

감압증류탑에서의 생산물 중비점 추정을 위한 인공신경망의 응용

이문용, 이종민*, 박준구*
영남대학교 화학공학과, 주)유공 울산연구소*

Application of an Artificial Neural Network to Product End-point Estimation of a Vacuum Distillation Column

Moonyong Lee, Jongmin Lee*, and Jungu Park*
Dept. of Chem. Eng., Yeungnam Univ., Yukong Ulsan Research Center*

서론

증류탑의 생산물 규격을 제어하기 위하여는 생산물의 규격을 on-line 으로 측정할수 있는 측정기기가 필요하다. 그러나 이와같은 on-line 측정기기는 신뢰성이 낮고 측정시간지연이 크며 고가이고 유지보수가 어렵다는 이유들로 인해 아직까지는 생산물의 규격제어에 직접 closed-loop 형태로 적용되지 못하고 있는 실정이다. 이와같은 이유로 규격을 직접 측정하는 대신 증류탑 내의 적정지점의 온도를 이용하여 생산물의 규격을 간접적으로 추정하는 방법이 생산물의 규격제어를 위해 현재까지도 가장 널리 쓰이고 있다. 이러한 온도에 의한 간접추정 방법은 측정이 쉽고 싸며 기기의 신뢰성이 높고 시간지연이 거의 없는 장점을 가지고 있는 반면 non-key 성분의 농도 변화와 증류탑 운전압력 변화에 대해 추정 정확도가 크게 저하되는 문제점을 가지고 있다. 이러한 문제점은 생산물이 다성분계 인수록 더욱 심각해지며 규격이 end-point 등과 같이 농도 이외의 형태로 나타나는 경우에는 적용이 불가능하게 된다. 이를 개선하기 위해서 여러 가지 추정방법들이 연구되어져 왔다[1-5]. 그러나 아직까지도 다성분계 증류탑에서는 엄밀한 규격제어가 매우 어려운 실정이며 실제운전은 생산물 규격이 어긋나지 않을 정도로 온도 설정점에 충분한 여유를 두고 운전하면서 수시간 마다 시료를 채취하여 실험실에서 분석한 후 그 결과를 토대로 운전원의 경험에 의거하여 운전조건을 재설정해 주는 manual 식 운전을 따르고 있는 실정이다.

본 연구에서는 다성분계 감압증류탑에서의 Vacuum Gas Oil (VGO) 의 end-point 를 추정하기위해 선형통계기법에 의한 추정기와 인공신경망을 이용한 추정기를 개발하였으며 실제공정에 적용하여 그 성능과 특성을 검토하였다.

본론

대상공정인 중질유 감압증류탑의 개략도는 그림 1. 에 나타낸 바와 같다. 주 원료는 상압증류탑에서 나오는 상압 잔사유이고 탑정으로는 sour water 와 slop

oil 이 나가고 탑 중간단에서 light VGO 와 heavy VGO 가 분리되어 합쳐지서 VGO 가 생산되며 탑저로는 감압 잔사유가 분리되어 나오게 된다. 이 감압증류탑은 감압잔사유와 VGO 의 제품규격을 되도록 엄밀히 유지하면서 운전되어야 한다. 여기서 주 생산물인 VGO 의 제품생산 규격은 end-point 이며 이를 결정짓는 주요인자를 찾기위해 전산모사를 통한 선형통계시험을 수행하였다. 그 결과 HVGO 유출단의 온도, HVGO 유출단으로 들어오는 vapor 의 온도, 유출단 이렛단의 vapor 와 liquid 유량 및 유방미, 증류탑 압력등으로 압축될 수 있었다. 따라서 VGO end-point 추정기는 아래의 함수 f 를 찾음으로서 구해진다. 즉

$$\text{VGO end-point} = f(T_L, T_v, L, V, L/V, P) \quad (1)$$

이때 T_L, T_v, L, P 는 on-line 측정이 가능하고 V 는 탑상부의 물질수지로부터 쉽게 구해질수 있다. 함수 f 를 구하기 위해서 본 연구에서는 선형통계기법인 Multiple Linear Regression (MLR) 방법과 Feed Forward Network (FFN) 구조의 인공신경망을 적용하였다. MLR 방법은 다변수간의 상관관계가 선형적일 경우 가장 널리 쓰이고 있는 방법이나 변수간의 상관관계가 비 선형적인 경우, 데이터의 noise 가 심한 경우, 변수간의 interaction 이 큰 경우에는 적합치 않은 한계점이 있다. 인공신경망 기법[6]은 비선형적 관계의 mapping 능력이 우수하고 data 의 noise 에 강건한 장점이 있어 최근 화학공정의 제어나 modeling 에의 응용연구가 활발히 이루어지고 있다[7,8]. 본 연구에서는 사용된 인공신경망의 층수는 입력층, 은닉층, 출력층의 세개로 구성되었으며 은닉층의 node 수는 simulation 결과를 기본으로 하여 세개로 정해졌다.

추정기 구조는 그림 2 와 같이 평형적 구조로 설계하였다. 운전 data 를 이용하여 단일구조로 추정기를 설계하는 경우 운전 data 의 편중에 의한 모델왜곡 현상과 calibration set 이외의 영역에서의 모델성능의 급격한 저하 등의 문제가 발생하게 된다. 제안된 추정기구조는 넓은 운전범위에서의 규격을 추정해 주기위한 principal model 과 실제 운전영역에서의 실제 규격추정치 보상을위한 residue model 로 구성되었다. 정상상태 모사기를 이용하여 가능한 운전범위에 대한 calibration set 을 구하였으며 이를 이용하여 principal model 을 구하였다.

그림 3-a, b 는 MLR 과 ANN 을 이용하여 principal model 을 구성하였을 때의 각각의 recall 특성을 보여주어 있다. 그림에서 볼수 있듯이 ANN 이 MLR 보다 훨씬 우수한 재현능력을 가짐을 알수 있다. 이는 또한 가능한 운전범위 내에서 VGO 의 end-point 와 운전변수 간에는 비선형관계가 있음을 보여주고 있다. 이렇게 구해진 principal model 은 정상상태 모사기 결과를 기본으로 한 것이기 때문에 실제 운전 data 와는 차이를 보이게 된다. 이러한 bias 를 보정해 주기 위하여 VGO end-point 와 실제 운전 data set 를 이용하여 residue model 을 만들었다. 모든 data 는 mean-centering 과 variance-scaling 처리를 하였으며 운전 data 는 averaging 값을 이용하였다. 그림 4 는 구성된 추정기의 end-point 추정결과와 실치를 비교한 결과이다. 그림에서 볼수 있듯이 MLR 이나 ANN 모두 만족스럽게 residue 를 보정해 줌을 알수 있다. 이는 principal model 이 이미 major characteristic 을 추정해 주고 bias 는 작은 선형적 범위에 국한됨을 보여주고 있다. 이렇게 구한 추정기의 실제적용결과 전영역에서 약 3.5 C 이내의 평균오차를 보이는 좋은 결과를 보였다. 이는 실험실의 실험오차와 계측기기의 오차를 고려

할 때 만족할 만한 성능이라 할수 있다.

결론

중진유분리를 위한 감압증류탑에서의 VGO end-point 의 on-line 추정을 위한 static 추정기를 개발하고 이를 실제현장에 적용하여 그 성능을 확인하였다. 추정기는 principal model 과 residue model 이 평행하게 구성되는 구조로 이루어졌다. 넓은 운전범위에서의 end-point 추정을 위한 principal model 은 인공신경망을 이용하여 구현하였으며 실험치와의 bias 보정을 위한 residue model 은 MLR 이나 인공신경망 이나 별다른 차이가 없었다. 이렇게 구성된 추정기는 현장적용결과 매우 우수한 추정성능을 보여주었으며 이 결과는 유사한 다성분계의 규격추정기 설계에 확장적용 될수 있으리라 보인다.

감사

본 연구는 한국과학재단지정 우수연구센터인 공정산업의 지능자동화연구센터의 연구비 지원과 주)유공의 연구비 지원에 의해 수행된 연구결과임.

참고문헌

1. Nisenfeld, A.E. and R.C. Seeman, "Distillation Columns", ISA, 1981.
2. Kister, H.Z., "Distillation Operation", McGraw-Hill, 1990.
3. Weber, R. and C. Brosilow, "The Use of Secondary Measurements to Improve Control", AIChE J., vol. 18, No. 3, 614-623, 1972.
4. Mejdell, T. and S. Skogestad, "Estimation of Distillation Compositions from Multiple Temperature Measurements Using Partial-Least-Squares Regression", Ind. Eng. Chem. Res., 30, 2543-2555, 1991.
5. Kresta, J.V., T.E. Marlin, and J.F. MacGregor, "Development of Inferential Process Models Using PLS", Comp. Chem. Engng, vol. 18, No. 7, 597-611, 1994.
6. Hecht-Nielsen R., "Theory of the Backpropagation Neural Network", Proc. IEEE 1989 Intl. Conf. Neural Networks, I-593-605, 1989.
7. Chen, S., et. al, "Nonlinear System Identification Using neural networks", Int. J. Control, 51, 1990.
8. Bhat, N. and T. J. McAvoy, "Use of Neural Network for Dynamic Modeling and Control of Chemical Process Systems", Comp. & Chem. Engng., 14, 1990.



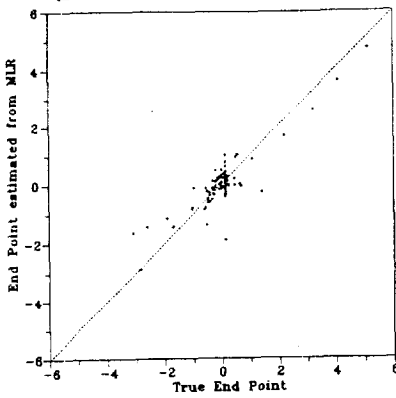



그림 2. 추정기 구조

그림 1. 감압증류공정 개략도




(a) MLR 에 의한 추정



(b) FNN 에 의한 추정

그림 3. Principal Model 추정 정확도 비교



(a) FNN (Principal) + MLR (Residue) (b) FNN (Principal) + FNN (Residue)

그림 4. End-point 추정결과와 실험실 결과 비교