

# 신경망을 이용한 태풍진로예측

박성진\*·조성준\*\*

## Typhoon Track Prediction using Neural Networks

Seongjin Park\*·Sungzoon Cho\*\*

### 요 약

정확한 태풍진로 예측은 동아시아 최대의 자연재해인 태풍의 피해를 최소화하는데 필수적이다. 기상역학에 기초를 둔 수치모델과 회귀분석등의 통계적 접근법이 사용되어왔다. 본 논문에서는 비선형 신경망모델인 다층퍼셉트론을 제안한다. 즉, 태풍진로예측을 이동경로, 속도, 기압 등의 변수로 이루어진 시계열의 예측으로 본다. 1945년부터 1989년까지 한반도에 접근한 태풍 데이터를 이용하여 제안된 신경망을 학습한 후, 94, 95년도에 접근한 태풍의 진로를 예측하였다. 신경망의 예측성능은 수치모델의 성능보다 조금 우수하거나 비슷하였다. 신경망의 성능은 충분히 더 향상될 수 있는 여지가 있다. 또한, 고가의 슈퍼컴퓨터로 여러 시간 계산을 해야하는 수치모델에 비하여 PC상에서 수초만에 계산을 할 수 있는 신경망 모델은 비용 면에서도 장점이 있다.

Keywords : Typhoon Tracking, Neural Networks, Time Series, Network Pruning

### 1. 서 론

기상 현상 중에서 인간에게 가장 많은 피해를 입히는 것의 하나가 태풍이다. 태풍은 북미, 인도, 동아시아 지역에서 주로 발생하며, 평균수명

일이 9일, 중심 최대 풍속이 120km/h 이상의 열대성 폭풍이다. 매년 평균 17개의 태풍이 발생하며, 그 중 3개 정도가 한반도를 통과한다. 기상청의 통계에 따르면 우리 나라에서 태풍으로 인한 피해는 연 평균 사망자 108명, 재산 피해 170억원에 이른다[한국 기상 학회, 1986]. 지

\*한미연합사 제607기상대대

\*\*포항공대 전자계산학과

금까지 태풍 진로 예측을 위해 수 십 년간 연구가 진행되었으나, 아직 정확한 태풍의 진로를 예측하는데 어려움을 안고 있다. 우리 나라에서는 기상청과 공군 기상 전대에서 태풍 진로 예보를 하고 있으며, 최근 기상청에서는 일본에서[Ueno, 1989] 도입한 수치 모델을 이용하여 태풍 진로를 예보하고 있다[한국 기상청, 1995; 한국 기상청, 1996, 부록 참조].

입력과 출력 사이의 함수를 예제를 통하여 교사 학습 받는 신경망 모델은 최근 시계열 예측 분야에서 기존의 통계적인 방법보다 좋은 결과를 내고 있다[Chakraborty, 1992; Tang, 1991; Weigend, 1990]. 본 논문에서는 신경망 모델을 이용하여 태풍 진로 예측을 한다.


첫째, 태풍의 생성에서부터 소멸 때까지를 예측하는 태풍 진로 예측 신경망 모델을 구성하고, 둘째, 태풍에 관한 기존 연구에 근거하여[Tang, 1991] 태풍을 전향전과 전향후로 분리하여 모델을 구성하였다. 셋째, “불필요한” 네트워크의 연결을 제거(Pruning)하는 기법을 사용하여 예측 성능의 향상을 꾀하였다. 본 논문에서 제안된 신경망 모델은 기상청에서 사용한 수치 모델인 KTM에 비하여 비슷하거나 약간 우수한 예측 성능을 보였다.

본 논문은 다음과 같이 구성되었다. 2절에서는 태풍 진로의 시계열화 방안에 대하여 논의한다. 3절에서는 제안된 다양한 신경망 모델에 대한 소개와 학습, 그리고 성능 평가가 제시되며, 4절에서는 결론과 토의가 이어진다.

## 2. 태풍 진로의 시계열화

태풍 진로를 보면 시간의 변화에 따라 태풍 위치와 특성이 변한다. 즉, 태풍 예상 이동 경로

는 과거의 태풍 진로 분석을 통해서 예상할 수 있는데, 시간 변화와 이동 위치에 따라 태풍 세력이 변하며, 태풍 발생에서 소멸의 일련의 과정 동안에 일어나는 태풍의 이동 방향, 세력 변화 등을 시계열로의 전환이 필요하다. 태풍 진로를 시계열화 하는데 여러 가지 선택 조건들이 존재한다. 첫째로, 입출력을 정하는 것이다. 입력으로 위도, 경도, 최대 풍속, 최저 기압의 기본 변수에[Johnson, 1995] 날짜, 전향 여부, 진행 속도 등의 변수를 하나씩 추가시키면서 학습과 검증의 반복을 통해서 변수 추가에 따른 예측 오차의 증감을 고려하였다. 결국 다음과 같이 두 가지 경우, 첫째, 위도, 경도, 최대 풍속, 최저 기압, 둘째, 위도, 경도, 최대 풍속, 최저 기압, 날짜, 위도 성분의 이동 속도, 경도 성분의 이동 속도, 전향 여부 등으로 입력 변수를 결정하였다. 학습 자료의 시계열화를 위해서, 한 단위 시간씩 움직여 가며 학습 패턴을 구성하는 슬라이딩 윈도우 기법을 사용하였다[그림 1].



[그림 1] 슬라이딩 윈도우 기법

## 3. 학습 및 결과

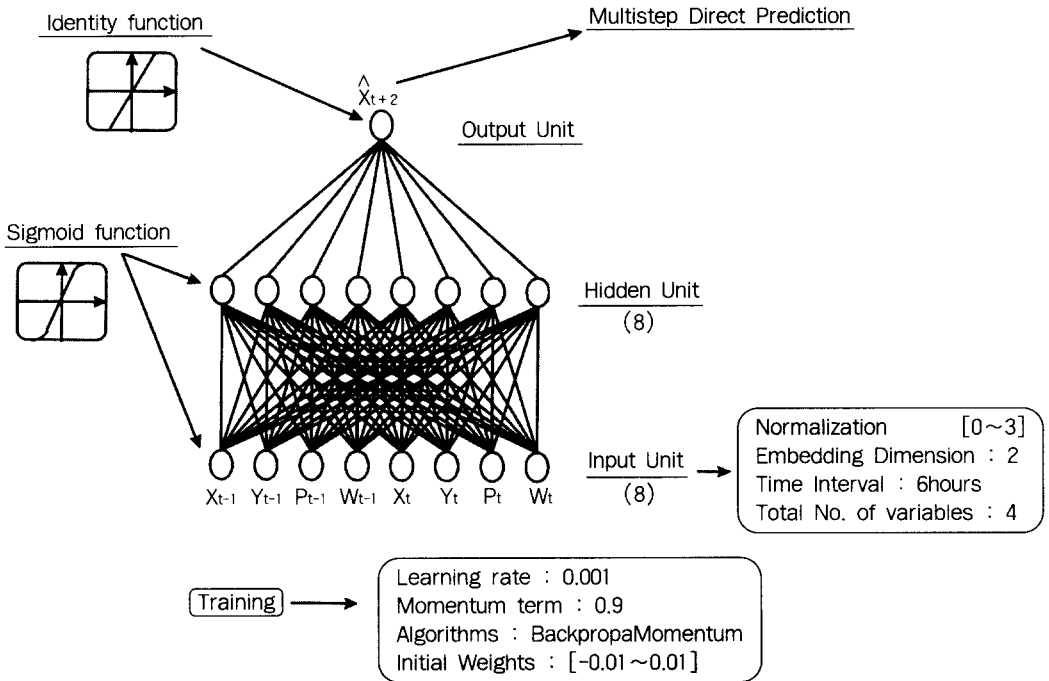
학습에는 1945년~1964년, 1970년~1989년의 기간 동안 6시간 간격 데이터로 계절에 상관없이 열대성 폭풍 단계에서부터 이름이 붙여진 태풍들을 사용하였다. 검증 데이터는 1965년~1969년의 기간 동안 발생한 태풍들로 구성되며, 과잉 학습 혹은 불충분 학습을 방지하는 역할을

한다. 성능 평가 데이터는 [Anthes, 1987]에서 사용한 1986년~1989년의 기간 동안 한반도에 접근하는 태풍의 유형을 7가지 유형으로 나누어, 그 유형별 대표적인 태풍을 선정하여 "In-sample"(학습 데이터와 동일 기간이라는 의미로) 패턴으로 구성하였으며, 1994년~1995년에 우리 나라 부근을 지나간 각각 5, 7개의 태풍으로 기상청의 수치 모델과 직접 비교할 수 있

는 데이터로 "Out-of-sample"(학습 데이터와 시점이 다르다는 의미로) 패턴을 구성하였다.

### 3.1 전체 태풍 모델과 그 예측 결과

태풍 진로 예측을 위해 제안된 신경망 모델의 네트워크 구조(경도 예측 네트워크)는 다음과 같은 형태를 갖는다[그림 2]. 동일한 구조의 위도 예



[그림 2] 경도 예측 네트워크 : 입력 변수  $X(t)$ ,  $Y(t)$ ,  $P(t)$ ,  $W(t)$ 는 각각 시간  $t$ 에서의 경도, 위도, 최저 기압, 최대 풍속을 의미한다.

측 네트워크도 있다.

신경망 모델은 각 시간별( 12, 24 .. ) 예측을 위해, 위도, 경도의 한 쌍의 네트워크로 존재함으로써 태풍의 예상 진로를 알 수 있다. 태풍 모델 학습을 위해 학습률은 0.001, Momentum term은 0.9, 초기 가중치는 [-0.01~0.01]에서 임의로 선택하였다. 학습 알고리즘은 에러역전파

(Backpropagation)를 사용하였으며, 입력 패턴으로는 6시간과 12시간 전의 데이터를 사용하였다(즉, embedding dimension = 2).

표 1과 2는 위와 같이 학습된 신경망 모델의 예측 성능을 보여 주고 있다. In samples 테스트의 경우 12시간 예측에서 수치 모델보다 50%의 예보 오차 감소를, out-of-sample의 경우 94년도


12시간, 95년도 24시간 예측에서 4.3%, 6.2%의 예측 오차 감소를 보인다. 나머지 경우에는 비슷하거나 수치모델보다 조금 성능이 떨어진다.

〈표 1〉 전체 태풍모델의 In-sample 패턴 태풍중심 예측오차 (단위:km, N/A:해당자료 없음)


태풍 이름	12시간 예측		24시간 예측	
	신경망 모델	수치 모델	신경망 모델	수치 모델
노리스	59	N/A	127	N/A
베라	65	N/A	241	N/A
포리스트	72	N/A	160	N/A
세실	60	N/A	156	N/A
셀마	69	N/A	181	N/A
엘리스	52	N/A	111	N/A
जू디	64	N/A	160	N/A
평균	62	124	151	139

〈표 2〉 전체 태풍모델의 Out-of-sample 태풍 중심 예측오차 (단위:km, N/A:해당자료 없음)

태풍 이름	12시간 예측		24시간 예측		
	신경망 모델	수치 모델	신경망 모델	수치 모델	
94	윌트	85	N/A	244	N/A
	브랜던	89	N/A	250	N/A
	도그	84	N/A	257	N/A
	엘리	79	N/A	232	N/A
	세스	106	N/A	158	N/A
	평균	87	91	225	169
95	페이	71	75	125	201
	제니스	140	113	296	252
	켄트	71	81	170	250
	오스카	116	59	117	115
	폴리	87	55	175	163
	라이언	80	103	208	136
	워드	101	105	194	190
	평균	91	87	181	193



[그림 3] 전향후 태풍 모델의 위도 예측을 위한 네트워크 : 16-8-1



[그림 4] 전향후 태풍 모델의 경로 예측을 위한 네트워크 : 16-16-1

전향후 수치 모델 예측 결과는 out-of-sample의 95년도 태풍 외에는 전향 전후 전체의 평균값만 존재하여 비교가 불가능하다. 일반적으로 전향 후 태풍에 대한 예측 성능은 전향 전보다 떨어진다. <표 3>에서 보는 바와 같이 out-of-sample의 95년 24시간 예측 오차가 전체 태풍 모델보다 감소하는 결과를 냈다. 태풍 켄트와 라이안의 신경망 예측 값이 없는 것은 태풍의 수명이 짧거나, 전향전의 태풍이기 때문이다.

<표 3> 전향후 태풍 모델의 Out-of-sample 95년도 태풍 중심 예측 오차(단위:km, N/A:해당자료 없음)

태풍 이름	12시간 예측		24시간 예측	
	신경망 모델	수치 모델	신경망 모델	수치 모델
페이	89	64	228	132
제니스	167	122	231	304
켄트	N/A	81	N/A	250
오스카	57	48	112	83
폴리	116	85	292	247
라이언	78	15	N/A	136
워드	53	138	135	276
평균	86	85	172	213

### 3.3 네트워크 가지치기 ( Pruning )

신경망의 구조, 특히 은닉 노드의 수는 모델의 복잡도를 결정하여 특정 응용 문제에서의 모델 성능에 중요한 영향을 미친다. 주어진 문제에 가장 적합한 신경망의 복잡도(크기)는 사전에 알 수 없다. 따라서, 충분히 커다란 네트워크로 먼저 학습을 시킨 후에 "적당한" 크기로 줄여 나가는, 즉, 네트워크 가지치기 기법들이 제안되었다[Le Cun, 1990; Hassibi, 1993]. 상대적 중요도가 작은 연결을 차례대로 제거하여 은닉 노드 또는 입력 노드 까지도 제거할 수 있게된다.

본 논문에서는 1990년 Le Cun이 제안한 Optimal Brain Damage(OBD)[Le Cun, 1990] 방식을 적용하였다. 여기서는 에러 함수에 대한 연결 가중치의 헤시안(Hessian) 행렬 값과 연결 가중치의 곱이  $(\frac{\partial^2 E}{\partial w_i^2} \cdot w_i^2)$  최소인것들부터 제거하기 시작한다. 실제로 연결을 제거하면 검증 에러가 조금 상승하는데 이 허용치, 절대 오차 값, 재학습 시간, 학습 정지를 위한 최소 오차 값, 그리고 입력 노드도 제거 대상으로 삼을 것

인 지의 여부 등이 실험적으로 결정되었다(표 4, 5 참조). 가지치기의 결과로 네트워크의 크기가 처음보다 훨씬 작아졌다. 입력 변수의 수도 16에서 6, 8, 12등으로 감소하였다.

〈표 4〉 OBD 파라미터와 결과 네트워크 구조 (12 시간 예측).

Networks	Max.Err.In	Absolute.Err	Retraining	Min.Err	Input Pruning
6-2-1	15	0.0003	100	0.0003	Yes
6-2-1	10	0.000021	100	0.00021	Yes

〈표 5〉 OBD 파라미터와 결과 네트워크 구조 (24 시간 예측).

Networks	Max.Err.In	Absolute.Err	Retraining	Min.Err	Input Pruning
12-2-1	15	0.00213	100	0.0003	Yes
8-8-1	10	0.0011	10	0.0011	Yes

전향후 태풍 진로 예측에서는 In-sample 테스트 경우에 수치 모델보다 12시간에서 54%, 24시간에서 6.4%의 태풍 중심 예측 오차가 감소하는 성능을 보였으며, out-of-sample 테스트에서 94년도 12시간 예측에서 21.9%, 95년도 24시간에서 19.7%의 태풍 중심 예측 오차가 감소하는 우수한 성능을 보였다.

가지치기된 네트워크의 입력 변수를 살펴보면 위도 예측을 위해서는 전시간의 위도, 현재시간의 경도, 현재 시간의 최저 기압, 현재 시간의 최대 풍속, 날짜가 계속 입력 변수로 사용되었고, 경도 예측을 위해서는 전시간의 경도, 현재 이동 속도 경도 성분, 현재의 최저 기압, 날짜 등이 남아 있었다. 따라서, 위도, 경도의 학습을 위해서는 별도의 입력 변수를 사용하여야 한다는 것과, 날짜와 현재의 최저 기압은 12, 24시간의 위도와 경도 예측하는데 모두 반드시 있어야 하는 변수라는 것이 판명되었다.

〈표 6〉 OBD에 의한 전향후 태풍 모델의 Out-of-sample 태풍 중심 예측 오차 (단위:km)

태풍 이름	12시간 예측		24시간 예측		
	신경망 모델	수치 모델	신경망 모델	수치 모델	
95	페이	92	64	219	132
	제니스	160	122	182	304
	켄트	N/A	81	N/A	250
	오스카	68	48	91	83
	폴리	121	85	276	247
	라이언	90	20	N/A	136
	워드	57	138	103	276
	평균	89	85	171	213

## 4. 토의 및 결론

현재 태풍 진로 예측을 위해서는 기상 상태를 수식화한 KTM이라는 수치 모델을 사용하고 있다. 한편 회귀분석기법에 기반을 둔 CLIPER 모델도 많이 연구되고 있다[권혁조, 1993; Neumann, 1976]. 예측 성능 면에서 수치 모델이 더 우수하지만 계산량이 엄청나게 많아 슈퍼컴퓨터를 사용하여야만 예보가 가능하다. 기상청에서 현재 사용중인 KTM ( Korea Typhoon Model )은 후지쓰 슈퍼컴퓨터로도 약 30분 가량의 계산을 하여야한다. 반면에 본 논문에서 제안한 신경망 모델은 태풍 진로를 시계열화 하여 과거의 태풍 진로를 학습한 후 사용되므로, PC 상에서도 1초 이내에 예측이 가능하다. 비용과 속도 면에서 수치 모델에 비해 매우 저렴하고 빠르다할 수 있다. 또한, 성능 면에서도 전향후 태풍 모델의 in-sample 패턴에서 미국과 일본에서 개발된 수치모델[한국 기상청, 1986; Ueno, 1989]을 기반으로 하는 KTM을 사용한 결과보

다, 12시간 예측에서 54%, 24시간에서 6.4%의 우수한 성능을 냈다. 수치모델에 비하여 신경망 예측 오차가 감소하는 우수한 성능을 보였다. Out-of-sample 패턴의 경우에는 기상청의 수치 모델에 비해 94년도 24시간예측을 제외한 95년도 12, 24시간 예측과 95년도 12시간 예측에서 우수한 성능을 보였다. 수치모델에 비하여 신경망 모델은 개발인력의 기상학적 전문성이 높지 않고 개발기간도 비교가 되지 않을 정도로 짧은 것을 고려하면 그 성능이 놀라운 것이다. 즉, 이 기법의 가능성을 보여주었다 하겠다.

앞으로 태풍에 대한 추가 정보(상층 기류, 고도별 기압계 이동) 등을 활용한다면 24시간 이상의 예측에서도 가능성이 있다. 그 외 다른 기상 분야 즉, 비행장 시정 단기예보, 강수예보, 집중호우 예보 등에 신경망 모델을 기반으로 한 기상 예측 모델의 가능성을 보였다 하겠다.

### 참고문헌

1. 권혁조, 이상호, 태풍 진로 예측을 위한 지역적으로 강화된 CLIPER 모델의 개발 연구, 한국 기상 학회, 제 27권, 제 3호, pp.195-204, 1993.
2. 권혁조, 이상호, 한국 접근 태풍에 대한 CLIPER 모델의 재조사, 한국 기상 학회, 제 27권, 제 3권, pp.195-204, 1993.
3. 수치 예보실, '94 KMA 수치 모델 예측 검증, KMA/NWPD 기술보고서 95-1, 한국 기상청, Korea, 1995.
4. 수치 예보실, '95 KMA 수치 모델 예측 검증, KMA/NWPD 기술보고서 96-1, 한국 기상청, 1996.
5. 수치 예보실, KTM의 수행과정과 운영, KMA/NWPD 기술보고서 94-2, 한국 기상청, 1995.
6. 이동일, 장동언, 위태권, 한국 접근 태풍들, 1960~1989, Part I : 통계와 종관 개요, 한국 기상학회, 제 28권, 제 2호, pp.133-147, 1992.
7. 이동일, 장동언, 위태권, 한국 접근 태풍들, 1960~1989, Part II : 중규모 수치 모델 예측 실험, 한국기상학회, 제 28권, 제 2호, pp.133-147, 1992.
8. 태풍 백서, 한국 기상 학회, 한국 기상청, 1986.
9. Anthes R., E. Hsi and Y. Kuo, Description of the Penn State Univ/NCAR Mesoscale Model, version 4 *Technical Note*, NCAR/TN 282-STR, 1987.
10. Chakraborty K., K. Mehrotra, C. K. Mohan and S. Ranka, Forecasting the Behavior of Multivariate Time Series using Neural Networks, *Neural Networks*, Vol.5, pp.961-970, 1992.
11. Hassibi B. and D. G. Stork, Second order derivatives for network pruning: optimal brain surgeon. In S.J. Hanson, J.D. Cowan and C.L. Giles(Eds.), *Advances in Neural Information Processing Systems*, Volume 5, pp.164-171, San Mateo, CA : Morgan Kaufmann, 1993.
12. Johnson G. and F. Lin, Hurricane Tracking via Backpropagation Neural Network, *Proceedings of IEEE International Conference on Neural Networks*, pp.1103-1106, Perth, Australia, 1995.
13. Le Cun Y., J. S. Denker and S. A. Solla(1990), Optimal Brain Damage. In D. S. Touretzky(Ed.), *Advances in Neural Information Processing Systems*, Vol.2, pp.598-605, San Mateo, CA:Morgan Kaufmann, 1990.

14. Neumann C. and E. Randrianarison, Statistical Prediction of tropical cyclone motion over the southeast Indian Ocean, Monthly Weather Review, Vol. 104, pp.76-85, 1976.
15. Tang Z., C. Almeida and P. Fishwick, Time Series Forecasting using Neural Networks vs. Box-Jenkins Methodology, Simulation, Vol.57, pp.303-310, 1991.
16. Ueno M., Operation bogussingand numerical prediction of typhoon in Japan, *JMA/NPD Technical report*, No. 28, 1989.
17. Weigend A., D. Rumelhart and B. Huberman, Predicting the future: A connectionist approach, *International Journal of Neural Systems*, Vol. 1, No. 3, pp.193-209, 1990.

### 부 록

태풍 모델의 수평 구조에서 각 예보 변수들은 동서 및 남북 방향으로 직교 및 비직교 성분의 sinusoidal functions으로 표현된다. 현재의 KTM은 Transform grid가 109 x 109이며, 연직 구조는 8층의 sigma 좌표 계를 사용한다. 기상청 태풍 모델(KTM)의 지배 방정식은 3차원 원시 방정식 계를 기본 방정식으로 사용하는 spectral model이며, 사용한 예보 변수들과 지배 방정식은 다음과 같다.

$$\pi = \ln P_s, \quad u^* = \frac{u}{m}, \quad v^* = \frac{v}{m}, \quad T_v, \quad q$$

( $P_s$ 는 mode's surface pressure,  $u$ 와  $v$ 는 바람의  $x, y$ 성분,  $T_v$ 는 가온도,  $q$ 는 비습,  $m$ 은 map factor (Polar stereographic, Mercator, Lambert conformal conical Projections)이다.)

그리고, 기본 지배 방정식들은 Advection forms으로 표현한다.

⟨Equations of motions⟩

$$\begin{aligned} \frac{\partial u^*}{\partial t} &= -m^2(u^* \frac{\partial u^*}{\partial x} + v^* \frac{\partial u^*}{\partial y}) - \frac{1}{2} u^*(u^* \frac{\partial m^2}{\partial x} + v^* \frac{\partial m^2}{\partial y}) - \sigma \frac{\partial u^*}{\partial \sigma} - (\frac{\partial \phi}{\partial x} + RT_v \frac{\partial \pi^*}{\partial x}) \\ &+ v^*[f + \frac{1}{2}(u^* \frac{\partial m^2}{\partial y} - v^* \frac{\partial m^2}{\partial x})] + D_u - \frac{g}{mP_s} \frac{\partial \tau_x}{\partial \sigma} \\ \frac{\partial v^*}{\partial t} &= -m^2(u^* \frac{\partial v^*}{\partial x} + v^* \frac{\partial v^*}{\partial y}) - \frac{1}{2} v^*(u^* \frac{\partial m^2}{\partial x} + v^* \frac{\partial m^2}{\partial y}) - \sigma \frac{\partial v^*}{\partial \sigma} - (\frac{\partial \phi}{\partial y} + RT_v \frac{\partial \pi^*}{\partial y}) \\ &+ u^*[f + \frac{1}{2}(u^* \frac{\partial m^2}{\partial y} - v^* \frac{\partial m^2}{\partial x})] + D_v - \frac{g}{mP_s} \frac{\partial \tau_y}{\partial \sigma} \end{aligned}$$

⟨Thermodynamic equation⟩

$$\begin{aligned} \frac{\partial T_v}{\partial t} &= -m^2(u^* \frac{\partial T_v}{\partial x} + v^* \frac{\partial T_v}{\partial y}) - \sigma \frac{\partial T_v}{\partial \sigma} (T_v \sigma^{-\alpha}) \\ &+ xT_v[-\frac{\partial \pi^*}{\partial x} + m^2(u^* \frac{\partial \pi^*}{\partial x} + v^* \frac{\partial \pi^*}{\partial y})] + \frac{Q^*}{C_p} + \frac{g}{C_{pP_s}} \\ &\frac{\partial F_H}{\partial \sigma} + D_H \end{aligned}$$

⟨Equation of water vapor⟩

$$\begin{aligned} \frac{\partial q}{\partial t} &= -m^2(u^* \frac{\partial q}{\partial x} + v^* \frac{\partial q}{\partial y}) - \sigma \frac{\partial q}{\partial \sigma} + M + \frac{g}{P_s} \frac{\partial F_q}{\partial \sigma} \\ &+ D_q \end{aligned}$$

⟨Tendency equation and continuity equation⟩

$$\begin{aligned} \frac{\partial \pi}{\partial t} &= -\int_0^1 m^2[\frac{\partial u^*}{\partial x} + \frac{\partial v^*}{\partial y}]d\sigma - \int_0^1 m^2[u^* \frac{\partial \pi^*}{\partial x} + v^* \frac{\partial \pi^*}{\partial y}]d\sigma \\ \sigma_{\sigma+\Delta\sigma} &= \sigma - m^2 \int_{\sigma}^{\sigma+\Delta\sigma} [-\frac{\partial u^*}{\partial x} + \frac{\partial v^*}{\partial y} - u^* \frac{\partial \sigma^*}{\partial x} + v^* \frac{\partial \pi^*}{\partial y}]d\sigma - \Delta\sigma \frac{\partial \pi^*}{\partial t} \end{aligned}$$

⟨Hydrostatic equation⟩

$$\frac{\partial \phi}{\partial \sigma^x} = -C_p T_v \sigma^{-x} \quad ; \quad \frac{\partial \phi}{\partial \sigma} = -\frac{RT_v}{\sigma}$$

태풍의 이동 경로를 현대의 역학적인 수치 모형



으로 예보하기가 매우 어려운데 그 가장 기본적인 이유중의 하나가 정확한 중심의 위치와 실제적인 구조에 대한 관측 자료가 없다는 것이다. 태풍의 진로 예보는 태풍 외동의 구조에 매우 민감하게 좌우됨으로 태풍의 진로를 예보 하기 위해서는 적절히 태풍을 모작하여 모델 초기자료로 정보를 제공하여야 하는데 이러한 방법을 Bogussing Method라 한다. 태풍 초기 움직임은 6시간 전의 태풍의 위치와 현재의 위치를 비교하여 wind vector를 계산하며, axisymmetric wind field를 갖는 boguss typhoon의 모든 층에 대해 이 값을 똑같이 더하여 준 후 객관분석장에 다음의 하중 평균 공식을 이용하여 boguss typhoon을 이식한다.

$$f(\gamma, \theta) = f_M(\gamma, \theta) \times w(\gamma) + f_E(\gamma, \theta) \times (1 - w(\gamma))$$

여기서,  $w(\gamma)$ 는 다음과 같다.

	1	$\gamma \leq R_{c1}$ inner area
$w(\gamma) =$	$\frac{R_{co} - \gamma}{R_{co} - R_{c1}}$	$R_{c1} \leq \gamma \leq R_{co}$ transition area
	0	$\gamma \geq R_{co}$ outer area

$R_{c1}$   $R_{co}$ 는 model typhoon과 객관분석장의 field variables 이다. 최종적으로 태풍 중심에 대해 파수가 1인 asymmetric flow field를 전체의 바람장에 더하여, 비발산 순압 방정식의 선형해로 주어지는 와도 장으로부터 계산하며, 태풍 중심 부근에서 평균된 비축대칭 바람 벡터는 관측된 태풍의 움직임과 일치하게 된다.

또한 태풍의 중심은 각 격자 점들에서의 각 변수의 값을 예측하고 그 예측한 값을 바탕으로 일기도 분석을 통해 고·저기압의 위치와 태풍 중심 위치를 정하게 된다. 즉 KTM 수치 모델은 Bougssing 방법으로 태풍 초기 자료를 만들고, 각 격자 점들의 태풍에 영향력 있는 변수들을 3차원 방정식 계산을 통해 예측하고 이 예측된 값중에서 기압 값을 가지고 태풍의 중심을 찾아내고, 바람 벡터를 이용하여 태풍의 이동 방향을 알아낸다.