)를 결정한다. 참조필드를 포함한 모든 모델들은 이와 같은 과정을 거쳐 만들어지며 이는 실제 필드의 유체투과율 분포를 반영하기 위함이다.




Figure 2.2 An example of generating a geological model for the research

### 2.2.2 차원축소

저류층모델은 유체투과율과 같이 관심있는 인자로 표현될 수 있다. 하나의 격자에는 하나의 유체투과율값이 대응되므로 모델의 차원은 격자의 개수와 일치한다. 따라서 저류층 특성화는 고차원의 문제이며 차원축소의 과정 없이 고차원의 자료를 그대로 이용하면 계산시간이 오래 걸린다. 또한 주요 채널특징과는 관계없는 잡음들을 제거할 수 없다. 본 연구에서는 PCA를 이용하여 모델들의 유체투과율을 대상으로 차원을 축소한다.

PCA는 정보의 손실을 최소화하며 주요 특징만을 추출하는 대표적인 차원축소기법으로 Karhunen-Loeve(KL) 변환 또는 Hotelling 변환이라고도 한다. Figure 2.3는 2차원의 공간에서 1차원 공간으로 투영된 PCA의 원리를 보여준다.

Figure 2.3a는 4개의 모델이 2차원 공간에 분포하고 있는 모양을 보여준다. Figure 2.3b와 Figure 2.3c는 2차원 공간에 있는 모델을 차원축소를 통해 1차원, 즉 직선에 투영한 결과를 보여준다. Figure 2.3b는 x축 방향의 직선에 모델을 투영하고 Figure 2.3c는 45도의 기울기를

가지는 직선에 모델을 투영하였다. 그 결과, 전자는 1번과 3번, 그리고 2번과 4번의 모델의 구분이 사라져 정보의 손실이 큰 반면, 후자는 모델간의 거리를 유지하여 정보의 손실을 최소화한다. 이렇게 차원축소 시, 분산을 최대화하여 모델 간의 비유사성을 유지하고 정보의 손실을 최소화할 수 있다. 즉 PCA는 샘플들의 분산을 최대화하는 축인 주성분을 찾고 여기에 모델을 투영하여 차원을 축소한다.

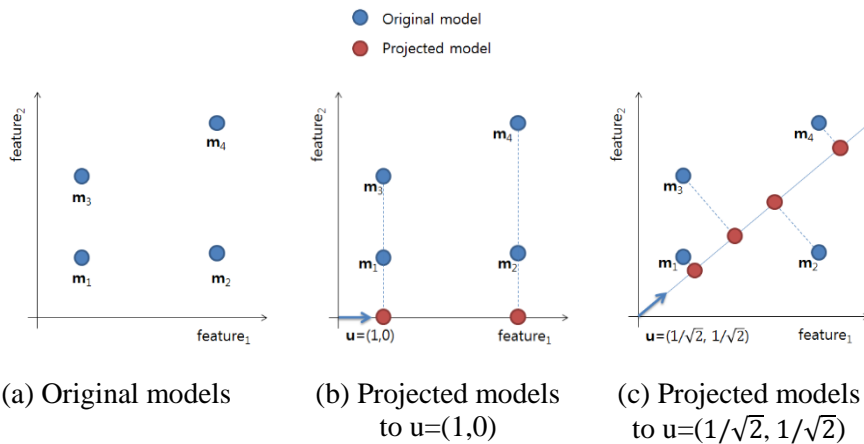


Figure 2.3 Dimensionality reduction by projection (오일석, 2008)

변환된 모델의 분산을 최대화하는 벡터인 주성분은 변환 전 모델들의 공분산행렬의 고유벡터이다. 공분산행렬은 식 (2.7)과 같이 정의된다.

$$Cov_m = \frac{1}{N_e} \sum_{i=1}^{N_e} (m_i - \bar{m})(m_i - \bar{m})^T \quad (2.7)$$



여기서  $N_e$  는 모델의 총 개수,  $m_i$  는  $i$  번째 모델,  $\bar{m}$  은 모델의 평균을 의미한다.

앞서 예제에서 설명했듯이, 모델들은 주성분으로 투영하여 차원을 축소할 수 있다. 모델의 집합을  $M$ 이라 하고 각 모델이  $D$  차원을 갖는다고 하면,  $d$ 개의 주성분을 이용하여  $d$ 차원의 공간으로 투영하는 식은 (2.8)과 같다.

$$X = UM \quad (2.8)$$

$U$  는 고유벡터로 이루어진 변환 행렬로  $[d \times D]$ 의 차원을 가지며 변환된 행렬  $X$ 는  $[d \times N_e]$ 의 차원을 갖는다.

이 때 사용하는 고유벡터의 개수, 즉  $d$  를 결정하는 것이 중요하다. 주성분, 즉 고유벡터의 중요도는 각 고유벡터에 대응하는 고유값(eigenvalue)과 같다. 따라서 고유벡터를 고유값이 큰 순서로 골라내야 한다. PCA를 통한 성공적인 차원축소를 위해서는 아래의 식 (2.9)을 만족하는 최소의  $d$ 를 사용해야 한다.

$$\frac{\sum_{i=1}^d \lambda_i}{\sum_{i=1}^{N_e} \lambda_i} > \alpha \quad (2.9)$$

여기서  $\lambda_i$ 는  $i$  번째 고유벡터인  $u_i$ 에 대응되는 고유값이며  $\alpha$ 는 문턱값을 의미한다. 일반적으로 0.7~0.9 사이의 문턱값을 사용할 때 효율적인 차원축소가 가능하다고 알려져있다. 본 연구에서는 0.8을 문턱값으로 사용하였다. Figure 2.4은 본 연구에서 사용한 참조필드에

대해 공분산행렬의 고유값을 내림차순으로 정리한 scree plot이다. 그림을 통해 확인할 수 있듯이 PCA를 통해 적은 수의 고유벡터로도 효과적으로 주요정보를 표현할 수 있다.

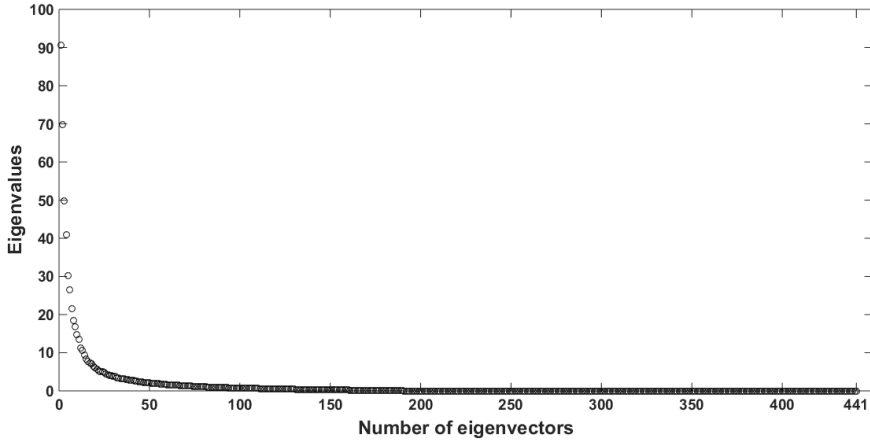


Figure 2.4 Scree plot of the eigenvalues (400 models with 21 by 21 grid system)

Figure 2.5는 PCA를 통해  $d$  차원으로 축소된  $N_e$  개의 모델들을 MDS를 통해 2차원에 나타낸 예시를 보여준다. MDS는 거리정보를 이용하여 모델간의 상대적인 거리를 유지하며 2차원 평면에 도시하는 방법이다. MDS를 수행하기 위해서는 거리행렬이 필요하다. 본 연구에서는 차원이 축소된 모델간의 비유사성을 유클리디안 거리로 정의하였다.

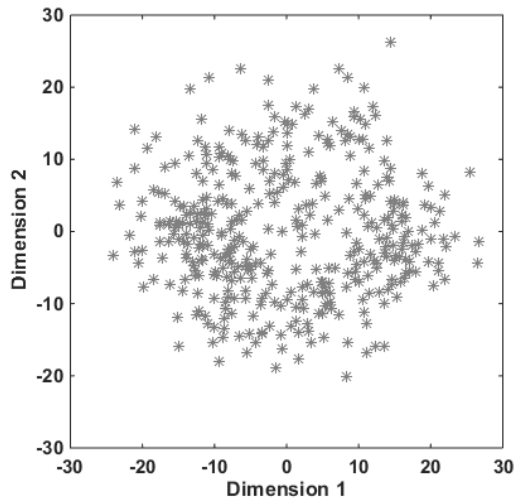


Figure 2.5 An example of 400 models projected in 2D plane by MDS

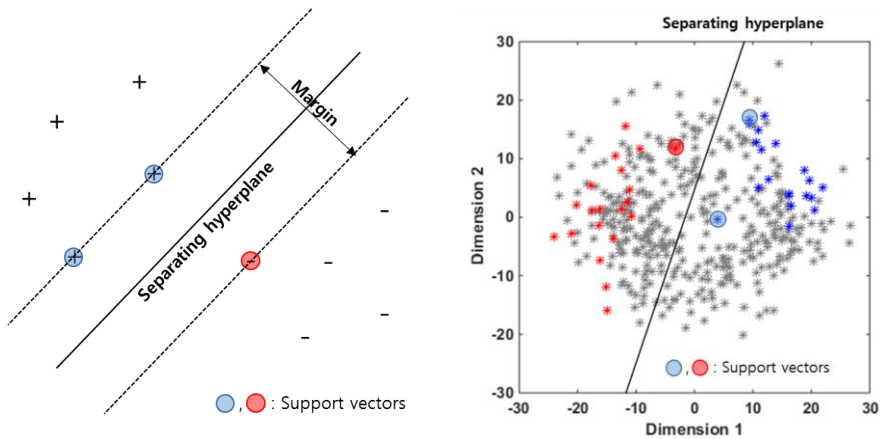
### 2.2.3 서포트 벡터 머신

SVM은 Vapnik의 통계학습이론에 기인하며 지도기계학습(supervised machine learning)의 일종으로 많은 분야에서 사용되는 분류기법 중 하나이다. SVM은 분류기(classifier)를 학습시키기 위해 학습모델들이 필요하며 이들은 두 가지 중 하나의 범주에 속한다. SVM에서 분류기는 곧 초평면(hyperplane)을 의미하며 이들은 샘플들을 두 가지의 범주로 구분하는 역할을 한다.

Figure 2.6a와 같이 초평면은 두 범주의 마진(margin)을 최대화하도록 정의된다. 마진은 내부에 모델이 존재하지 않는 초평면에 평행한 판의 너비로 정의된다. 서포트 벡터는 두 범주를 분류하는 초평면과 가장 가까운 모델을 의미한다. 이렇게 두 범주간의 마진, 즉 차이를 최대화하여 분류오차를 최소한으로 줄일 수 있다. 이렇게

초평면이 학습모델들에 의해 결정되고 나면 다른 모델들은 결정된 초평면에 따라 분류된다. SVM은 주로 패턴인식 분야에서 사용되기 때문에 지질학적인 패턴이 뚜렷한 채널저류층에 적용하기 매우 용이하다.

Figure 2.6b는 본 연구에서 SVM을 적용한 예제를 보여준다. PCA와 MDS를 통해 차원이 축소되어 2차원 평면에 존재하는 샘플을 대상으로 SVM을 수행하였다. 전체 샘플의 10%를 학습모델로 사용하였으며 기준은 WOPR로 하였다. 즉, 실제 관측값과 가장 작은 WOPR 오차를 가지는 5% 모델들과, 가장 큰 WOPR 오차를 가지는 5% 모델들을 학습 모델로 지정하고 초평면을 결정하여 나머지 모델들을 분류하였다. Figure 2.6b에서 파란색과 빨간색으로 표기된 모델은 각각 WOPR 오차가 낮고 높은 학습모델을 보여준다. 낮은 WOPR 오차를 가지는 모델들이 좋은 모델이므로 파란색의 학습 모델이 존재하는 범주에 속하는 모델들을 선택할 수 있다.



(a) A concept of SVM

(b) Classification of 400 models

Figure 2.6 Classification using SVM

PCA는 지질학적인 비유사성을 보존하면서 차원을 축소하기 때문에 2차원 평면에 가깝게 존재하는 모델들은 채널연결성, 연속성, 패턴 등의 특징이 유사하다. 따라서 이러한 2차원 평면에서 오일생산량을 기준으로 학습모델들을 선택하고 SVM을 시행하는 것은 지질학적인 특징과 생산거동 등을 동시에 고려하는 방법이다. PCA, MDS, SVM으로 구성되는 제안된 분류방법의 시행으로 한 번에 시행 전 모델의 45~55%의 모델을 선택할 수 있다. 본 연구에서는 초기모델의 30% 이하가 될 때까지 위의 과정을 반복하였다. Figure 2.7은 본 연구에서 사용한 IGMSS를 예시로서 자세히 나타낸 것이다.

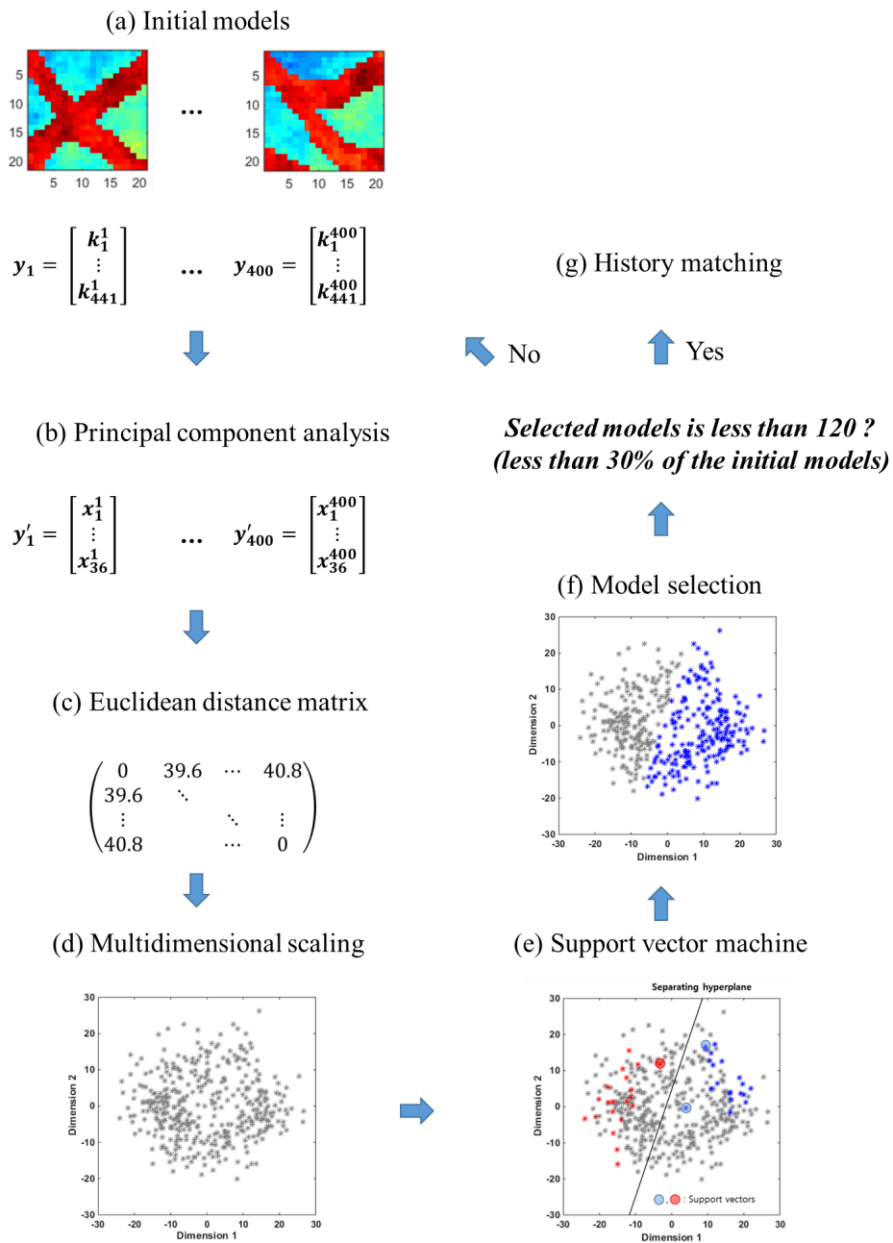


Figure 2.7 Overall procedure of the IGMSS with actual examples ( $k$  means permeability and  $x$  is new parameter transformed by PCA)

## 2.3 채널저류층 특성화를 위한 역산기법

좋은 초기모델을 선택하여 앙상블의 평균이 참값에 근사해야 한다는 가정을 만족하더라도 일반적인 앙상블기반기법으로는 채널저류층의 특징을 보존하기 어렵다. 따라서 이봉분포를 유지하여 채널의 특징을 보존할 수 있고 계산효율 또한 높은 적절한 역산기법을 사용하는 것이 중요하다. 본 연구에서는 DCT와 채널정보교정법을 ES에 결합하여 채널저류층을 특성화하였다.

### 2.3.1 이산코사인변환

DCT는 이미지 등의 정보를 이산적인 코사인함수의 계수로 변환하는 방법으로 신호처리 및 영상처리에 널리 사용된다(김성일, 2017). DCT는 이산푸리에변환(discrete Fourier transform, DFT)와 유사한 변환이며 수식적으로는 길이가 두 배이며 실수값을 가지는 짝함수에 DFT 연산을 수행하는 것과 동일하다. DFT로 변환된 자료는 복소수로 표현되는 반면, DCT는 모두 실수의 계수로 변환하기 때문에 자료처리에 용이하다.

식 (2.10)과 (2.11)은 1차원의 DCT를 설명하는 수식이며. 역이산코사인변환(inverse discrete cosine transform, IDCT)은 식 (2.12)와 같다.

$$v(k) = \alpha(k) \sum_{n=0}^{N-1} u(n) \cos \left[ \frac{\pi(2n+1)k}{2N} \right], 0 \leq k \leq N-1 \quad (2.10)$$

$$\alpha(k) \equiv \begin{cases} \sqrt{2/N}, & k = 0 \\ \sqrt{1/N}, & 1 \leq k \leq N-1 \end{cases} \quad (2.11)$$

$$u(n) = \sum_{k=0}^{N-1} \alpha(k)v(k)\cos\left[\frac{\pi(2n+1)k}{2N}\right], \quad 0 \leq n \leq N-1 \quad (2.12)$$

여기서,  $u(n)$  은 입력신호, 즉 원래의 데이터를 의미하고  $N$  은 데이터의 크기를 의미한다. DCT를 통해 변환된 계수는  $v(k)$  로 표현될 수 있다. DCT로 자료를 매개변수화하면 자료의 수, 즉  $N$  개의 코사인함수를 이용하며, 계수의 개수도  $N$  이 된다. IDCT 수행과정에서  $N$  개의 계수를 그대로 이용하여 역변환을 수행하면 데이터 손실없이 원래의 자료인  $u(n)$  을 온전히 얻을 수 있다. 2차원 자료에 DCT를 수행할 경우, 각 방향으로의 1차원 DCT 변형을 통해 데이터가 매개변수화 된다. 즉 2차원의  $N \times N$  격자를 가지는 자료는 DCT를 통해  $N \times N$  의 코사인함수의 계수로 이루어진 행렬로 변환된다.

일반적으로 IDCT를 수행할 때, 모든 코사인계수를 이용하지는 않는데, 이는 일부의 자료만으로도 원래의 자료특징을 효과적으로 보존할 수 있기 때문이다. 이는 코사인의 파장이 큰 저주파성분에 대부분의 에너지가 집중되는 현상에 기인한다. 따라서 저주파의 코사인함수의 계수는 고주파의 것보다 전반적인 경향을 나타내는 정보를 표현한다. 사람이 육안으로 알아볼 수 있는 이미지 정보는 보통 일관된 경향이나 패턴을 가지므로 일부 계수만으로도 이를



나타낼 수 있다.

2차원 DCT 계수행렬의 경우, 왼쪽 위에 있는 계수일수록 저주파의 코사인함수를, 오른쪽 아래에 있는 계수일수록 고주파의 코사인함수를 표현한다. 따라서 오른쪽 아래의 계수를 배제하고 왼쪽 위에 존재하는 일부 계수만 사용하여 IDCT를 수행하면 잡음은 제거하고 전반적인 경향을 파악할 수 있다.

Figure 2.8은 21 by 21의 격자시스템의 채널저류층에 DCT를 적용하여 얻은 성분 중 일부만 사용하는 과정이다. 첫 번째 그림은 유체투과율로 필드이며 두 번째 그림은 DCT를 수행하여 얻어진 계수행렬이다. 이 때 DCT 계수의 경우 코사인함수에 따라 음 또는 양의 값을 갖고 그 변화의 폭이 크기 때문에 편의를 위해 절대값에 자연로그를 취한 값으로 가시화하였다. 세 번째 그림은 계수행렬에서 좌측 상위에 존재하는 요소만 선별한 것이다. 마지막 그림은 선별된 계수로만 IDCT를 수행한 결과로, 경계의 뚜렷함은 약해지지만 일부의 계수만으로도 패턴을 확실히 파악할 수 있다.

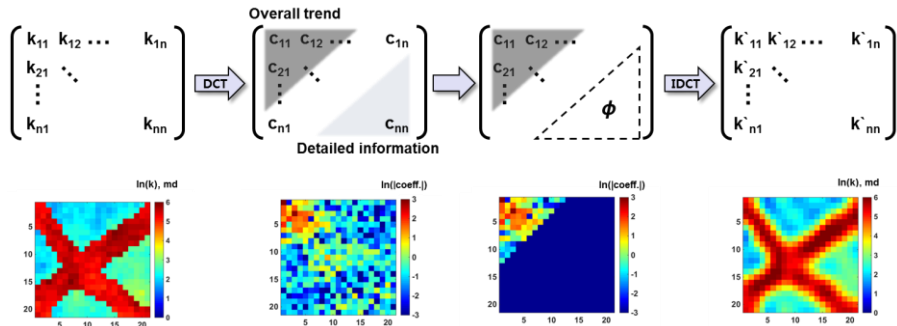


Figure 2.8 Example of DCT application on a channel reservoir model

본 연구에서는 ES를 이용한 히스토리매칭에 DCT를 적용하기 위해 각 모델의 유체투과율값을 DCT를 사용하여 변환하고 상단에 존재하는 일부의 계수들만 ES를 통해 교정하였다. 이 후 교정된 계수들은 다시 IDCT를 통해 유체투과율값으로 변환된다. 21 by 21의 격자시스템으로 이루어진 필드의 경우 78개의 계수(18%)를 이용하였으며 60 by 60 by 3의 필드의 경우 630개의 계수(6%)를 특성화에 이용하였다.

### 2.3.2 채널정보교정법

사암과 셰일, 두 암상의 큰 유체투과율 차이로 인해 채널저류층의 유체투과율 분포는 일반적으로 이봉분포를 따른다. 따라서 추가적인 방법 없이 양상불기반기법을 통해 교정하면 유체투과율은 정규분포를 따르게 되므로 성공적인 특성화가 어렵다. 그 결과 채널의 경계가 흐려지고 연속성 및 연결성을 표현하지 못하며 오버슈팅이 발생한다. 따라서 정규분포를 따르는 교정 후 인자들을

적절한 방법을 통해 이봉분포로 변환시켜주는 과정이 필요하다.

본 연구에서는 채널저류층의 특성을 나타내는 인자를 채널정보로 정의하고 이를 ES의 상태벡터에 추가하여 교정하는 채널정보교정법을 제안한다. 여기서 채널정보는 사암의 로그유체투과율 평균값, 셰일의 로그유체투과율 평균값, 그리고 사암의 암상 비율로 정의된다.

언급된 세 가지의 채널정보는 식 (2.13)과 같이 각각의 초기 모델에서 계산되어 상태벡터에 추가된다. 이 후, 채널정보는 다른 석유물리학적 인자들과 함께 ES에 의해 교정된다.

$$y = \begin{bmatrix} m_k^s \\ m_k^d \\ \varphi \\ \mu_{sand} \\ \mu_{shale} \\ d_1 \\ \vdots \\ d_N \end{bmatrix}, \quad t = 1, \dots, N \quad (2.13)$$

여기서,  $\varphi$  는 사암의 암상 비율,  $\mu_{sand}$  는 사암의 로그유체투과율 평균값,  $\mu_{shale}$  은 셰일의 로그유체투과율 평균값을 의미한다. 이는 ES의 상태벡터인 식 (2.6)에 세 가지의 인자만 추가한 형태이다.

이 때 교정된 상태벡터를 이용하여 두 개의 CDF를 계산할 수 있다. 첫 번째는 교정된 유체투과율의 CDF이며 이는 정규분포를 따른다. 두 번째는 교정된 채널정보를 이용하여 생성한 CDF로 이봉분포를 따른다. 두 개의 CDF를 이용하여 정규분포를

이봉분포로 변환하는 CDF 맵핑을 수행하면 ES의 유체투과율 교정결과를 반영하면서도 이봉분포를 따르는 결과를 얻을 수 있다. 식 (2.14)과 식 (2.15)는 CDF 맵핑의 과정을 보여주며 식 (2.16)은 각 암상의 유체투과율 분포가 로그정규분포를 따른다는 가정하에 이봉분포 CDF를 생성하는 과정을 보여준다. Figure 2.9은 CDF 맵핑을 예제로서 설명한 것이다.

$$F_X(x) = P(X \leq x), F_Y(y) = P(Y \leq y) \quad \text{for all } x, y \in \mathbf{R} \quad (2.14)$$

$$y = F_Y^{-1}(F_X(x)) = T(x) \quad (2.15)$$

$$\begin{aligned} F_Y(x) &= \varphi \times F_{sand} + (1 - \varphi) \times F_{shale} \\ &= \frac{\varphi}{2} \left\{ 1 + \operatorname{erf} \left( \frac{x - \mu_{sand}}{\sigma_{sand}\sqrt{2}} \right) \right\} \\ &\quad + \frac{(1 - \varphi)}{2} \left\{ 1 + \operatorname{erf} \left( \frac{x - \mu_{shale}}{\sigma_{shale}\sqrt{2}} \right) \right\} \end{aligned} \quad (2.16)$$

여기서,  $F_X$ 와  $F_Y$ 는 각각 정규분포를 따르는 변수  $X$ 와 이봉분포를 따르는 변수인  $Y$ 의 CDF이다.  $\mathbf{R}$ 은 실수 집합을 의미하고  $T(\cdot)$ 는 CDF 맵핑함수를,  $\operatorname{erf}(\cdot)$ 는 오차함수를 의미한다.  $\sigma_{sand}$ 과  $\sigma_{shale}$ 는 각각 사암과 셰일의 표준편차를 의미한다. 본 논문에서는  $\varphi$ ,  $\mu_{sand}$ , 그리고  $\mu_{shale}$ 만 교정하였다. 민감도분석을 통해  $\sigma_{sand}$ 과  $\sigma_{shale}$ 가 특성화 결과에 미치는 영향은 미미하다는 것이 파악되었으므로 이들은 초기모델들의 평균값으로 고정하여 변환을 수행하였다.

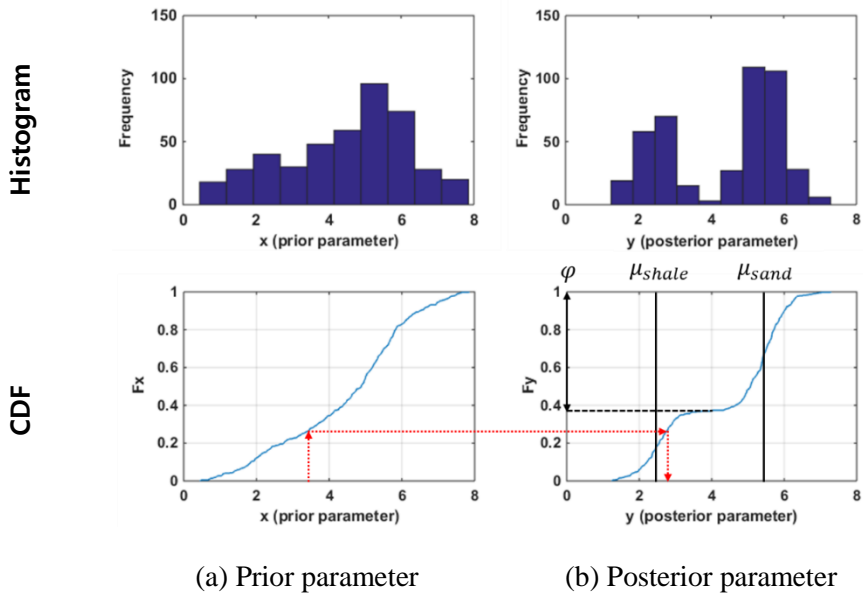


Figure 2.9 An example of CDF mapping: histogram and CDF of prior parameter and posterior parameter ( $\mu_{sand}$ ,  $\mu_{shale}$ , and  $\varphi$  are updated)

Figure 2.10는 본 연구에서 제안하는 역산기법의 흐름도를 나타낸 것이다. 전체적인 이해를 돕기 위해 각 단계에 해당하는 상태벡터와 필드를 같은 행에 표기하였다. 구체적인 순서는 아래와 같다.

1. 2.2장에서 제시된 IGMSS를 통해 선택된 모델을 초기 모델로 하여 역산을 진행한다.
2. 각 모델에서 암상비율, 사암과 셰일의 로그유체투과율 평균값 등 주요채널정보를 계산하여 상태벡터에 추가한다.
3. 각 모델, 즉 상태벡터의 유체투과율값에 DCT를 수행하고

좌측 상위의 일부 계수만 선택적으로 남긴다. 이 때, 2단계에서 계산한 채널정보는 변하지 않는다.

4. 선택된 DCT 계수와 채널정보로 이루어진 상태벡터를 ES를 통해 교정한다.
5. 교정된 DCT 계수에 IDCT를 수행하여 유체투과율값으로 환원한다.
6. 환원된 유체투과율값은 정규분포를 따른다. 따라서 CDF 맵핑을 통해 교정된 채널정보를 이용하여 생성한 이봉분포의 값으로 변환한다.
7. 최종적으로 얻어진 유체투과율값으로 미래생산거동을 예측한다.

이 후 본 논문에서는 이 역산기법을 ‘제안된 역산기법’으로 명명하며 이는 본 연구의 ‘제안방법’과는 구분된다. IGMSS와 제안된 역산기법을 결합한 것이 본 연구의 제안방법이다.

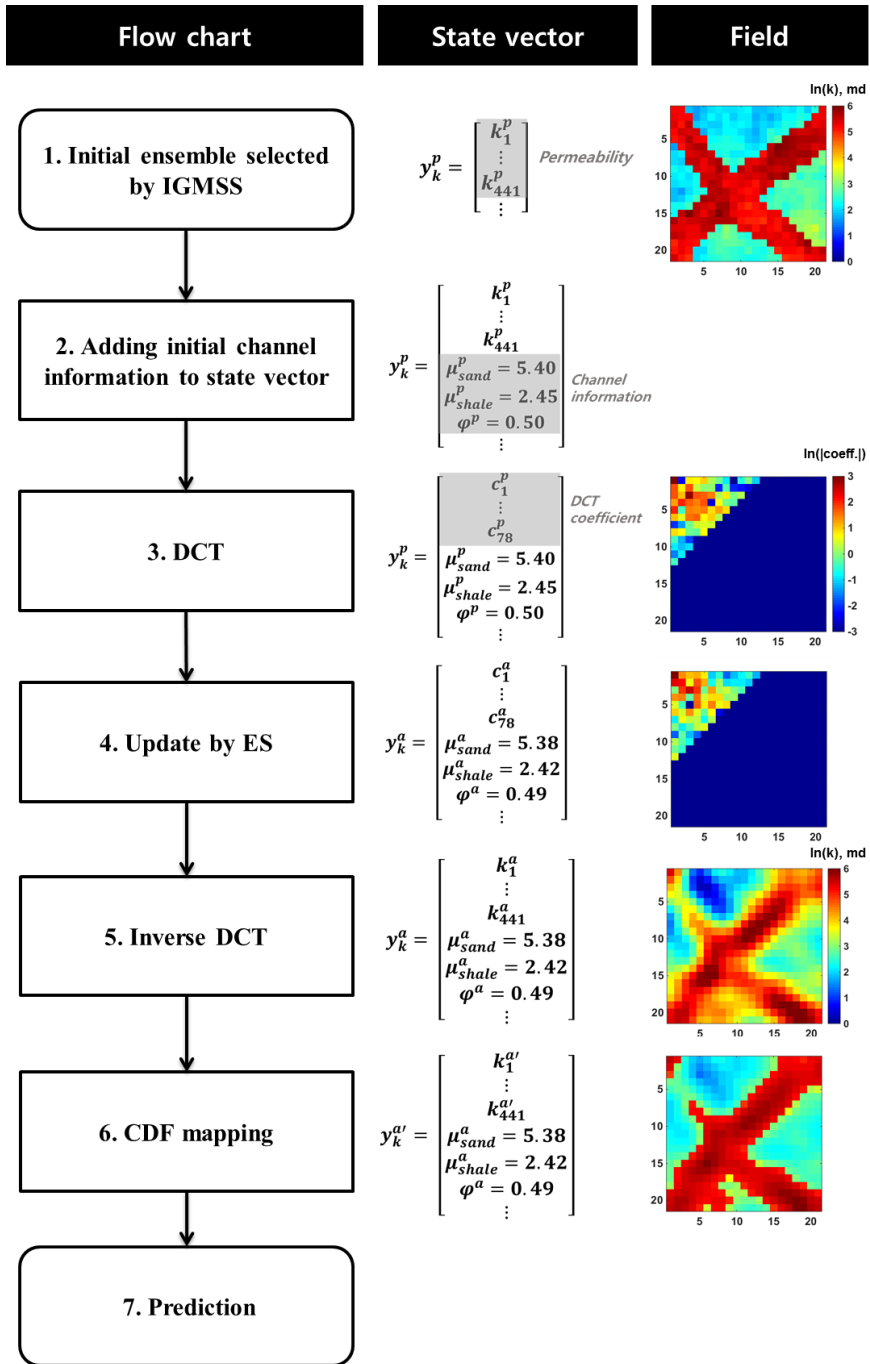


Figure 2.10 Overall procedures of the proposed inverse scheme

### 3. 제안방법의 적용결과

특성화의 목적은 신뢰할만한 저류층모델을 구축하여 미래생산거동 및 매장량을 올바르게 예측하고 이를 통해 의사결정의 근거를 제공하는 것이다. 본 장에서는 여러가지 최적화방법을 통해 채널저류층 특성화를 수행하고 그 결과를 비교하였다. 결과는 유정별 오일생산량 및 워터컷, 누적 오일 및 물생산량, 평균 로그유체투과율, 로그유체투과율 예시, 채널정보 히스토그램 순으로 제시한다. 여기서 워터컷이란 전체 생산유체에서 물이 차지하는 비율을 의미한다.

제안방법의 특성화 성능 및 예측 신뢰성을 검증하기 위해 다양한 케이스를 비교하였다. Figure 3.1은 본 연구에서 적용한 최적화 기법들의 흐름도를 나타낸다. Case 1은 정적자료 통합을 통해 얻어진 초기 400개 모델들의 결과이다. Case 2는 본 연구에서 제시하는 IGMSS를 통해 선택된 모델들의 결과이다. Case 1과 Case 2는 역산기법을 사용하지 않는다. Case 3은 초기모델을 입력값으로 사용하는 기본 ES, Case 4는 IGMSS로 선택된 모델들로 기본 ES를 수행한 결과이다. Case 5은 2.3장에서 설명한 ‘제안된 역산기법’으로 초기모델을 특성화한 결과이다. Case 6는 본 연구의 ‘제안방법’으로, IGMSS로 선택된 모델에 제안된 역산기법을 통해 히스토리매칭을 수행한다. Table 3.1은 케이스 별 각 기법의 적용여부를 표로 정리한 것이다.



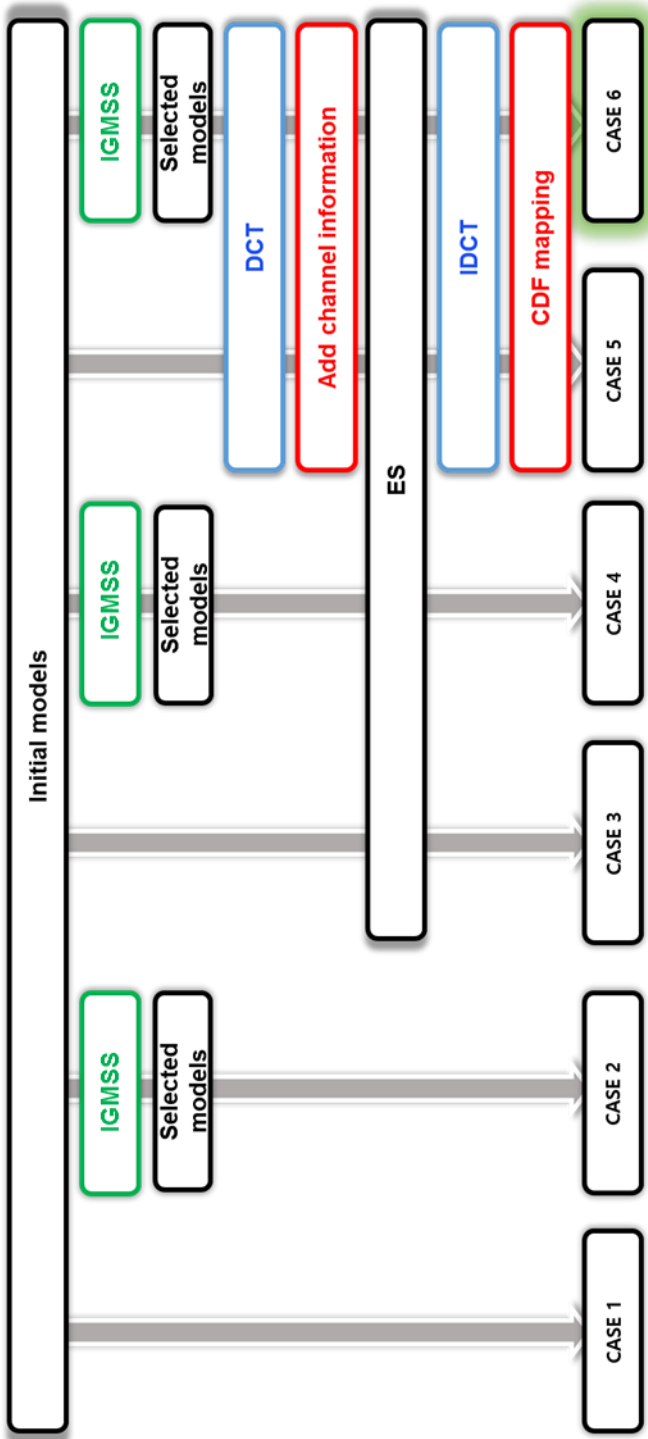


Figure 3.1 Comparison between the cases (Case 6 is the proposed method)

Table 3.1 Summary on the simulation setup for 6 cases

	The number of models	Use of IGMSS	Type of inverse method
Case 1	400	No	None
Case 2	Less than 120	Yes	None
Case 3	400	No	ES
Case 4	Less than 120	Yes	ES
Case 5	400	No	Proposed inverse method
Case 6	Less than 120	Yes	Proposed inverse method


또한 다양한 필드에 위의 기법들을 적용하고 결과를 비교하였다. 본 연구에서는 아래와 같은 3개의 필드에 대한 적용결과를 제시한다.

- 1) Field 1: 간단한 2차원 채널저류층
- 2) Field 2: 복잡한 2차원 채널저류층
- 3) Field 3: 3차원 채널저류층(Egg 모델)

Field 1은 하나의 TI만 이용하여 암상을 생성하였으며, Field 2는 다양한 방향의 채널패턴을 생성하기 위해 서로 다른 방향의 TI 4개를 사용하였다. Field 3은 3개의 TI를 사용하여 생성한 3차원 모델로 제안방법의 3차원 확장성을 검증하고자 하였다. Figure 3.2은 각 케이스에서 사용된 TI를 나타낸다.


모든 케이스에서 초기양상블은 400개이며, 2.2.1에서 설명한 것과

같이 초기암상블은 SNEsim과 SGS를 사용하여 생성하였다. 즉, SNEsim을 통해 암상을 구분하고, SGS로 각 암상의 유체투과율분포를 설정해 주었다. 전위모델로는 Schlumberger 社의 ECLIPSE 100을 이용하였다. 이는 블랙오일모델 기반의 저류층 시뮬레이터로 압력에 따라 물, 오일, 가스의 물성이 변하는 것을 가정한다. ES와 제안방법의 모든 추가적인 기법은 MATLAB 기반으로 프로그래밍하였다.



$90^\circ$  (from y axis)

(a) Field 1




$0^\circ$

$45^\circ$


$90^\circ$

$-45^\circ$


(b) Field 2



$0^\circ$



$30^\circ$



$-30^\circ$

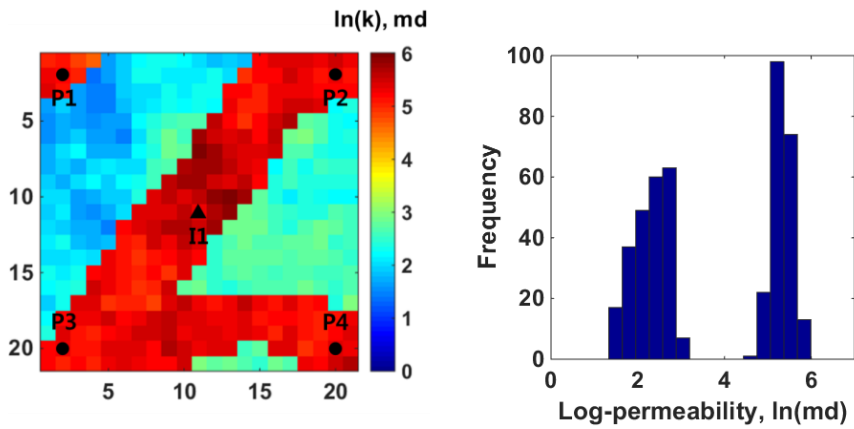
(c) Field 3

Figure 3.2 Various TIs for Field 1, Field 2, and Field 3

### 3.1 간단한 2 차원 채널저류층

Figure 3.3a는 Field 1의 참조필드, Figure 3.3b는 참조필드의 히스토그램이다. 중앙의 주입정(II)이 4개의 생산정(P1, P2, P3, P4)으로 둘러싸인 역 5점 공법(inverted 5-spot)으로 오일을 생산한다. 참조필드는 P2와 II, 그리고 P3로 연결되는 대각선 방향과 P3와 P4로 연결되는 가로방향의 뚜렷한 사암연결성을 보이며 유체투과율의 분포가 이봉분포를 나타낸다. 21 by 21 by 1의 격자시스템으로 이루어진 2차원 저류층으로 각 격자는 x, y, z 방향으로 각각 50, 50, 20 ft의 크기를 가진다. Tables 3.2~3.4 은 Field 1의 자세한 저류층 및 시뮬레이션 조건을 나타낸다.

히스토리매칭을 위해 100, 200, 300, 400, 500일, 총 5개 교정시점의 동적자료를 취득하였다. 역산에 사용된 동적자료는 WOPR이며 미래거동예측은 1,000일 까지 수행하였다. 이는 본 연구에서 사용된 모든 특성화 방법에서 동일하다.



(a) The reference field

(b) Histogram of the reference

Figure 3.3 Log permeability field and histogram of the reference (Field 1)

Table 3.2 Channel information (Field 1)

Parameters	Values
Reservoir type	Channel oil reservoir
Facies	Sand and shale
Ratio of sand, fraction	0.47
Mean of $\ln(k_{sand}), \ln(md)$	5.34
Mean of $\ln(k_{shale}), \ln(md)$	2.37

Table 3.3 Well locations and operating conditions (Field 1)

Well names	Locations, coordinate	Control mode
I1	(11, 11)	Constant injection rate (300 stb/day)
P1	(2, 2)	Constant BHP (500 psi)
P2	(20, 2)	
P3	(2, 20)	
P4	(20, 20)	

Table 3.4 Petrophysical parameters for simulation (Field 1)

Parameters		Values
Top depth, ft		2,700
Oil-water contact, ft		3,000
Initial pressure, psi		2,000
Porosity, fraction		0.2
Formation volume factor, rb/stb	Water	1 at 2,000 psig
	Oil	1.012 at 0 psig 1.011 at 1,000 psig 1.01 at 2,000 psig
Density of fluid, lb/ft <sup>3</sup>	Water	48.6
	Oil	62.3
Viscosity of fluid, cp	Water	1
	Oil	3
Compressibility, 1/psi	Water	5.00E-07 at 2,000 psig
	Oil	3.00E-05 at 2,000 psig

### 3.1.1 유정별 오일생산량 및 워터컷

Figure 3.4와 Figure 3.5는 각 케이스의 WOPR 및 유정별 워터컷(well water-cut, WWCT) 미래예측을 보여준다. 회색 실선은 각 모델의 예측결과이며 파란색 실선은 모델들의 평균이다. 빨간색 점선은 참조필드의 거동을 의미한다. 신뢰성있는 미래예측을 위해서는 모델들의 평균거동이 실제 참조필드의 값과 유사해야 하며, 개별모델 결과인 회색 실선이 적절한 불확실성 범위를 가져야 한다. 또한 실제 관측값이 예측 불확실성의 범위내에 포함되는 것이 중요하다.

Figure 3.4a는 정적자료를 통합하여 생성한 초기 400개 모델, 즉 Case 1의 오일생산량 예측결과이다. 또한 Figure 3.4b는 초기 400개 모델에서 IGMSS를 사용하여 선택한 모델, 즉 Case 2의 유정별 오일생산량이다. Field 1의 경우 IGMSS를 사용하여 96개의 모델이 선택되었다. Figure 3.4a에서 확인할 수 있듯이 초기양상들은 굉장히 큰 불확실성을 보인다. 또한 모델들의 평균 예측값이 참조필드의 실제 관측값과 크게 차이나는 것을 확인할 수 있다. 하지만 IGMSS에 의해서 모델을 선택한 경우 예측 불확실성을 크게 감소시켰으며 P1, P2, 그리고 P3 유정에서 모델들의 평균값이 실제 관측값에 가까워졌다(Figure 3.4b).

Figure 3.4c와 Figure 3.4d는 각각 Case 3과 Case 4의 결과이다. Case 3의 경우 여전히 큰 예측 불확실성을 보인다. 이는 400개의 모델을 사용하며 여러 번의 교정을 수행하지 않고 단 한번의 전역교정을




수행하는 ES의 한계이다. Case 4의 경우 적절한 예측 불확실성 범위를 제공하며 평균값도 실제 관측값에 가깝게 예측하여 신뢰성 있는 결과를 보여준다.

Case 5는 Case 3와 거의 유사한 결과를 보여준다(Figure 3.4e). DCT 및 채널정보교정법을 추가로 사용하여도 400개의 모델을 입력값으로 단 한번의 교정을 수행하기 때문에 예측값의 범위가 크게 감소하지 않았다. Case 6은 다른 모든 케이스와 비교할 때 가장 좋은 WOPR 예측결과를 보여준다. 모든 유정에서 적절한 불확실성 범위를 제공하며 평균값이 실제 관측값과 모든 시점에서 거의 일치했다. 특히 Case 4에서 P2 유정의 평균 예측값이 초기 500일 이전의 관측값과 불일치하는 것과 P4 유정에서 500일 이후의 관측값을 정확히 예측하지 못하는 현상을 개선하였다.


Figure 3.5는 Field 1에 대한 각 케이스의 WWCT 예측결과를 도시한 것이다. 전반적으로 WOPR과 유사한 결과를 보여주지만 좀 더 불확실성의 폭이 크며 참값을 맞추기가 어렵다. 이는 모델을 교정하는 기준이 WOPR이기 때문이다.

Case 1은 모든 유정에서 예측결과의 불확실성이 매우 크며, 평균값이 관측값과 크게 다르다(Figure 3.5a). Case 2는 Case 1에 비해 예측범위가 크게 감소하며 평균값 또한 실제값에 가까운 결과를 제공한다(Figure 3.5b). Case 3(Figure 3.5c)와 Case 5(Figure 3.5e)는 Case 1에 비해서는 불확실성을 감소시켰지만 P2, P3 그리고 P4 유정에서 여전히 큰 밴드폭을 가지기 때문에 의사결정에 사용하기는 어렵다.


Case 4(Figure 3.5d)와 Case 6(Figure 3.5f)은 적절한 불확실성의 범위를 제공한다. 하지만 Case 4의 경우 P2, P3, P4 유정에서 모델들의 평균값이 실제 관측값에서 벗어난다. 제안방법인 Case 6은 모든 유정에서 파란 실선이 빨간 점선과 거의 일치하여 신뢰할만한 결과를 제공한다.




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4

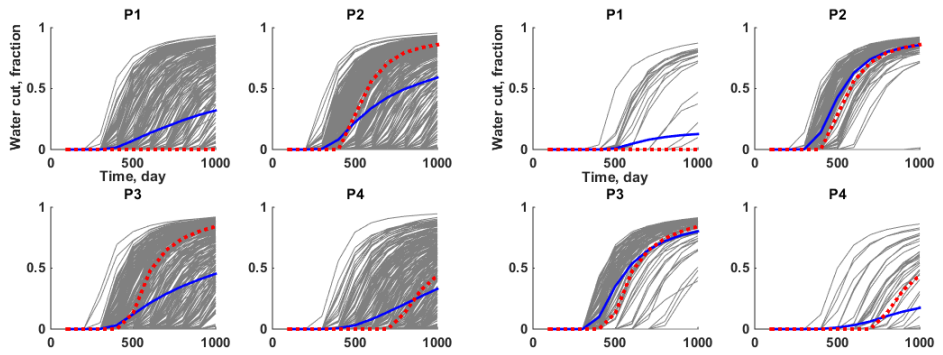


(e) Case 5



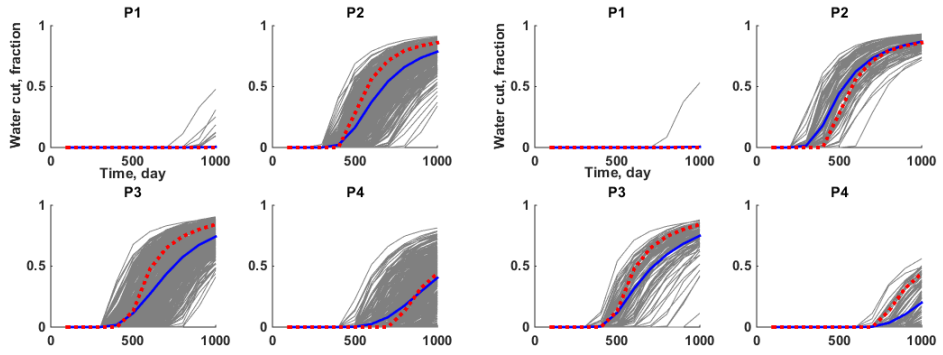
(f) Case 6

Figure 3.4 WOPR predictions of all cases (Field 1)



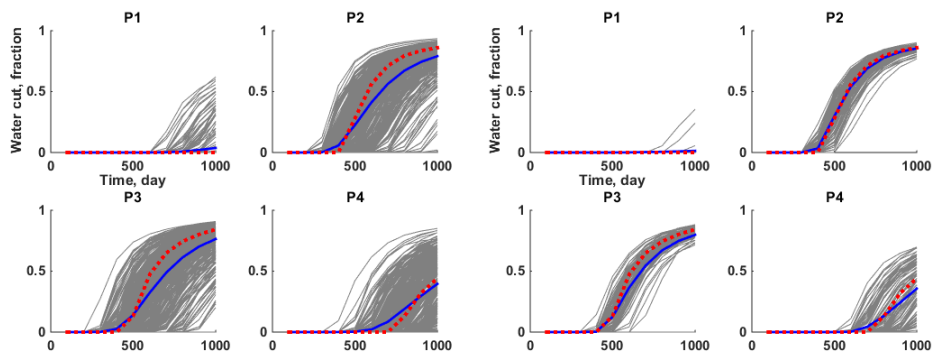
(a) Case 1

(b) Case 2



(c) Case 3

(d) Case 4



(e) Case 5


(f) Case 6

Figure 3.5 WWCT predictions of all cases (Field 1)


### 3.1.2 누적 오일 및 물 생산량

Figure 3.6은 각 케이스의 누적 오일 및 물 생산량을 보여준다. Figure 3.6a에서 확인할 수 있듯이 Case 1의 경우 오일 및 물 생산량에서 모두 큰 불확실성을 보이며 특히 물생산량의 경우 불확실성이 너무 커서 신뢰성 있는 미래거동예측이 불가능하다. Case 2의 경우 누적 생산량의 불확실성을 감소시킨다(Figure 3.6b). 오일생산량의 경우 소폭 감소되며 물생산량의 불확실성은 큰 폭으로 감소한다.


Case 3과 Case 5는 모두 Case 1에 비해서는 감소된 밴드폭을 보여주지만 Case 2와 비슷한 불확실성 범위를 제공한다(Figures 3.6c and e). Case 4는 적절한 오일생산량 불확실성 범위를 제공하며 물생산량의 불확실성 범위 또한 Case 2에 비해 소폭 감소시킨다(Figure 3.6d). Figure 3.6f는 Case 6의 결과로, 누적 오일 및 물 생산량의 미래거동예측에서 가장 신뢰할만한 결과를 제공한다. 가장 적은 폭의 불확실성 범위를 가지며 모델들의 예측값 평균도 실제 관측값과 가장 유사하다.




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6

Figure 3.6 FOPT and FWPT predictions for all cases (Field 1)

### 3.1.3 평균 로그유체투과율

Figure 3.7는 각 케이스의 평균 로그유체투과율 결과를 보여준다. Case 1의 평균 필드(Figure 3.7a)의 경우 채널의 연결성이 명확하지 못하며 참조필드의 채널패턴과는 전혀 다른 경향을 보인다. 특히 대각선 방향의 연결성이 보이지 않는다. 하지만 Case 2의 평균 필드(Figure 3.7b)의 경우 P2과 P3를 연결하는 대각선 방향의 채널연결성을 확보하며 비교적 뚜렷한 사암경계를 가진다. 하지만 P3와 P4를 연결하는 가로 방향의 사암연결성은 찾아내지 못하였다.

Figure 3.7c는 초기모델에 ES를 수행한 Case 3의 결과이며, Figure 3.8d는 선택된 모델에 ES를 수행한 Case 4의 결과이다. 제안된 역산기법으로 초기 모델을 교정한 Case 5의 결과는 Figure 3.7e에, 동일기법으로 선택된 모델을 교정한 Case 6의 결과는 Figure 3.7f에 나타내었다. Case 3~6의 모든 결과는 참조필드에서 대표되는 두가지 채널연결성을 모두 성공적으로 찾아낸다. 이는 Field 1이 비교적 간단한 검증 차원의 필드이며, 하나의 TI만 사용하여 초기모델의 복잡성이 비교적 낮기 때문이다.




Figure 3.7 Average log permeability fields of all cases (Field 1)



### 3.1.4 로그유체투과율 예시

Figure 3.8은 각 케이스별 두 개의 임의의 모델의 유체투과율과 히스토그램을 보여준다. Figure 3.8a는 Case 1의 두 개의 예시모델을 보여준다. 두 개의 모델 모두 대각선 방향의 채널연결성을 가지는 참조필드와는 확연히 다른 채널연결성을 보인다. Case 2의 경우 임의로 선택한 두 개의 모델 모두 대각선 방향의 사암연결성을 잘 나타내어 Case 1에 비해 참조필드와 비슷한 채널경향을 가진다(Figure 3.8b).

Case 3의 경우 Figure 3.8c에서 확인할 수 있듯이, 유체투과율의 분포를 크게 변화시키지 못한다. 이것은 단 한번의 전역교정을 수행하는 ES의 한계라 볼 수 있다. 유체투과율의 히스토그램 또한 이봉분포가 아닌 정규분포에 가까운 형태를 가진다. 따라서 채널의 경계가 명확하지 못하고 채널의 특성을 보존하지 못한다. Case 4의 경우 유체투과율의 분포가 참조필드에 더 가까우며 채널의 연결성 또한 유사하여 Case 3보다는 개선된 결과를 보여준다(Figure 3.8d). 하지만 여전히 이봉분포가 아닌 정규분포를 따라 경계가 흐리다.

Figure 3.8e에서 볼 수 있듯이 Case 5는 유체투과율이 이봉분포를 따르며 채널경계가 명확하다. 하지만 유정간의 사암연결성을 잘못 파악한다. Case 6은 가장 개선된 결과를 보여준다(Figure 3.8f). 채널의 패턴과 유정간 사암연결성이 참조필드와 거의 유사하며 유체투과율이 이봉분포를 따라 채널경계 또한 명확하다.

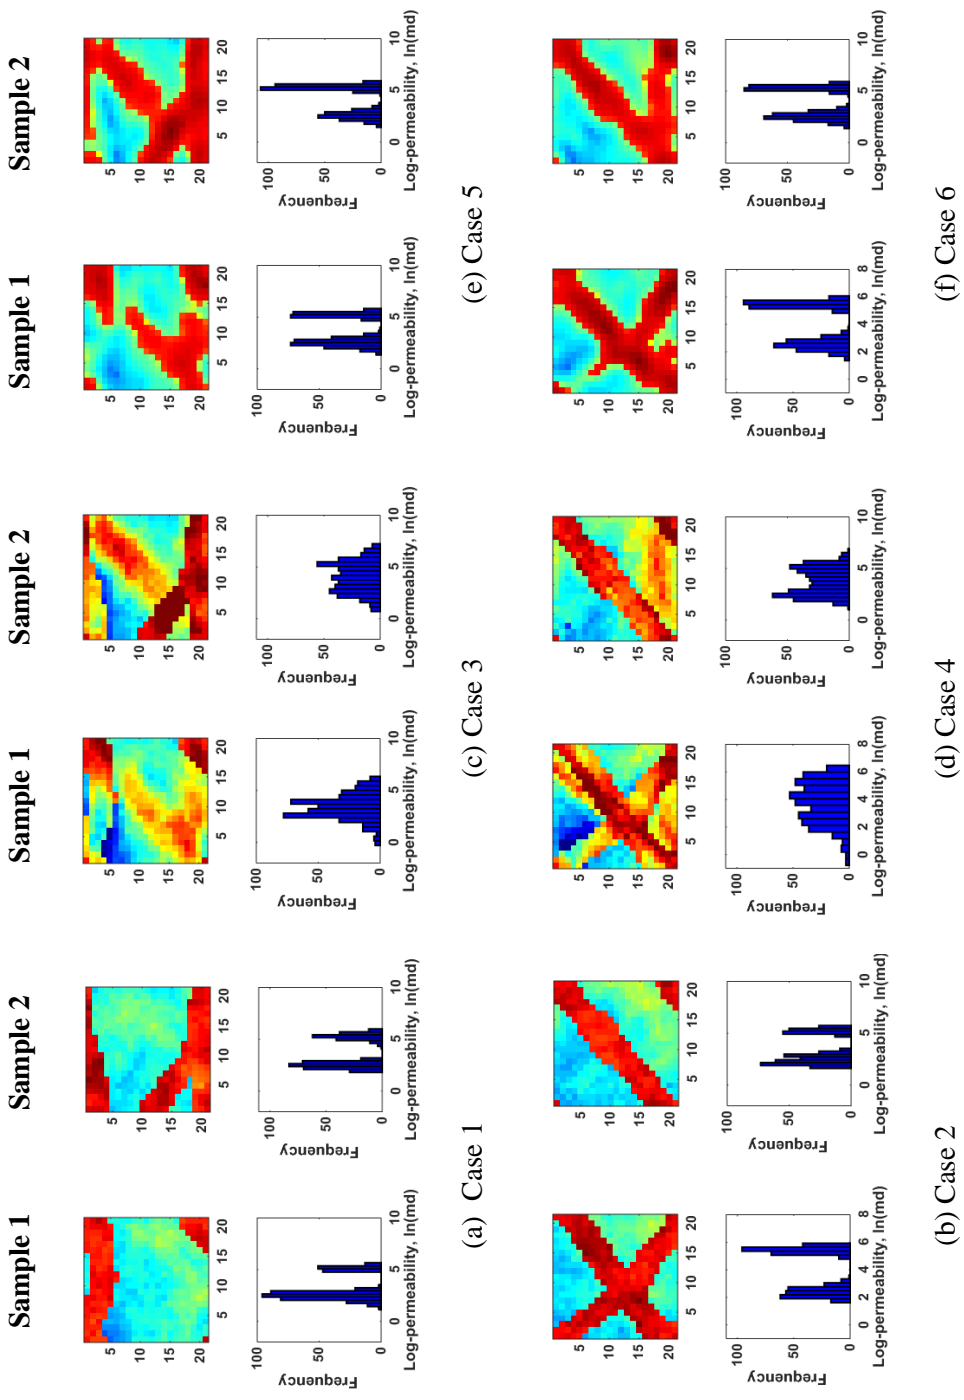


Figure 3.8 Log permeability fields and their histograms of two ensemble members of each case (Field 1)

### 3.1.5 채널정보 히스토그램

Figure 3.9은 정의된 세 가지의 채널정보, 즉 사암의 로그유체투과율 평균, 세일의 로그유체투과율 평균, 그리고 사암의 암상비율을 히스토그램으로 표현한 것이다. 제안된 역산기법이 아닌 전통적인 ES를 통해 모델을 교정할 경우, 히스토그램이 정규분포를 따르며 암상간의 경계가 명확하지 못하기 때문에 Case 3과 Case 4의 경우는 결과에서 제외하였다.

Figure 3.9a는 Case 1의 채널정보 히스토그램을 보여준다. 세 가지의 채널정보 모두 큰 불확실성을 가지며 파란색 점으로 표현되는 모델들의 평균값 또한 빨간색 실선으로 표현되는 실제 참조필드값에서 다소 벗어나 있다. Figure 3.9c는 제안된 역산기법을 통해 교정된 400개 모델들, 즉 Case 5의 채널정보 히스토그램이다. 전반적으로 불확실성의 범위는 유지하지만, 사암비율의 결과에서 Case 1에 비해 모델들의 평균값이 실제값에 가깝다.

Figure 3.9b는 Case 2의 채널정보 히스토그램이다. Case 1에 비해 불확실성도 큰 폭으로 감소하며 평균값 또한 참조필드의 값에 가까워졌다. Figure 3.9d는 Case 6의 결과로 세 가지 채널정보 모두 모델들의 평균값이 실제 값과 거의 일치하며 불확실성 또한 Case 2에 비해서도 감소한 결과를 나타냈다. 이렇게 올바르게 교정된 채널정보를 통해 채널의 연결성을 정확하게 표현할 수 있다.

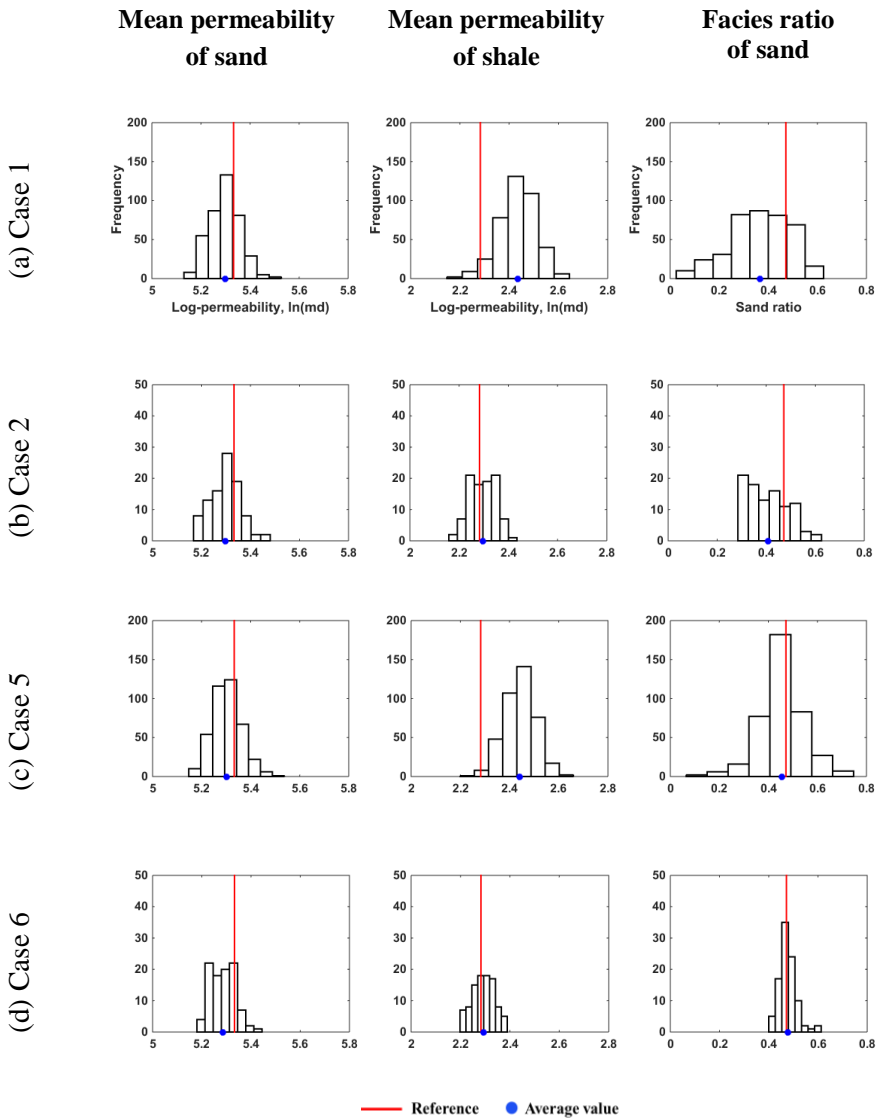


Figure 3.9 Channel information distribution for Case 1, 2, 5, and 6 (Field 1)

### 3.2 복잡한 2차원 채널저류층

본 장에서는 Field 1보다 더 복잡한 필드에서의 특성화 성능을 검증한다. Figure 3.10은 Field 2의 참조필드와 그 히스토그램을 나타낸다. 45 by 45 by 1의 격자시스템으로 구성되어 Field 1보다 찾아내야 하는 미지수가 많다. 각 격자는 x, y, z 방향으로 각각 30, 30, 20 ft의 크기를 가진다. 중앙의 주입정(I1)이 8개의 생산정(P1~P8)으로 둘러싸인 역 9점 공법(inverted 9-spot)으로 생산되며 유체투과율의 분포가 Field 1과 마찬가지로 이봉분포를 따른다.

참조필드는 P2와 P5, 그리고 P3와 I1로 연결되는 X자 모양의 뚜렷한 사암연결성을 보인다. 또한 P2와 I1 그리고 P7을 연결하는 세로 방향의 채널이 형성되어 있다. 특성화를 통해 두 가지의 채널패턴을 찾고 미래생산거동을 적절하게 예측하는 것이 중요하다. Tables 3.5~3.7은 Field 2의 자세한 시뮬레이션 조건을 나타낸다.

Field 1과 마찬가지로 100일부터 500일까지 100일 간격으로, 총 5개의 관측자료가 존재하며 교정을 위해 사용한 자료는 WOPR이다. 미래생산예측은 1,000일 까지 수행하였다.

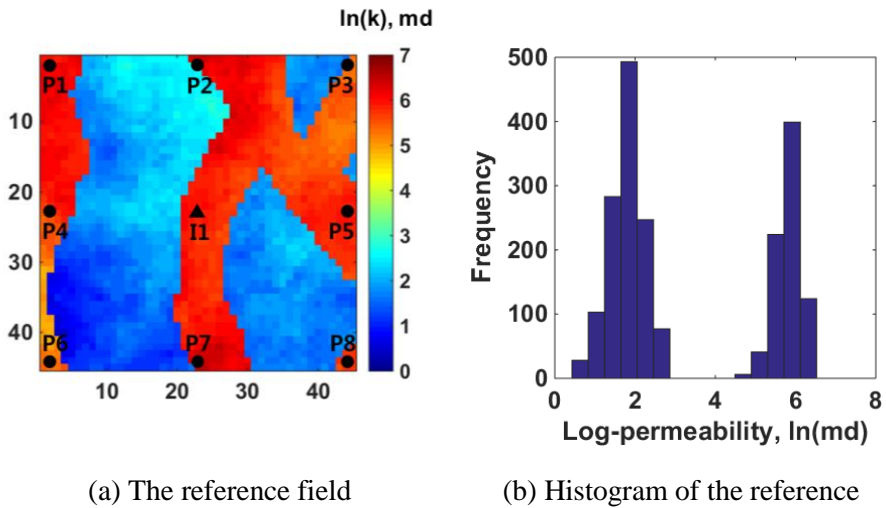


Figure 3.10 Log permeability field and histogram of the reference (Field 2)

Table 3.5 Channel information (Field 2)

Parameters	Values
Reservoir type	Channel oil reservoir
Facies	Sand and shale
Ratio of sand, fraction	0.39
Mean of $\ln(k_{sand}), \ln(\text{md})$	5.81
Mean of $\ln(k_{shale}), \ln(\text{md})$	1.80

Table 3.6 Well locations and operating conditions (Field 2)

<b>Well names</b>	<b>Locations, coordinate</b>	<b>Control mode</b>
I1	(23, 23)	Constant injection rate (300 stb/day)
P1	(2, 2)	Constant BHP (500 psi)
P2	(23, 2)	
P3	(44, 2)	
P4	(2, 23)	
P5	(44, 23)	
P6	(2, 44)	
P7	(23, 44)	
P8	(44, 44)	

Table 3.7 Petrophysical parameters for simulation (Field 2)

<b>Parameters</b>		<b>Values</b>
Top depth, ft		2,700
Oil-water contact, ft		3,000
Initial pressure, psi		2,000
Porosity, fraction		0.2
Formation volume factor, rb/stb	Water	1 at 2,000 psig
	Oil	1.012 at 0 psig 1.011 at 1,000 psig 1.01 at 2,000 psig
Density of fluid, lb/ft <sup>3</sup>	Water	48.6
	Oil	62.3
Viscosity of fluid, cp	Water	1
	Oil	3
Compressibility, 1/psi	Water	5.00E-07 at 2,000 psig
	Oil	3.00E-05 at 2,000 psig



### 3.2.1 유정별 오일생산량 및 워터컷

Field 2에 대한 각 케이스의 유정별 오일생산량 및 워터컷 결과를 각각 Figures 3.11과 3.12에 나타내었다. Field 1과 마찬가지로 회색 실선은 각 앙상블의 예측결과이며 파란색 실선은 평균값, 그리고 빨간색은 실제 참조필드의 거동을 의미한다.

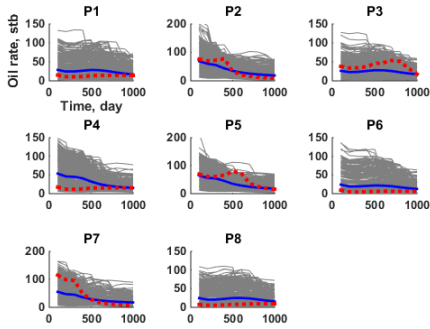
Case 1은 모든 유정에서 큰 오일생산량 밴드폭을 나타낸다(Figure 3.11a). 제한된 자료만으로 생성한 400개의 초기앙상블 만으로는 적절한 미래거동 예측이 불가능하였다. Figure 3.11b는 IGMSS를 이용해 선택된 103개 모델의 결과이다. Case 1에 비해 불확실성이 감소하였으며 P4 및 P7 유정에서 평균 예측값이 실제 관측값에 더 가까워져 향상된 결과를 보여준다. 하지만 여전히 큰 불확실성을 가지며 예측성능 또한 좋지 못하다. 이는 IGMSS 만으로도 크게 예측성능을 향상시킨 Field 1의 결과와는 상이하다. 격자의 개수가 증가하여 미지수의 수가 많아졌으며 유정의 개수도 2배로 증가하여 개별 유정의 효과가 감소한 것이 그 이유이다. 따라서 복잡한 필드의 경우 IGMSS 수행 후, 적절한 역산기법이 수행되어야 신뢰할만한 결과를 얻을 수 있다.

Figures 3.11c와 3.11d는 각각 Case 3와 Case 4의 결과를 나타낸다. Case 3의 경우 Case 1과 Case 2보다 불확실성을 소폭 감소시키지만 여전히 큰 예측 불확실성을 보인다. ES는 여러 번의 교정을 통해 불확실성을 연속적으로 줄이는 것이 아니라 단 한번의 교정만을 수행한다. 따라서 초기 불확실성이 너무 크고 앙상블의 수가 많으면

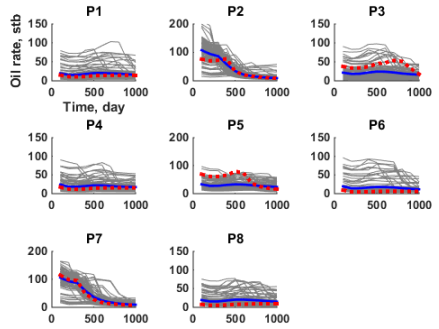
ES를 통해 예측결과의 폭을 효과적으로 줄이는 것이 힘들다. Case 4의 경우 선택된 앙상블로 ES를 수행하여 불확실성의 폭을 크게 감소시킨다. 하지만 P5 유정의 경우 500일 이후의 예측에서 평균값이 참조필드의 값에 크게 벗어난다.

Case 5는 Case 3와 유사한 결과를 제공한다(Figure 3.11e). 큰 불확실성 범위를 가지며 실제 관측값을 적절하게 예측하지 못한다. 하지만 제안방법인 Case 6은 모든 유정에서 예측 불확실성의 폭을 적절하게 줄이며 특히 500일 이후의 P5 유정의 참조필드 값을 비교적 정확히 예측한다. 이는 Case 4에 비해서도 개선된 결과이다.

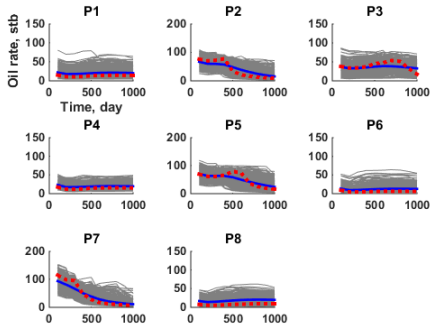
위터컷의 결과는 모든 케이스에서 오일생산량의 결과와 거의 유사하다. Case 1은 모든 유정에서 큰 불확실성을 가지며 Case 2는 IGMSS를 통해 Case 1의 불확실성을 소폭 감소시킨다. Case 3와 Case 5의 경우 역산기법을 통해 400개 모델의 예측결과의 폭을 감소시키지만 여전히 P2, P3, P5, P7 에서는 큰 불확실성 범위를 가진다. Case 4와 Case 6의 경우 모두 적절한 불확실성을 가지며 평균값이 실제 참조필드의 값과 거의 일치하여 신뢰할만한 결과를 제공한다. 다만 Case 4의 경우 오일생산량의 결과와 마찬가지로 500일 이후에 P5의 거동을 맞추지 못하는데 Case 6은 이를 개선한다.



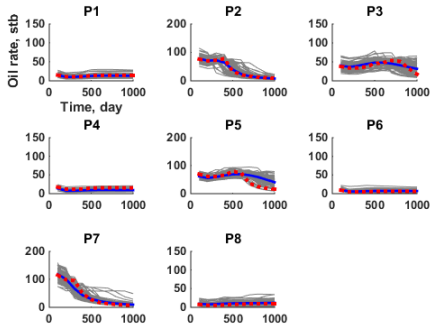
(a) Case 1



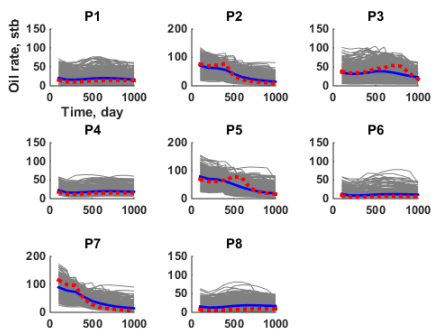
(b) Case 2



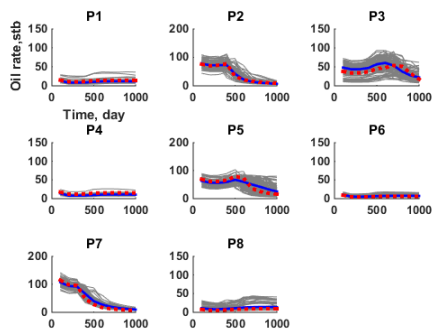
(c) Case 3



(d) Case 4




(e) Case 5

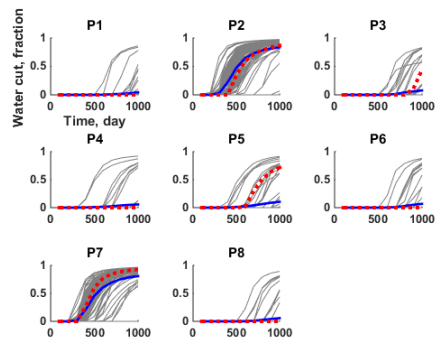


(f) Case 6

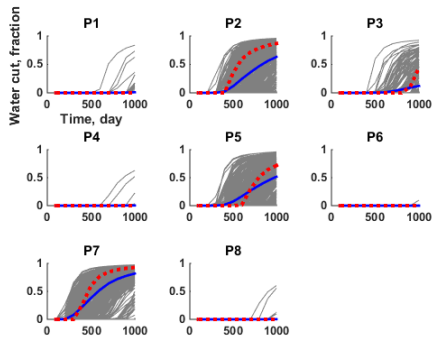
Figure 3.11 WOPR predictions of all cases (Field 2)



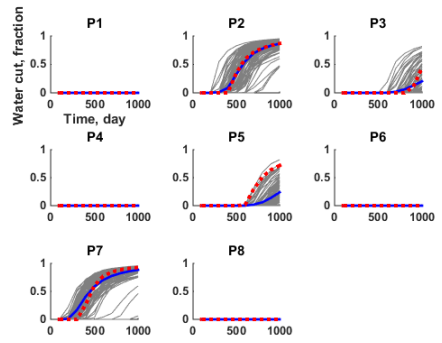
(a) Case 1



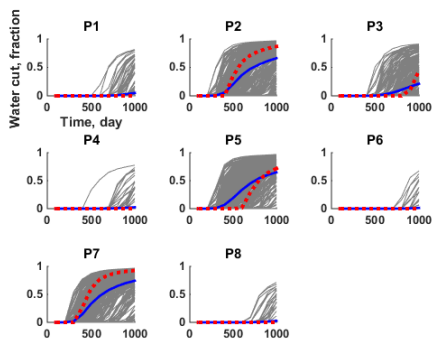
(b) Case 2



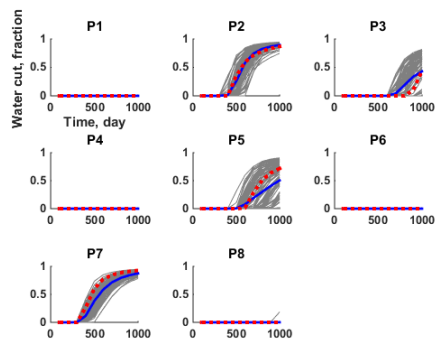
(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6


Figure 3.12 WWCT predictions of all cases (Field 2)

### 3.2.2 누적 오일 및 물 생산량


Figure 3.13은 각 케이스의 누적 오일 및 물 생산량의 미래 예측결과를 보여준다. Figure 3.13a는 Case 1, 즉 초기 400개 모델의 결과이며 오일생산량과 물생산량에서 모두 큰 불확실성의 보인다. 특히 물생산량 거동예측은 큰 밴드폭을 가진다. Case 2의 경우 103개의 모델을 선택하여 누적 오일 및 물 생산량에서 모두 불확실성을 소폭 감소시킨다.

Figures 3.13c와 3.13e는 각각 Case 3과 5의 누적 생산량 결과이다. 두 케이스 모두 400개의 앙상블을 이용하여 역산을 수행한 결과이기 때문에, 여전히 큰 불확실성을 가지며 Case 2와 비슷한 밴드폭을 나타내었다. 또한 모델들의 평균값은, Case 2에 비해 실제 참조필드의 관측값에서 더 멀어졌다.


Case 4는 Case 2의 ES 역산결과로, 앞에서 언급한 모든 케이스들에 비해 개선된 결과를 제공한다(Figure 3.13d). 오일 및 물 생산량 모두 Case 2에 비해 불확실성의 범위가 크게 감소했다. Figure 3.13f는 Case 6, 즉 제안방법의 누적 오일 및 물 생산량 결과를 도시한 것이다. 오일생산량의 경우 Case 4와 거의 비슷한 밴드폭을 가지며 물생산량의 경우, Case 4보다도 불확실성을 감소시켜 신뢰있는 미래거동예측결과를 보여준다.




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6

Figure 3.13 FOPT and FWPT predictions for all cases (Field 2)

### 3.2.3 평균 로그유체투과율

Figure 3.14는 Field 2에 대한 각 케이스의 평균 로그유체투과율 결과이다. Figure 3.10a 에서 확인할 수 있듯이, 참조필드는 오른쪽 상단에 P2, P3, I1, P5로 구성되는 X자 모양의 채널과 P2, I1, P7로 연결되는 세로방향의 사암연결성을 가진다. 또한 뚜렷한 암상경계를 가져 유체투과율의 분포가 이봉분포를 형성한다.

정적자료통합만으로 생성된 400개의 초기모델은 유정주변에서만 높은 유체투과율값을 가지며, 특별한 채널경향을 나타내지 않는다(Figure 3.14a). 채널저류층임을 확인할 수 있는 암상의 경계, 채널의 패턴, 연결성, 연속성 등을 전혀 찾아볼 수 없다. 이는 Field 2의 경우 다양한 방향의 TI를 사용하여 모델을 생성하였기 때문이다. Figure 3.14b의 경우 IGMSS를 통해 선택된 모델의 결과로서 전체적인 채널의 방향을 찾아낸다. Figure 3.2b 에서 확인할 수 있듯이 Field 2의 경우 4가지 방향의 TI(0°, 45°, 90°, 135°)를 사용하여 모델을 생성하였는데, 그 중 90°의 방향성을 가지는 모델들을 성공적으로 샘플링하였다. 이는 참조필드의 채널방향과 일치한다.

Figure 3.14c는 초기 400개의 앙상블을 사용하여 ES를 수행한 Case 3의 결과를 보여준다. Case 3의 경우 채널경계가 흐리며 올바른 채널연결성을 파악하지 못한다. 특히 참조필드에 나타나는 X자 모양의 연결성이 보이지 않는다. 초기 앙상블에 DCT 및 채널교정법을 이용하여 역산을 수행한 Case 5의 결과는 Figure

3.14e와 같다. Case 3에 비해 암상간의 경계가 뚜렷하지만 여전히 참조필드의 채널연결성을 찾아내지 못한다.

Figures 3.14d와 3.14f는 각각 Case 4와 Case 6의 결과이다. Case 4는 전반적으로 참조필드와 유사한 채널패턴을 보인다. 하지만 X자 모양의 채널연결성이 여전히 뚜렷하지 못하고 채널경계가 흐리며, 일부 구간이 비정상적으로 높게 교정되는 오버슈팅이 발생하였다. Case 6은 가장 신뢰할만한 유체투과율 특성화 결과를 제공한다. 세로방향 및 X자 모양의 채널연결성을 잘 표현하며 채널의 경계 또한 뚜렷하다. 또한 Case 4에서 발생한 오버슈팅을 개선한다.






Figure 3.14 Average log permeability fields of all cases (Field 2)

### 3.2.4 로그유체투과율 예시

Figure 3.15는 임의로 선택한 두 가지 지질모델의 로그유체투과율 분포와 히스토그램을 나타낸 것이다. Figure 3.15a는 Case 1의 역산 전 초기모델을 나타내는 것으로 두 모델 모두 대각선 방향의 사암연결성을 가지고 있어 세로방향의 연결성을 나타내는 참조필드와는 확연히 다른 채널연결성을 보인다. 이에 반해 IGMSS로 선택된 두 개의 모델은 모두 세로방향의 패턴을 잘 나타낸다(Figure 3.15b).

Case 3의 경우 로그유체투과율 분포가 Case 1에 비해 크게 개선되지 않았다(Figure 3.15c). 부분적으로 유체투과율의 높낮이가 조정되었지만 이는 전반적인 채널연결성에 영향을 주지 못했다. Figure 3.15d는 Case 4의 결과로, 전반적인 채널패턴이 참조필드와 유사하게 나타났다. 하지만 로그유체투과율의 분포가 이봉분포가 아닌 정규분포를 따르며 이로 인해 채널의 경계가 흐리고 오버슈팅 및 언더슈팅이 발생하였다.

Figure 3.15e는 Case 5의 결과로 유체투과율의 분포가 이봉분포를 따르지만 올바른 채널연결성을 찾아내지 못했다. Case 6은 두 가지 샘플에서 모두 참조필드와 유사한 채널연결성 및 패턴을 나타내었다(Figure 3.15f). 또한 이봉분포를 유지하여 채널의 경계가 명확하고 뚜렷한 연결성을 보였다. 또한 Case 3과 Case 4에서 발생한 오버슈팅을 완화하여 가장 개선된 결과를 제공한다.

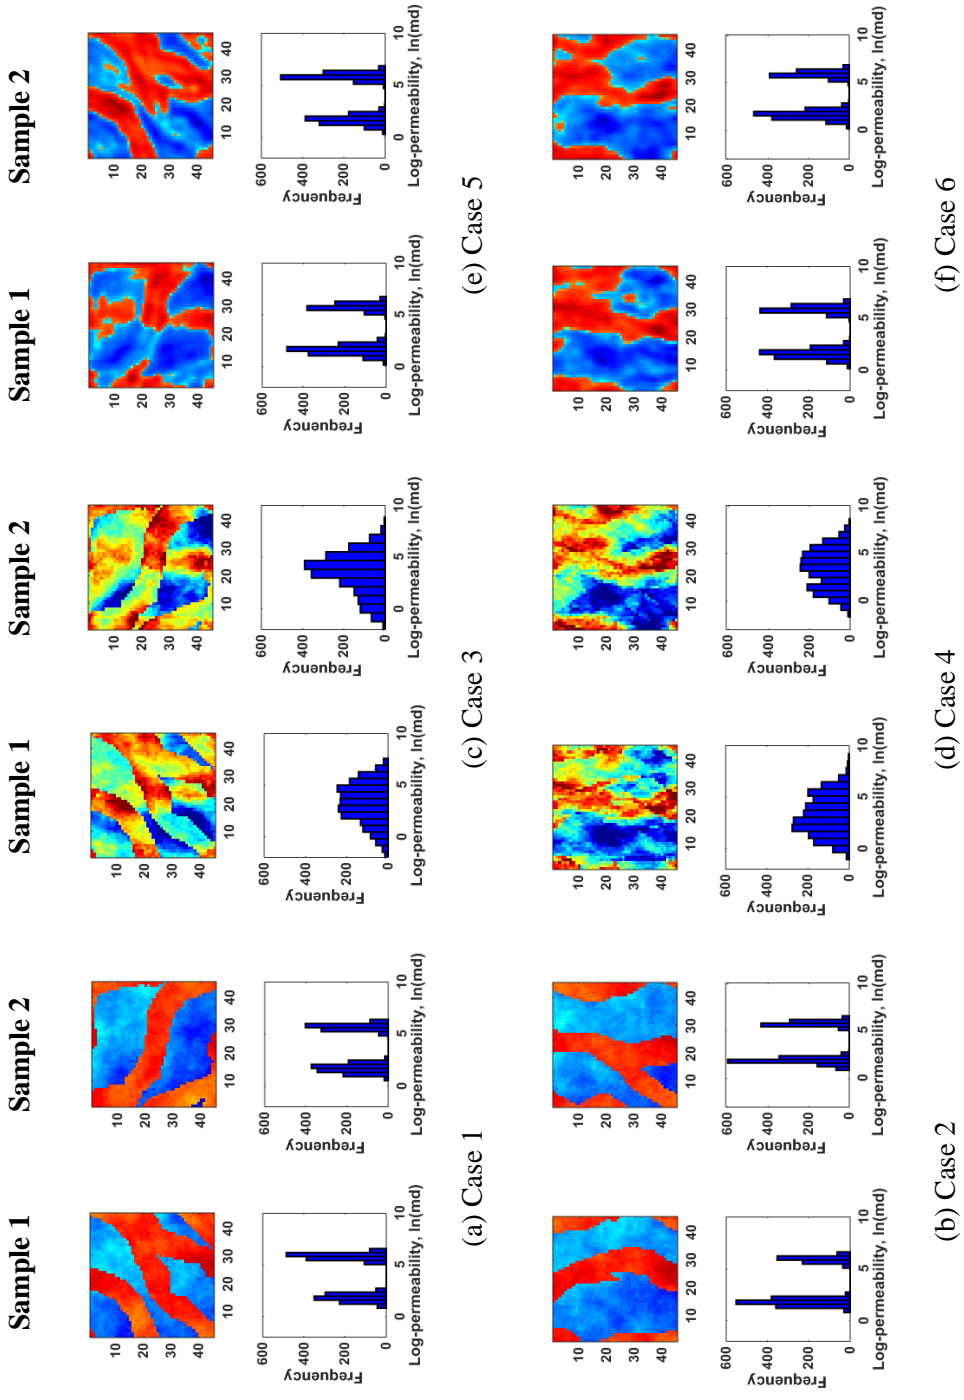


Figure 3.15 Log permeability fields and their histograms of two ensemble members of each case (Field 2)

### 3.2.5 채널정보 히스토그램

Figure 3.16은 Field 2에 대하여 모델들의 세 가지 채널정보 히스토그램을 케이스 별로 나타낸 것이다. Field 1과 마찬가지로 Case 3과 4의 경우 ES의 영향으로 유체투과율의 분포가 정규분포를 따르게 되고 이로 인해 암상간의 구분이 어려워 결과에서 제외하였다.

Figure 3.16a는 Case 1의 채널정보 히스토그램을 나타낸다. 세 가지 인자 모두 큰 불확실성을 가지며 특히 세일의 로그유체투과율 평균값과 사암의 암상비율은 평균값이 실제값에서 크게 벗어나 있다. Case 5 또한 불확실성을 크게 감소시키지 못하였다(Figure 3.16c). 또한 사암의 로그유체투과율 평균값은 오히려 Case 1에 비해 실제값에서 더 멀어졌다.

Figure 3.16b는 IGMSS로 선별된 103개 모델, 즉 Case 2의 채널정보 히스토그램을 도시한 것으로 Case 1에 비해 불확실성을 소폭 감소시켰다. 하지만 여전히 큰 불확실성을 가지며 평균값이 실제값에서 많이 벗어나 있다. Case 6은 앞의 세 가지 케이스에 비해 크게 개선된 결과를 보여준다. 모든 채널정보 히스토그램에서 현저하게 감소된 불확실성 폭을 보여주며 모델들의 평균값이 실제 채널정보와 거의 일치하였다.

따라서 초기의 큰 지질학적 불확실성으로 인해 초기모델들이 잘못된 채널정보를 가지고 있더라도 IGMSS와 제안된 역산기법을 통해 불확실성을 감소시키고 이들을 실제값에 가깝도록 올바르게 교정할 수 있다.

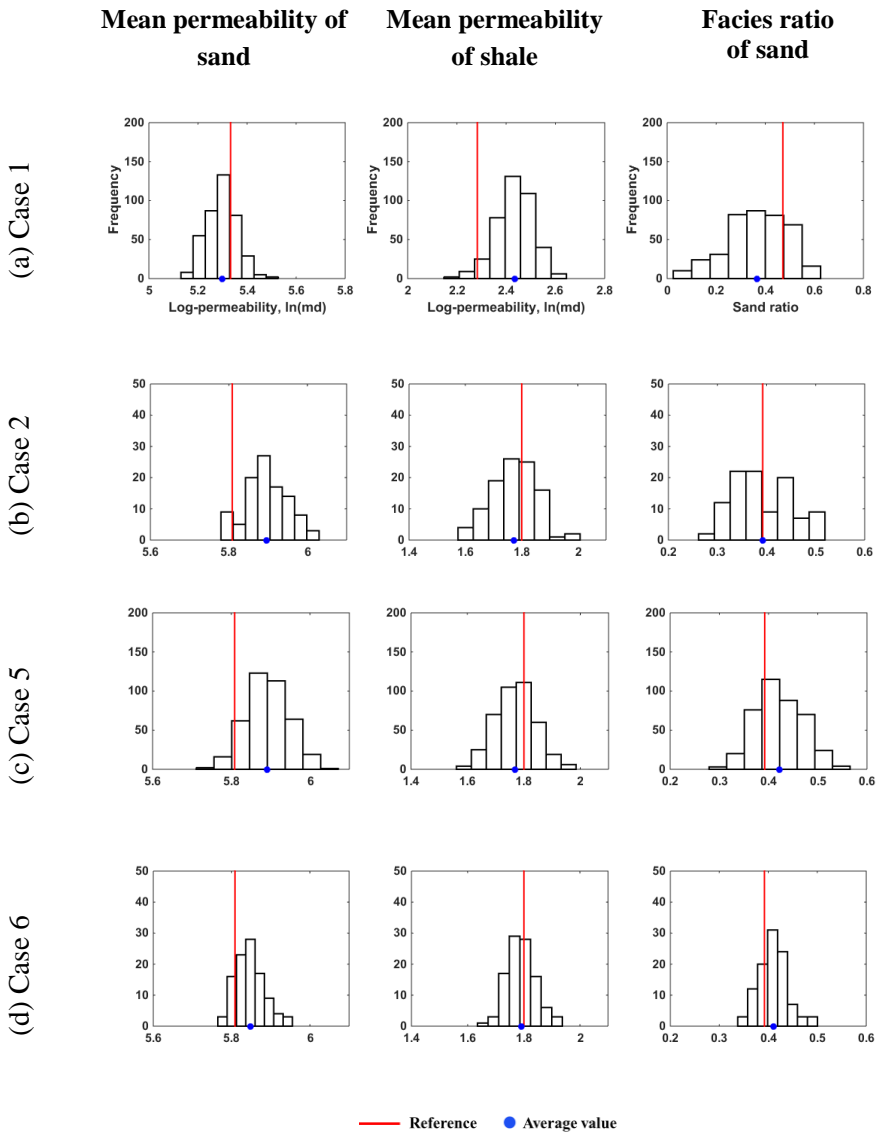




Figure 3.16 Channel information distribution for Case 1, 2, 5, and 6 (Field 2)

### 3.3 3차원 채널저류층

본 장에서는 대표적인 채널저류층 벤치마크 모델인 Egg 모델을 기반으로 생성한 3차원 필드에 관한 검증을 수행한다. Field 3의 참조필드는 Figure 3.17과 같다. 60 by 60 by 3의 격자로 구성되며, 각 격자는 x, y, z 방향으로 각각 8, 8, 4 m의 크기를 가진다. 또한 4개의 생산정과 8개의 주입정이 존재하여 수공법으로 오일이 생산되는 필드이다. 세 개의 층이 비슷한 채널패턴을 가지며 천공은 전 층에 수행되었다.



(a) The reference field



(b) Histogram of the reference

Figure 3.17 Log permeability field and histogram of the reference (Field 3)

100일부터 500일까지 100일 간격으로 5번의 관측시점이 존재하며 역산을 위해 생산정의 WOPR 및 주입정의 유정공저압력(well bottom-hole pressure, WBHP)를 사용하였다. 이 후, 오일생산량 및 워터컷의 미래생산거동 예측은 1,000일까지 수행하였다. Tables 3.8~3.10은 Field 3에 대한 보다 자세한 시뮬레이션 조건을 보여준다.

Table 3.8 Channel information (Field 3)

<b>Parameters</b>	<b>Values</b>
Reservoir type	Channel oil reservoir
Facies	Sand and shale
Ratio of sand, fraction	0.31
Mean of $\ln(k_{sand}), \ln(md)$	5.93
Mean of $\ln(k_{shale}), \ln(md)$	1.70

Table 3.9 Well locations and operating conditions (Field 3)

<b>Well names</b>	<b>Locations, coordinate</b>	<b>Control mode</b>
I1	(5, 57)	Constant injection rate (100 sm <sup>3</sup> /day)
I2	(30, 53)	
I3	(2, 35)	
I4	(27, 29)	
I5	(50,35)	
I6	(8, 9)	
I7	(32, 2)	
I8	(57, 6)	
P1	(16, 43)	Constant BHP (395 bar)
P2	(35, 40)	
P3	(23, 16)	
P4	(43, 18)	



Table 3.10 Petrophysical parameters for simulation (Field 3)


<b>Parameters</b>		<b>Values</b>
Top depth, m		3,600
Oil-water contact, m		5,000
Initial pressure, bar		400 at 4,000 m
Porosity, fraction		0.2
Formation volume factor, m <sup>3</sup> /m <sup>3</sup>	Water	1 at 400 bar
	Oil	1 at 400 bar
Density of fluid, kg/m <sup>3</sup>	Water	900
	Oil	1,000
Viscosity of fluid, cp	Water	1
	Oil	5
Compressibility, 1/bar	Water	1.00E-05 at 400 bar
	Oil	1.00E-05 at 400 bar

### 3.3.1 유정별 오일생산량 및 워터컷


Field 3의 경우, Field 1과 Field 2에 비해 전반적으로 오일생산량 및 워터컷에서 큰 불확실성을 가지지는 않는다. 이는 400개의 서로 다른 지질모델들의 주입정이 모두 세일에 위치하기 때문이다. 즉, 물이 사암이 아닌 세일에 주입되어 선택적으로 흐르지 않으며 배수구역이 필드 전체에 고르게 분포된다.

Case 1은 전 유정에서 다소 큰 불확실성을 가지며(Figures 3.18a and 3.19a) Case 2의 경우 400개 중 72개의 모델을 선택하여 불확실성을 감소시킨다(Figures 3.18b and 3.19b). Case 3의 경우도 Case 1에 비해 불확실성을 소폭 감소시키며 Case 2와 비슷한 불확실성의 폭을 가진다(Figures 3.18c and 3.19c). 하지만 Case 5의 경우 Case 1보다 미래거동예측 불확실성이 오히려 증가한다. 이는 제안된 역산기법이 ES로 교정을 수행한 후, CDF 맵핑을 통해 일부 유체투과율 분포를 변형시키기 때문이다(Figures 3.18e and 3.19e).


신뢰성 있는 미래거동예측을 위해서는 불확실성은 적절한 범위를 유지하면서 참조필드의 값을 밴드 내에 포함해야 한다. Case 4는 전 유정에서 매우 작은 불확실성 범위를 나타낸다(Figures 3.18d and 3.19d). Figures 3.18f와 3.19f는 본 연구의 제안방법인 Case 6의 오일생산량 및 워터컷 예측결과이다. 그림에서 확인할 수 있듯이 전 유정에서 적절한 불확실성을 유지하면서 참조필드의 값이 평균값과 거의 일치한다. 따라서 제안방법을 통해 신뢰성 있는 오일생산량 및 워터컷 예측이 가능하다.




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4




(e) Case 5




(f) Case 6


Figure 3.18 WOPR predictions of all cases (Field 3)




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6

Figure 3.19 WWCT predictions of all cases (Field 3)



### 3.3.2 주입공저압력

주입정의 경우, Table 3.3에서 제시된 바와 같이,  $100 \text{ sm}^3/\text{day}$ 의 주입유량을 유지하도록 제어된다. 또한 Field 3에서는 주입정의 WBHP가 히스토리매칭에 사용되기 때문에 이를 파악하는 것은 매우 중요하다. 본 장에서는 비교적 불확실성이 큰 I1, I3, I4, 그리고 I7 유정에 대한 미래거동예측결과를 제시한다.

Figure 3.20a는 Case 1의 주입공저압력 예측결과를 보여준다. 4개의 유정에서 모두 큰 불확실성을 가지며 실제 관측값 또한 예측값의 평균에서 크게 벗어나 있다. Case 2의 경우 Case 1에 비해 불확실성이 소폭 감소한다. 하지만 여전히 평균값은 참조필드의 값과 차이가 난다(Figure 3.20b).



Figure 3.20c에서 확인할 수 있듯이 Case 3의 경우 Case 1에 비해 불확실성을 감소시키며 모델들의 평균값 또한 실제 관측값에 가깝도록 교정한다. Case 5는 Case 3 보다도 개선된 결과를 보여준다. 특히 I1과 I3에서 불확실성을 크게 감소시킨다(Figure 3.20e).

Figures 3.20d와 3.20f는 각각 Case 4와 Case 6의 미래 주입공저압력 예측결과를 도시한 그래프이다. 두 방법 모두, 4개의 유정에서 모두 적절하게 작은 불확실성을 유지하며 평균값이 참조필드의 관측값과 거의 일치하여 신뢰할만한 예측성능을 보인다.





(a) Case 1

(b) Case 2



(c) Case 3

(d) Case 4




(e) Case 5

(f) Case 6


Figure 3.20 WBHP predictions of all cases (Field 3)

### 3.3.3 누적 오일 및 물 생산량


Figure 3.21은 각 케이스의 누적 오일 및 물 생산량 예측결과를 나타낸다. 모든 케이스에서 작은 밴드폭을 보이며 참조필드의 값을 밴드내에 포함한다. 이는 앞서 언급했던 바와 같이 8개의 주입정이 모두 세일에 위치하며 필드의 전영역에 걸쳐 고르게 분포하기 때문이다. 즉 주입된 물이 사암체를 따라 특정한 방향성을 가지고 확산되는 것이 아니라, 넓은 배수구역을 가지고 오일을 밀어내며 생산되기 때문에 오일 및 물생산량에서 큰 차이가 나지 않는다.




(a) Case 1




(b) Case 2




(c) Case 3



(d) Case 4



(e) Case 5



(f) Case 6

Figure 3.21 FOPT and FWPT predictions for all cases (Field 3)



### 3.3.4 평균 로그유체투과율

Figure 3.22는 Field 3에 대한 각 케이스의 평균 로그유체투과율 결과를 층별로 나타낸 것이다. Case 1의 경우 어떠한 채널경향도 나타내지 않는다(Figure 3.22a). 다만, 정적자료통합으로 초기모델을 생성할 때 주입정은 세일에, 생산정은 사암에 있다는 가정을 하였으므로 주입정 주변의 유체투과율은 낮고 생산정 주변의 유체투과율은 비교적 높게 형성되어 있다. Case 2도 Case 1과 마찬가지로 주입정 주변은 낮은 유체투과율값을, 생산정 주변은 반대로 높은 유체투과율값을 가진다. 하지만 Case 1에 비해 세로 방향의 채널경향이 보이는 것을 확인하였다(Figure 3.22b).

Figure 3.22c는 Case 3의 평균 로그유체투과율 결과를 보여준다. Case 3의 경우 생산정간의 사암연결성은 비슷하게 표현하였지만, 채널경계가 명확하지 못하다. 또한 P3와 P4 사이의 세일인 부분을 사암으로 표현하였고 필드의 오른쪽 부분이 대부분 사암으로 표현되어 일부 암상을 잘못 예측하였다. Case 4는 Case 3에 비해 참조필드와 유사한 채널연결성을 보여준다(Figure 3.22d). 하지만 그 경계가 뚜렷하지 못하고 역시 P1과 P2 사이의 세일을 사암으로 잘못 교정한 한계가 있다.

Case 5의 경우 암상경계는 Case 3보다 뚜렷하지만 참조필드와 비슷한 사암연결성을 찾기는 힘들다(Figure 3.22e). Figure 3.22f는 Case 6의 로그유체투과율 특성화 결과를 제시한다. 제안방법은 1~3번 층에서 모두 명확한 경계를 가지며 이에 따라 암상간의 구분이

용이하다. 또한 채널연결성이 참조필드와 거의 유사하여 성공적인 특성화가 수행되었다고 볼 수 있다. 이렇게 채널의 연결성을 올바르게 파악하며, 사암 및 셰일의 위치를 정확히 파악하는 것은 향후 유전개발계획 수립에 매우 중요하다.




Figure 3.22 Average log permeability fields of all cases (Field 3)

### 3.3.5 로그유체투과율 예시

Figure 3.23는 각 케이스별 두 개 모델의 유체투과율 분포이다. Field 3의 경우 각 층별 특성화 결과가 유사하므로 3번 층의 결과만 나타내었다. 단 히스토그램의 경우 참조필드(Figure 3.17b)와의 비교를 위해 전 층의 유체투과율에 해당하는 히스토그램을 도시하였다.

Figure 3.23a는 역산을 통해 교정되기 전, 정적자료통합으로 생성된 두 개의 필드를 보여준다. 참조필드는 y축으로부터  $0^\circ$  기울어진 TI를 사용하여 생성된 모델로 수직방향의 채널연결성을 가진다(Figure 3.17a). Case 1의 Sample 1은 y축으로부터  $-30^\circ$  기울어진 TI를, Sample 2는  $30^\circ$  기울어진 TI를 사용하여 생성된 모델이다. 따라서 이들은 참조필드와는 전혀 다른 채널패턴을 보여준다. 이에 반해 Case 2의 경우 Sample 1과 Sample 2 모두 참조필드와 같은 방향의 채널연결성을 가진다(Figure 3.23b).

Case 3의 결과는 Figure 3.23c와 같다. 우선 로그유체투과율의 분포가 정규분포에 가깝다. 따라서 채널의 구분이 명확하지 못하며 뚜렷한 연결성을 가지지 못한다. 또한 초기필드의 채널모양을 크게 변화시키지 못했다. Figure 3.24d은 Case 4의 결과이다. 이들은 참조필드와 전반적으로 유사한 채널패턴을 나타내지만 유체투과율이 정규분포를 따르기 때문에 암상간의 경계가 뚜렷하지 못하다.

Case 5는 유체투과율의 분포가 이봉분포를 따른다(Figure 3.23e).

따라서 명확한 암상경계를 보이지만, 채널연결성은 참조필드와 완전히 다른 한계를 나타낸다. 이는 Case 5가 Case 3의 결과를 CDF 맵핑을 통해 후처리하기 때문인 것으로, Case 3의 결과가 극단적으로 좋지 못하다면 Case 5의 결과 또한 크게 개선될 수 없다. Case 6은 가장 좋은 특성화 결과를 제공한다(Figure 3.23e). 참조필드와 같은 사암연결성을 찾아내고 유체투과율의 분포가 이봉분포를 따라 암상경계 또한 명확하다.

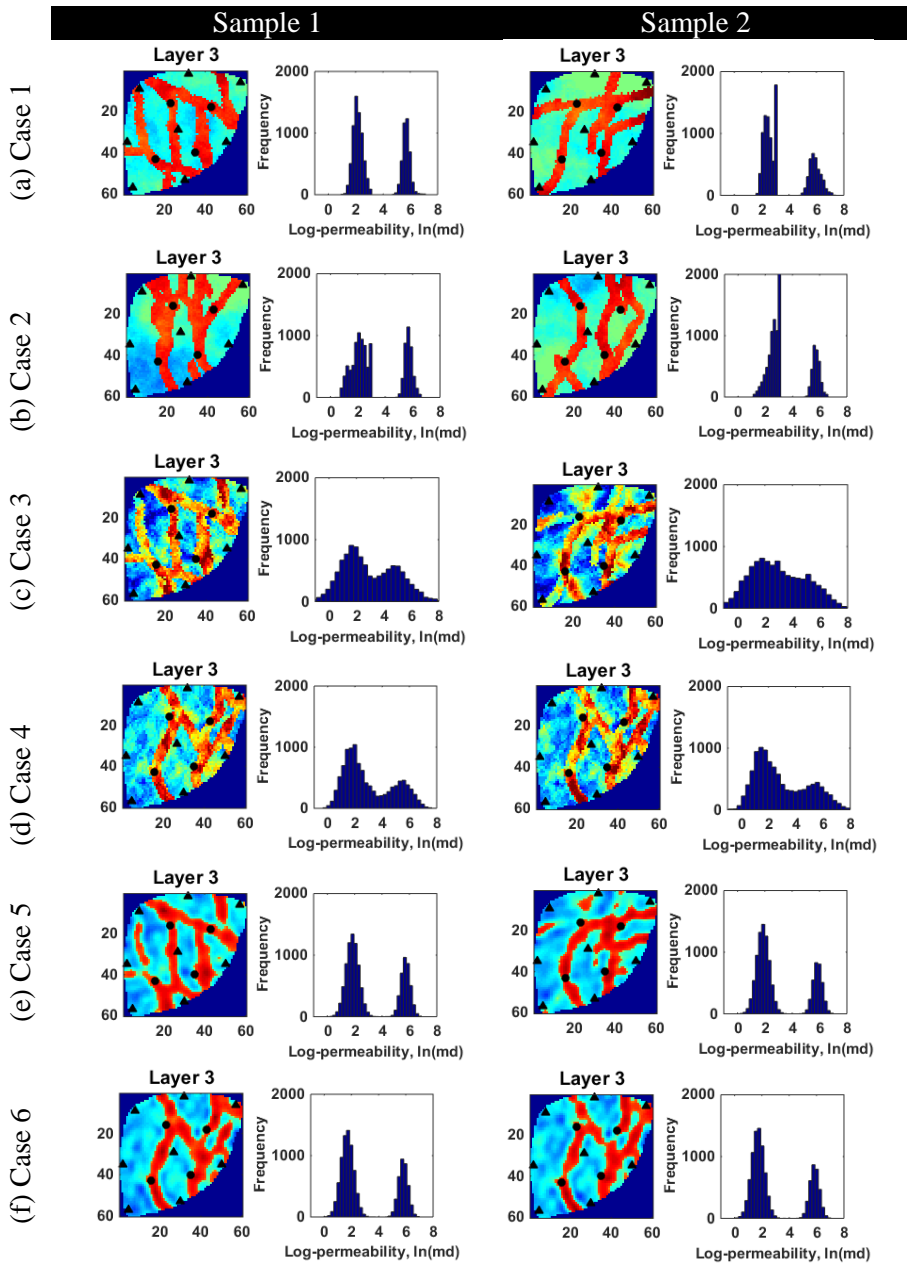


Figure 3.23 Log permeability fields and their histograms of two ensemble members of each case (Field 3)

### 3.3.6 채널정보 히스토그램

Field 3에 대한 세 가지 채널정보의 히스토그램은 Figure 3.24와 같다. Case 1의 경우 큰 불확실성을 보이며, 평균값이 실제값에서 크게 벗어나있다(Figure 3.24a). Figure 3.24b는 선택된 72개 모델의 채널정보 히스토그램으로 불확실성을 소폭 감소시키며 평균값 또한 실제 참조필드의 채널정보와 비슷하게 교정한다.

Case 5는 초기 400개의 모델을 제안된 역산기법을 통해 교정한 결과이다(Figure 3.24c). Case 1에 비해 세일의 평균 로그유체투과율 결과를 크게 개선했으며 사암의 평균 로그유체투과율 및 암상 비율의 불확실성을 감소시켰다.

Figure 3.24d는 Case 6, 즉 IGMSS로 선택된 72개의 모델을 제안된 역산기법을 통해 교정한 결과이다. 모든 채널정보의 불확실성이 크게 감소하며 모델들의 채널정보가 참조필드의 값과 거의 일치하도록 교정되었다. 따라서 IGMSS 및 제안된 역산기법을 통해 초기모델의 채널정보 불확실성을 감소시키며 그 값들 또한 실제값에 가깝게 교정함으로써 CDF 맵핑 수행 시, 올바른 채널연결성을 확보할 수 있다.

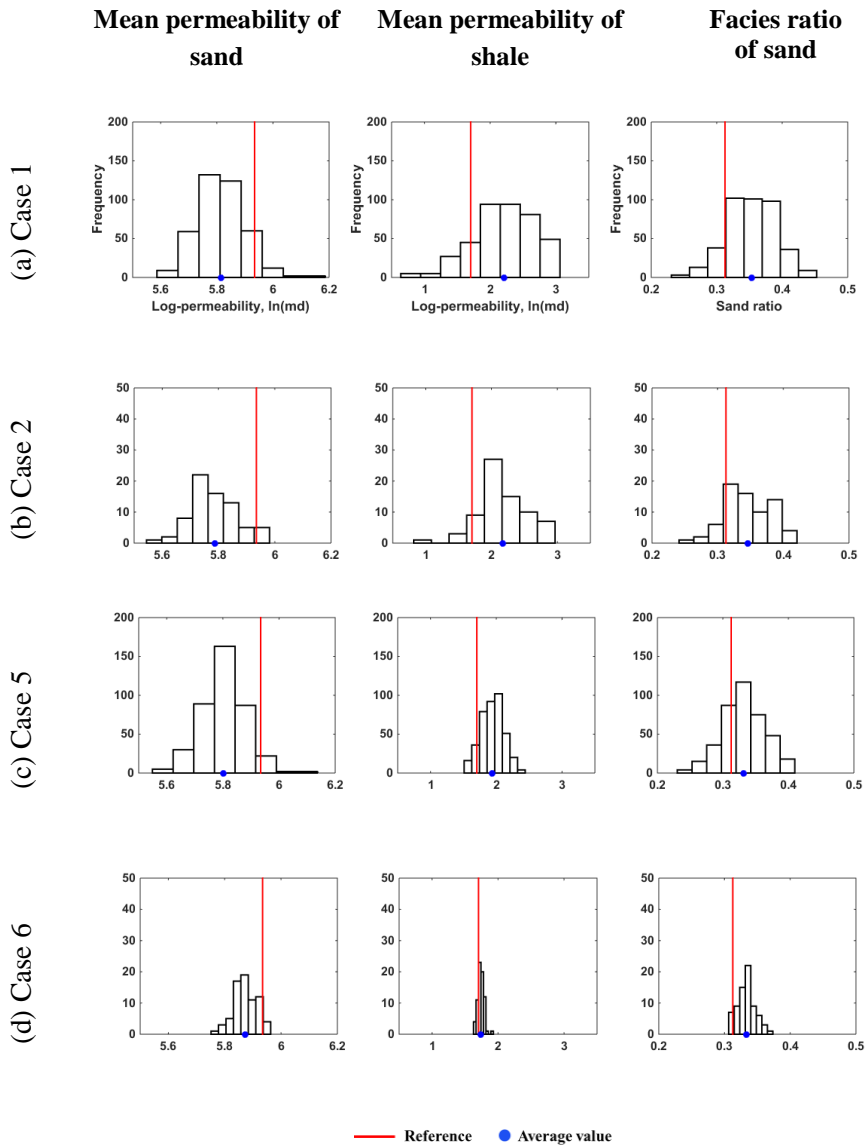


Figure 3.24 Channel information distribution for Case 1, 2, 5, and 6 (Field 3)



## 4. 결론

본 연구에서는 IGMSS, DCT, 채널정보교정법을 저류층 특성화의 최적화 기법인 ES에 결합하는 새로운 방법을 제안하였다. 제안기법을 간단한 2차원 저류층, 복잡한 2차원 저류층, 3차원 저류층에 적용하여 특성화 성능을 검증하였고 아래와 같은 결론을 도출하였다.

1. 본 연구에서는 참조필드와 비슷한 채널패턴 및 연결성을 가지는 초기모델들을 선별하는 IGMSS를 제안한다. IGMSS에서는 PCA와 MDS를 이용하여 모델의 차원을 축소하고 2차원 평면에 나타낸다. 이 후 일부 선별된 모델들을 SVM을 이용하여 학습시키고 나머지 모델들을 분류, 선택하였다.
2. PCA와 MDS는 모델간의 지질학적 비유사성을 보존하면서 차원을 축소하기 때문에 2차원 평면에서 가깝게 존재하는 모델들은 채널의 연결성, 연속성, 패턴이 유사하다. 이러한 2차원 평면에서 오일생산량을 기준으로 학습모델들을 선별하고 나머지 모델을 분류하는 SVM을 시행하면 지질학적인 특징과 생산거동을 동시에 고려하여 모델을 샘플링할 수 있다.
3. 좋은 초기모델을 선택하여 역산을 수행하더라도 일반적인

ES를 통해서도 채널저류층의 특징을 보존하기 어렵다. 본 연구에서는 DCT와 채널정보교정법을 ES에 결합하는 새로운 역산기법을 제안한다. DCT를 통해 전반적인 채널경향을 파악하고 잡음을 제거하며 계산효율을 증진시킨다. 또한 채널정보교정법을 이용하여 암상비율 및 각 암상의 평균 유체투과율을 교정하고 이봉분포를 유지한다. 이를 통해 암상경계를 명확히 하고 채널의 연속성 및 연결성을 표현하며 오버슈팅을 예방한다.

4. 초기 400개의 모델, IGMSS로 선택된 모델을 각각 Case 1과 Case 2로 정의하고 이들을 ES와 제안된 역산기법을 통해 특성화하였다. Case 1과 Case 2를 ES로 히스토리매칭한 결과를 각각 Case 3과 Case 4로 정의하고 제안된 역산기법으로 히스토리매칭한 결과를 각각 Case 5와 Case 6으로 정의하였다. 본 연구에서 제안하는 최종기법은 Case 6이며, 각 케이스를 간단한 2차원 채널저류층(Field 1), 복잡한 2차원 채널저류층(Field 2), 3차원 채널저류층(Field3) 에서 비교하였다.
5. Field 1의 경우 미지수의 개수가 적고 채널패턴이 단순하며 하나의 TI만을 사용하여 초기 400개의 앙상블을 그대로 사용하여 역산을 수행하여도 채널경향을 찾아낼 수 있었다. 하지만 Field 2, Field 3와 같이 미지수가 많고 다양한 TI를 사용하여 초기모델을 생성하면 참조필드와 다른 경향을

가지는 다수의 지질모델이 존재하게된다. 이들을 바탕으로 역산을 수행할 경우 목적함수를 크게 변화시키지 못한다. 따라서 Case 3와 Case 5는 Field 2와 Field 3에서 적절한 채널패턴을 찾는데 실패하였다. 또한 미래거동예측의 불확실성이 커서 적절한 의사결정의 도구로 활용되기 어렵다.

6. IGMSS는 본 연구에서 검증을 수행한 모든 필드에서 결과를 개선시켰다. 미래생산거동 예측의 불확실성을 감소시키고 모델들의 평균값을 참조필드의 관측값에 가깝도록 모델들을 선별한다. 채널의 연결성, 패턴, 방향 또한 초기 400개의 모델들에 비해 참조필드와 비슷한 경향을 가지도록 개선하고 주요 채널정보 또한 그 불확실성을 감소시켰다.
7. IGMSS를 통해 선택된 모델을 사용하여 ES를 수행한 Case 4의 경우 성공적으로 미래거동을 예측하였으며 전반적인 채널경향을 파악할 수 있다. 하지만 유체투과율의 분포가 이봉분포를 유지하지 못해 암상간의 경계가 흐리고 정확한 채널패턴을 파악하기 어려웠다.
8. 본 연구의 제안기법인 Case 6은 모든 필드에서 신뢰성 있는 결과를 제공하였다. 채널의 연결성, 연속성, 패턴 등의 특징을 올바르게 찾아내었으며 유체투과율의 이봉분포를 유지하여 두 암상을 명확하게 구분하였다. 또한 오일생산량, 워터컷,

누적 오일생산량, 누적 물생산량, 주입정의 공저압력 등 미래거동을 적절한 불확실성으로 예측하였다. 또한 모든 경우에서 모델들의 예측값의 밴드에 참조필드의 관측값이 포함되어, 신뢰있는 미래거동예측이 가능하다.

본 연구로부터 더 발전할 향후 연구는 보다 효율적으로 초기 지질모델을 선택하는 기법에 대한 것이다. 제안된 초기 지질모델 선택기법은 그 신뢰성이 증명됐지만 더 효율적인 기법이 제시된다면 특성화에 소모되는 시간과 비용을 아끼고 제안방법의 적용범위를 넓힐 수 있을 것이다. 제안할 수 있는 연구들은 다음과 같다.

IGMSS는 초기모델들의 거동을 알아야 적용 가능하므로 만약 더 큰 규모의 저류층모델이 타겟이라면 소요되는 시뮬레이션 시간이 크다. 따라서 학습모델 선별 시 거리기반 군집화기법을 사용하면 시뮬레이션 시간을 단축시킬 수 있을 것이다. 또한 IGMSS 수행 시, 선택된 모델들의 평균 유체투과율 필드를 모델 재성성을 위한 확률지도로 활용할 수 있다. 이 경우 존재하는 모델 중에 일부를 선택하는 것이 아니라 새로운 모델을 생성하기 때문에 더 다양한 초기모델을 확보할 수 있다.

## 참고문헌

- 김성일. 2017. 앙상블칼만필터를 이용한 대수층 동반 채널가스저류층 특성화 및 불확실성 평가. 공학박사 학위논문, 서울대학교, 서울, p. 25-31.
- 오일석. 2008. *패턴인식*. 서울: 교보문고, p. 57-85.
- 이경복. 2014. 거리기반 앙상블스무더를 이용한 채널저류층 특성화. 공학박사 학위논문, 서울대학교, 서울, p. 6-10.
- 정승필. 2008. 앙상블칼만필터를 이용한 균열저류층 특성화, 공학박사 학위논문, 서울대학교, 서울, p. 22-28.
- 조흥근. 2016. 앙상블칼만필터와 채널정보교정을 이용한 채널저류층 특성화, 공학석사 학위논문, 서울대학교, 서울, p. 1-10.
- 최종근. 2013. *지구통계학*. 서울: 시그마프레스, p. 7-8.
- Al-Anazi, A. and Gates, I.D. 2010. A support vector machine algorithm to classify lithofacies and model permeability in heterogeneous reservoirs. *Engineering Geology* 114 (3-4): 267-277.
- Agbalaka, C.C. and Oliver, D.S. 2011. Joint updating of petrophysical properties and discrete facies variables from assimilating production data

using the EnKF. *SPE Journal* 16(2): 318–330.

Astrakova, A. and Oliver, D.S. 2015. Conditioning truncated pluri-Gaussian models to facies observations ensemble-Kalman-based data assimilation. *Mathematical Geosciences* 47(3): 345-367.

Astrakova, A., Oliver, D.S., and Lantuéjoul, C. 2015. Truncation Map Estimation Based on Bivariate Probabilities and Validation for the Truncated Plurigaussian Model. ArXiv e-prints.

Evensen, G. 1994. Sequential data assimilation with a nonlinear quasi-geostrophic model using Monte Carlo methods to forecast error statistics. *Journal of Geophysical Research* 99(C5): 10143–10162.

Gholami, R., Shahraki, A.R., and Jamali-Paghaleh, M. 2012. Prediction of hydrocarbon reservoirs permeability using support vector machine. *Mathematical Problems in Engineering* 2012: 670723.

Gu, Y. and Oliver, D.S. 2004. History Matching of the PUNQ-S3 Reservoir Model using the Ensemble Kalman Filter. Paper SPE 89942 presented at the SPE Annual Technical Conference and Exhibition, Houston, Texas, 26-29 September.

Gu, Y. and Oliver, D.S. 2006. The ensemble Kalman filter for continuous updating of reservoir simulation models. In *Transactions of the ASME*, Vol. 128, Issue 1, 79-87. New York City: American Society of Mechanical Engineers.

Jafarpour, B. and McLaughlin, D.B. 2007. Efficient permeability

parameterization with the discrete cosine transform. Paper SPE 106453 presented at the SPE Reservoir Simulation Symposium, Houston, Texas, USA, 26-28 February.

Jafarpour, B. and McLaughlin, D.B. 2008. History matching with an ensemble Kalman filter and discrete cosine parameterization. *Computational Geosciences* 12(2): 227-244.

Jafarpour, B. and McLaughlin, D.B. 2009. Reservoir characterization with the discrete cosine transform. *SPE Journal* 12(2): 227-244.

Jafarpour, B. 2011. Wavelet Reconstruction of Geologic Facies From Nonlinear Dynamic Flow Measurements. *IEEE Transaction on Geoscience and Remote Sensing* 49(5): 1520-1535.

Jo, H., Jung, H., Ahn, J., Lee, K., Choe, J. 2017. History matching of channel reservoirs using ensemble Kalman filter with continuous update of channel information. *Energy Exploration and Exploitation* 35 (1): 3–23.

Jung, S. and Choe, J. 2012. Reservoir characterization using a streamline-assisted Ensemble Kalman filter with covariance localization. *Energy Exploration and Exploitation* 30(4): 645–660.

Jung, H., Jo, H., Kim, S., Lee, K., and Choe, J. 2017a. Recursive update of channel information for reliable history matching of channel reservoirs using EnKF with DCT. *Journal of Petroleum Science and Engineering* 154, 19–37.

Jung, H., Jo, H., Lee, K., and Choe, J. 2017b. Characterization of various

channel fields using an initial ensemble selection scheme and covariance localization. *Journal of Energy Resources Technology* 139(6): 062906.

Jung, H., Jo, H., Lee, K., and Choe, J. 2018. Geological model sampling using PCA-assisted support vector machine for reliable channel reservoir characterization. *Journal of Petroleum Science and Engineering* 167: 396-405.

Kang, B., Yang, H., Lee, K., and Choe, J. 2017. Ensemble Kalman filter with principal component analysis assisted sampling for channelized reservoir characterization. *Journal of Energy Resources Technology* 139(3): 032907.

Kang, B. and Choe, J., 2017a. Initial model selection for efficient history matching of channel reservoirs using Ensemble Smoother. *Journal of Petroleum Science and Engineering* 152: 294-308.

Kang, B. and Choe, J., 2017b. Regeneration of Initial Ensembles With Facies Analysis for Efficient History Matching. *Journal of Energy Resources Technology* 139 (4): 042903.

Kim, S., Lee, C., Lee, K., and Choe, J. 2016a. Characterization of channelized gas reservoirs using ensemble Kalman filter with application of discrete cosine transformation. *Energy Exploration and Exploitation* 34(2): 319–336.

Kim, S., Lee, C., Lee, K., and Choe, J. 2016b. Characterization of channel oil reservoirs with an aquifer using EnKF, DCT, and PFR. *Energy Exploration and Exploitation* 34 (6), 828–843.



- Kim, S., Jung, H., Lee, K., and Choe, J. 2017. Initial ensemble design scheme for effective characterization of three-dimensional channel gas reservoirs with an aquifer. *Journal of Energy Resources Technology* 139 (2): 022911.
- Lee, K., Jeong, H., Jung, S., and Choe, J. 2013a. Characterization of channelized reservoir using Ensemble Kalman filter with clustered covariance. *Energy Exploration and Exploitation* 31(1): 17–29.
- Lee, K., Jeong, H., Jung, S., and Choe, J. 2013b. Improvement of ensemble smoother with clustering covariance for channelized reservoirs. *Energy Exploration and Exploitation* 31(5): 713–726.
- Lee, K., Kim, S., Jung, S., Shin, H., and Choe, J. 2014. Channelized Reservoirs characterization using ensemble smoother with selective measurement data. This Paper presented at 76<sup>th</sup> EAGE Conference & Exhibition, Amsterdam, Netherlands, 16–19 June.
- Lee, K., Jung, S., and Choe, J. 2016. Ensemble Smoother with Clustered Covariance for 3D Channelized Reservoirs with Geological Uncertainty. *Journal of Petroleum Science and Engineering* 145: 423-435.
- Lee, K., Lim, J., Choe, J., and Lee, H.S. 2017. Regeneration of channelized reservoirs using history-matched facies-probability map without inverse scheme. *Journal of Petroleum Science and Engineering* (in press).
- Lorentzen R.J., Flornes, K.M., and Nævdal, G. 2012. History matching channelized reservoirs using the ensemble Kalman filter. *SPE Journal* 17(1): 137-151

- Luo, X., Stordal, A.S., Lorentzen, R., and Nævdal, G. 2015. Iterative ensemble smoother as an approximate solution to a regularized minimum-average-cost problem: theory and applications. *SPE Journal* 20 (5), 962–982.
- Nævdal, G., Mannseth, T., and Vefring, E.H. 2002. Near-well reservoir monitoring through Ensemble Kalman filter. Paper SPE 75235 presented at SPE/DOE Improved Oil Recovery Symposium, Tulsa, Oklahoma, USA, 13–17 April.
- Nejadi, S., Leung, J., and Trivedi, J.J. 2015. Characterization of Non-Gaussian Geologic Facies Distribution Using Ensemble Kalman Filter with Probability Weighted Re-Sampling. *Mathematical Geosciences* 47(2): 193-225.
- Peters, E., Wilschut, F., and Leeuwenburgh, O. 2011. Integrated workflow for computer assisted history matching on a channelized reservoir. Paper SPE 141659 presented at SPE Middle East Oil and Gas Show and Conference, Manama, Bahrain, 25-28 September.
- Sebacher, B., Hanea, R., and Heemink, A. 2013. A probabilistic parameterization for geological uncertainty estimation using the ensemble Kalman filter (EnKF). *Computational Geosciences* 17 (5): 813–832.
- Sebacher, B., Stordal, A.S., and Hanea, R. 2015. Bridging multipoint statistics and truncated Gaussian fields for improved estimation of channelized reservoirs with ensemble methods. *Computational Geosciences* 19 (2): 341–369.
- Shin, Y., Jeong, H., and Choe, J. 2010. Reservoir characterization using an

EnKF and a non-parametric approach for highly non-Gaussian permeability fields. *Energy Sources, Part A: Recovery Utilization & Environmental Effects* 32(16): 1569-1578.

Skjervheim, J.-A., Evensen, G., Hove J., and Vabø, J.G. 2011. An ensemble smoother for assisted history matching. Paper SPE 141929 presented at the SPE Reservoir Simulation Symposium, The Woodlands, Texas, 21-23 February.

Van Leeuwen, P.J. and Evensen, G. 1996. Data assimilation and inverse methods in terms of a probabilistic formulation. *Monthly Weather Review* 124(12): 2898–2913.

Zhou, H., Gómez-Hernández, J.J., Franssen, H.J.H., and Li, L. 2011. An approach to handling non-Gaussianity of parameters and state variables in ensemble Kalman filtering. *Advances in Water Resources* 34(7): 844–864.

Zhou, H., Li, L., Franssen, H.J.H., and Gómez-Hernández, J.J. 2012. Pattern recognition in a bimodal aquifer using the normal-score ensemble Kalman filter. *Mathematical Geosciences* 44(2): 169–185.

## ABSTRACT

Ensemble smoother(ES) is one of the powerful optimization schemes for production data history matching in petroleum engineering. It updates all available observation data at once and has high calculation efficiency. For successful history matching using ES, several assumptions should be satisfied. An average of models should be close to a reference field and petrophysical properties should follow a Gaussian distribution. Since channel reservoirs usually have high heterogeneity, they hardly satisfy the assumptions.

In this paper, the three schemes are integrated in ES: initial geological model selection scheme(IGMSS), discrete cosine transform(DCT), and channel information update scheme. In IGMSS, reservoir models are reduced in dimension and visualized in two-dimensional(2D) plane. Then, the transformed models are classified using support vector machine(SVM). DCT figures out main channel features by extracting out essential coefficients which represent overall channel characteristics. Channel information update scheme can assimilate channel information of ensemble models close to the reference, maintaining a bimodal distribution of parameters.

The proposed method is applied to three fields to test its applicability: simple 2D field, complex 2D field, and 3D field. The suggested method can maintain channel properties and bi-modal distribution and solve over-/under-shooting problems in cases of high uncertainty and a large number of grids. Moreover, it provides reliable prediction of future productions. The proposed method can be helpful for making proper and reasonable decisions in operation of petroleum production.

Keywords: ensemble smoother, initial geological model selection scheme, support vector machine, discrete cosine transform, channel information update  
Student number: 2013-21026

## 감사의 글

지난 5년반의 연구실 생활은 제 인생에서 가장 중요한 전환점이 되는 소중한 시간이었습니다. 그 동안 정말 많은 분들께 도움을 받았고 결실을 맺는 시점에서 이렇게 글로나마 감사를 전합니다.

제자로 받아주시고 지도해 주신 최종근 교수님께 감사의 마음을 가장 먼저 전합니다. 교수님께는 참 많은 것을 배웠습니다. 학업과 더불어 삶을 살아가는 데에 있어 교수님은 언제나 저에게 모범적인 지표였습니다. 언제나 단점보다는 장점을 보고 격려해 주시는 교수님이 계셨기에 연구에 전념할 수 있었습니다. 사회에 나가서도 실력과 인격을 겸비하여 부끄럽지 않은 제자가 되도록 노력하겠습니다.

저의 박사학위 심사위원을 맡아주신 박형동 교수님께도 감사드립니다. 교수님의 조언으로 논문의 흐름을 바로잡을 수 있었습니다. 바쁘신 와중에도 더 나은 논문이 될 수 있도록 도와주시고 또 격려해주신 송재준 교수님, 신현돈 교수님, 감사합니다. 언제나 친근하게 대해주시고 진심어린 조언을 아끼지 않아주신 정훈영 교수님께도 감사의 말씀을 전합니다.

석유공학에 대한 기본 소양을 길러 주시고 사회생활의 자세와 업무능력을 가르쳐주신 강주명 교수님께 감사드립니다. 전과를 결정하기까지 많은 조언을 해주신 민동주 교수님, 언제나 먼저 다가와 진솔한 상담을 해주셨던 민기복 교수님, 감사드립니다. 교수님들이 계셨기에 제 학부생활이 전공에 대한 열정으로 가득할 수 있었습니다.

긴 시간 동안 좋은 분위기에서 연구실 생활을 할 수 있었던

것은 저 이전에 선배님들이 좋은 환경을 만들어주셨기 때문이라고 생각합니다. 특히 논문과 연구에 대해 많은 조언을 해주셨던 이경복 박사님께 감사드립니다. 박사님과 함께 연구를 하면서 정말 많은 것을 배웠습니다. 또한 연구, 진로, 인생에 대한 고민을 할 때 진심어린 조언으로 도움을 주신 주성규 박사님, 진정우 박사님, 김성일 박사님, 이태엽 선배님, 정대인 박사님, 그리고 정승필 박사님께 감사 드립니다. 사회 곳곳에서 활약하고 계시는 선배님들께 부끄럽지 않게 저 또한 정진하겠습니다.

연구실 생활을 함께했던 선후배님들에게도 감사의 말씀을 전합니다. 특히 오랜시간을 함께한 병철이와 준이에게 더욱 고맙습니다. 서로 연구에 대한 조언을 주고받고, 또 힘든 시기에는 고민을 나눌 수 있어 많은 도움이 되었습니다. 앞으로도 좋은 인연 계속 이어나갔으면 좋겠습니다. 그리고 지금은 먼 타지에서 고생하고 있는 연구파트너 홍근, 청개구리 형준, 듬직한 채우형, 자유로운 영혼 민수형에게도 감사의 말씀을 전합니다. 언제나 성실하게 맡은 바 최선을 다해주었던 재호, 관덕, 남훈, 영빈, 충호, 준규, 종현, 준희, 새봄, 지윤, 혜윤에게도 또한 감사 드립니다. 여러분의 도움이 있었기에 제가 연구실 생활을 잘 마무리할 수 있었습니다.

학부시절부터 대학원 생활까지 많은 시간을 함께한 정민이와 재준이에게도 고맙단 말을 전합니다. 고민을 나누고 서로 격려해주는 과정에서 많은 위안을 얻었습니다. 앞으로 하는 모든 일이 잘되길 바랍니다.

언제나 저의 곁에서 격려와 응원을 아끼지 않는 사랑하는 여자친구 예진에게도 고마운 마음을 전합니다. 저를 가장 먼저

생각해주고 배려해주는 당신이 있었기에 행복한 마음으로 더욱 연구에 정진할 수 있었고 미래를 준비할 수 있었습니다. 앞으로 오랜시간 함께 행복했으면 좋겠습니다.

마지막으로 가족들에게 감사의 마음을 전합니다. 무엇보다 저를 낳아주시고 물심양면 부족함이 없이 키워주신 부모님께 정말 감사드립니다. 물려 주시고 길러 주신 것 잊지 않고, 주신 사랑에 조금이나마 보답할 수 있도록 겸손하고 당당하게 살겠습니다. 하나뿐인 동생, 어릴 때는 잘 몰랐지만 존재만으로 큰 힘이 됩니다. 가족이 있기에 힘들 때 기대어 견디고 앞으로 나아갈 수 있었습니다. 정말 감사드리고 사랑합니다.

2018년 7월,  
정형식 드림.