

# GOES-9 적외영상자료를 이용한 AODT 검증



박정현  
기상청 예보국 기상위성과



박중서 >  
기상청 예보국 기상위성과



서애숙 >  
기상청 예보국 기상위성과장

## 1. 서론

정확한 태풍중심 강도에 대한 추정은 해상주의보 및 경보, 태풍의 상륙 속보를 통한 주민 대피명령 등의 비상시 정책 결정에 중요한 역할을 한다. 부정확한 태풍중심 강도 추정과 예측은 인간 생활의 안전과 경제적인 면에서도 큰 부담이 아닐 수 없다.

해양에서 주로 발생하는 태풍은 해상에서 직접 관측이 어렵고 종관 규모보다 작아서 태풍의 구조 및 역학을 종관관측망만으로 이해하기에는 어려움이 있다. 따라서 태풍분석에는 전 세계적으로 위성이나 레이다 등의 원격탐사자료가 유용하게 쓰여 왔으며 특히 위성관측자료

는 해상을 포함한 전 지구를 높은 해상도로 관측 가능하여 태풍 등의 열대저기압을 감시하는 데 효과적이다. 미국에서도 대서양 서쪽은 위성관측 외에 비행기를 이용한 직접 관측을 일부 수행하고 있지만, 대서양 동쪽 및 중부는 아직도 태평양을 포함한 대부분의 해양과 마찬가지로 거의 위성관측에 의존하고 있다.

최근 들어 전 세계적으로 태풍중심 위치와 구조, 강도 추정, 변화경향 및 이동 속도 등도 위성관측 외에 비행기, 드랍존데 등 직접관측자료를 활용하려는 시도가 증가하고 있다. 비행기관측자료는 태풍을 직접 관측하여 분석값으로 사용하기도 하지만, 위성관측영상에 의해 추정된 태풍분석 결과를 검증하고 보정할 때 활용하고 있다.

GMS (Geostational Meteorological Satellite), GOES (Geostationary Operational Environmental Satellite), MTSAT (Multi-Funcional Transport Satellite) 등의 정지기상위성은 거의 매 시간 기상상황을 감시하고 태풍정보를 실시간 분석할 수 있어 일찍부터 Dvorak 등에 의해 가시 및 적외영상 기반의 태풍중심 강도를 분석하는 기법 (이하 VIS/IR 기법) 및 적외강조영상 분석기법 (이하 EIR 기법)을 개발되었다 (Dvorak, 1975, 1984). 그러나 주관적인 드보락의 VIS/IR 기법 및 EIR 기법에 의한 결과값은 분석자마다 다를 수 있고, 절차 또한 복잡하여 시급성을 요하는 태풍 분석에서 취약점으로 지적되어 오고 있다. 이러한 주관적인 방법의 한계를 보완하기 위하여 구름패턴을 컴퓨터기반의 자동 객관화된 알고리즘을 적용하는 객관 드보락 분석기법 (Advanced Objective Dvorak Technique, 이하 AODT)이 개발되었고 (Velden et al, 1998), Zehr (1989)에 의해 비행기 관측자료를 이용해서 보완·검증되었다.

드보락기법은 적외영상을 기반으로 하기 때문에 매 시간 중단없이 태풍영역을 감시가능한 장점이 있어서, 객관화와 검증을 거치면서 전 세계적으로 사용되고 있다. 그러나, 하층 및 중층운이 상층운에 의해서 뒤덮여 있어서 판별이 어려운 한계가 있다. 하층

구조와 저기압성회전을 모르면 강도 추정과 구름 시스템 중심 위치 판별이 어렵기 때문에 분석들은 종관 관측자료, 해상풍, SSM/I (Special Sensor microwave/Imager) 등 다른 관측자료 및 다양한 위성자료를 참조하게 된다. SSM/I passive 마이크로웨이브 채널에 대해서 대부분의 상층운이 통과한다. SSM/I 영상은 이런 점 때문에 태풍의 구조를 파악하는 데 사용할 수 있는 이점이 있다 (Hawkins et al. 2001).

이러한 이유로 드보락기법의 단점을 보완할 수 있는 새로운 영상기반의 태풍분석 기법들이 꾸준히 연구되어 오고 있다. May et al. (1997)은 SSM/I 영상으로부터 컴퓨터기반의 경험적 직교 함수 (Empirical Orogonal Fuction, 이하 EOF) 기법을 이용하여, 태풍강도를 자동적으로 추정할 수 있는 신경망 통계기법의 입력자료로 사용한 바 있다. 최근에는 Bankert and Tag (2002)은 SSM/I 영상으로부터 최소 및 평균 픽셀 당 밝기온도 값, 구름 조직 분석 그리고, 최대풍속으로부터 얻어질 수 있는 태풍강도 추정방법 등이 현실적으로 가능하다고 하였으며 K (신경망에서 사용된 표본 자료 개수)-NN (Neural Network) 강도추정 알고리즘 (Duba and Hart, 1973)을 사용한 연구 결과를 발표하여 현업화 가능성을 보였다. 이 논문에서 검증에 사용한 자료는 드보락 강도 추정값, 지상관측자료, 비행기관측자료, 베스트트랙 중심최대풍속, 그리고 JTWC (Joint Typhoon Warning Center)와 NHC (National Hurricane Center) 등의 태풍분석 정보이다. 기준값은 베스트 트랙(best track)의 강도값으로 사용하였으며, 오차범위는  $\pm 10\sim 15$ kt이다. Bankert and Tag (2002)은 SSM/I 영상자료에 K-NN 알고리즘을 적용하여 얻은 강도 추정값을 베스트 트랙 자료와 비교하고, 그 결과 19.8kt의 RMSE (Root Mean Square Error)를 얻었다.

기상청에서는 2001년도부터 GMS 위성관측영상을 이용하여 태풍의 중심위치와 강도를 분석하고 이를 정량적으로 지수화한 주관 드보락기법 (Subj-

ective Dvorak Technique, 이하 SDT)를 이용하여 태풍중심 위치 및 강도를 실시간 분석하여 예보관 및 일반인에게 제공하고 있다. 또한 주관적인 드보락기법이 분석자에 따라 다른 결과가 도출될 수 있어, 이를 보완하기 위해 QuikSCAT 해상풍 관측자료, 정지 및 극궤도위성자료를 활용한 해수면온도 등 위성관측 및 분석자료와 기타 관측자료를 참조하여 태풍정보를 분석하여 제공하고 있다. 드보락기법은 적외영상만으로 태풍 중심위치를 강도를 분석할 수 있는 장점 외에 앞에서 열거한 몇가지 극복되지 못한 한계도 있으나, 아직은 이를 대체할 만한 현업용 분석기법이 개발되지 못했다. 따라서 기상청에서는 그동안 태풍분석업무를 개선하기 위해서 2005년부터 AODT를 도입하여 시험 적용하고 있다. 또한 AODT 알고리즘은 기본적으로 대서양에서 발생하는 태풍에 초점을 두고 개발되었으므로, 북서태평양에서 발생하는 태풍에 직접 적용하기에는 어려움이 있다 (Velden et al. 1998). Hsieh (2004)는 신경망 (Neural Network, 이하 NN)을 통한 비선형 다변수 시계열 분석법을 기상학에 도입하였다. 본 연구에서는 SDT와 AODT자료를 입력자료로 하는 비선형 회귀분석을 시도하여 태평양에서 발생한 태풍 자료에 대해 AODT와 SDT 분석 결과 산출된 CI 수간의 통계적 관계를 밝히고, 이를 북서태평양에 적합하게 보정하고 활용 가능한 관계식을 도출하여 실시간 분석과 태풍감시에 활용하고자 한다.

## 2. 자료 및 분석방법

2004년 4월 5일부터 2004년 12월 22일까지 SUDAL, DIANMU, MINDULLE, MEGI, CHABA, HAIMA 등 26개 태풍 123개 자료를 사용하여 AODT 분석결과와 기존의 SDT 분석결과를 비교검증하였다. 2004년 분석의 경우는 검증을 위하여, 2004년 자료의 맨 처음 두개 태풍인 2004년 4월 5일에 발생한 태풍 SUDAL과 2004년 5월 15일 발생한 태풍

NIDA는 분석에 포함하지 않았으며, 단지 산출된 보정식을 검증하는 데에만 사용되었다. 이는 이어 기술될 비선형 회귀 분석에서도 동일하게 적용되었다.

AODT로 도출된 태풍분석자료는 위스콘신 대학의 분석결과를 수집하고, SDT 결과에 대해서는 태풍중심 위치 및 강도의 비교검증이 가능한 시간대에서 GOES-9 위성의 적외, 가시, 근적외 및 적외강조영상을 활용하였다. 기본관측 채널영상을 통해 태풍중심 위치를 결정하고 적외강조영상을 이용하여 주관 드보락 분석법을 수행하였다. 이렇게 도출된 AODT 결과와 SDT 결과에 대해 선형회귀를 이용한 bias correction 방법과 Hsieh (2004)의 신경망 비선형 주성분 분석법을 이용하여 각각 결과를 얻고 최적의 보정식 도출을 시도하였다.

## 3. 드보락기반 태풍분석 알고리즘

### 3.1 AODT (Advanced Objective Dvorak Technique)

AODT 알고리즘은 컴퓨터 기반 기술로, 정지기상 위성의 적외채널영상을 사용한 열대저기압의 강도를 객관 분석할 목적으로 UW (University of Wisconsin-Madison/CIMSS (Cooperative Institute for Meteorological Satellite Studies)에서 개발하였다. AODT는 열대저기압 (tropical storm)의 생성과 발달에서 소멸까지 태풍강도를 단계별로 분류할 수 있다. AODT의 이전 버전인 ODT(Objective Dvorak Technique)는 태풍의 T수가 3.5 이상이거나 서태평양[대서양]에서 984hPa[994hPa] 이하일 때만 분석이 가능했지만 AODT는 이러한 제한을 없었다.

AODT는 열대저기압 강도를 결정하기 위해 개발되었던 주관적인 드보락 강조적외영상 분석기법 (SDT, Dvorak, 1975, 1984)을 발전시킨 것으로 AODT는 강도 결정 프로토콜에 SDT와 다양한 분석기

술을 결합하였으며, 기존 SDT 규칙 중 몇가지는 AODT 수행결과와 통계분석을 통해 재조정되었다. AODT는 UW/SSEC (Space Science and Engineering Center)와 CSU/CIRA (Colorado State University/Cooperative Institute for Research Applications)에서 개발한 객관적 위성 예측 알고리즘에 기반을 두고 있다. 이전 ODT와 비교하여 분석방법, 기능 및 항목에서 중요한 변화와 추가사항은 이전 디지털 드보락 방법과 비교할 때, 히스토리 파일 (열대저기압 시작에서 소멸시까지 이전 강도추정을 포함)의 추가, 시간 가중평균 기능, 다양한 환경온도값의 새로운 정의 및 결정, 강도추정 변화를 지배하는 다양한 SDT 규칙 등이다. 이러한 변화는 더 안정적이고 통계적인 강도추정 결과를 이끌어낸다 (Velden et al., 1998 and Olander et al., 2004, 2002).

### 3.2 SDT (Subjective Dvorak Technique)

북서태평양에서 발생한 태풍의 영향권에 있는 우리나라는 태풍의 중심위치 및 강도분석을 위해서 GOES-9, MTSAT-1R 등의 위성자료를 적극 활용해 왔으며, 강도분석을 위해서 세계적으로 널리 이용되는 드보락기법 (Dvorak, 1975)을 사용한다. 드보락 기법은 가시영상과 적외 및 적외강조영상을 이용하는 방법이 있으며, 야간에는 가시영상의 부재로 적외영상이 흔히 사용되고 있다. 적외강조영상(EIR) 분석법은 구름시스템의 중심 결정, 그에 따른 3가지 참조 T수 결정, 적합한 최종 T수 선택, 최종 T수로부터 구속조건에 따라 CI 수 결정, 지역별 변환표에 따라 태풍중심의 최대풍속과 기압 추정 등의 5단계로 구분된다. 참조 T수 (Tropical No.) 3가지는 DT 수 (Data T-No.), MET 수 (Model Expected T-No.) 및 PT 수 (Pattern T-No.)로, DT 수는 열대저기압에 동반되는 구름시스템을 구름 패턴별로 정의된 다이아그램에 따라 구조를 분석하여 결정한다. MET 수는 강도변화 모델을 기초로 과거 24시간 전과 현재

의 구름 패턴을 비교하여 예측하며, 마지막 PT 수는 정해진 구름의 패턴 분류에 의해 구름시스템을 결정한다. 최종 T수의 결정은 구름패턴의 특징에 따라 참조 T수들 중에서 선택된다. CI 수의 결정은 여러 가지 구속조건에 의해 최종 T 수로부터 결정하게 된다. CI 수가 결정되면 대서양과 태평양에 대해 구해진 MSLP (Minimum Sea Level Pressure)와 MWS (Maximum Wind Speed) 변환표로부터 태풍 중심의 최대풍속과 최저기압을 결정하는데, 발달단계에 따라 구분된 값을 찾는다. 자세한 내용은 Dvorak (1975) 등을 참조한다.

## 4. 비선형 신경망 정의 및 개념

신경망은 인간 두뇌에서 일어나는 신경 전달 과정을 모방하여 자연 현상 예측에 사용되는 알고리즘으로 모형의 개략적인 형태에 대한 추정이 불가능한 경우나 그 과정이 매우 복잡할 때 효과적으로 적용될 수 있다. 신경망은 이론적으로 복잡하지 않으면서도 자동 학습이 되는 장점을 지니고 있어 많은 분야에서 활용되고 있다. 신경망에서는 많은 가중치들 (weights)에 의하여 이루어지는 정보전달 과정과 은닉층을 이루는 노드들에 값을 저장시키는 정보 활성화 과정이 반복적으로 이루어지고 있으므로 입력에서 출력까지의 과정이 복잡하여 입력인자가 출력치에 주는 영향분석을 쉽게 파악하지 못하는 문제점이 있다. 이는 기상예측에서 인과관계를 밝힐 수 없는 단점이 있기에 적용이 꺼려지는 원인이 되기도 한다. 그러나, 이러한 점을 무시할 수 있을 정도로 예측의 결과가 타 모형보다 크게 우수하다면 신경망의 적용은 고려되어야 할 것이다. 신경망은 최종 출력 추정값들과 실제 출력값의 차이가 최소가 되도록 가중치값들을 변화시키는 역전파법으로 최적 가중치들을 결정하는 학습과정과 새로운 입력자료에 대한 출력 추정값을 구하는 인식과정으로 이루어진다. Hsieh (2004)는 신경망을 통한 비선형 다변수 시계열 분석법을 기상

학에 도입하였다. 사용된 신경망의 구조는 전방향 피드백 방식(Feedforward Neural Network)이다. 이 구조는 신경망의 정보 흐름이 입력층 (input layer) 으로부터 숨김층 (hidden layer), 출력층 (output layer)로 이동하고, 그 반대 방향의 흐름은 제한된다. 이러한 구조를 다른 말로 다층 퍼셉트론 (multilayer perceptron)이라 부른다. 숨김층은 입력층과 출력층 사이에 존재하며 정보를 전달한다. 숨김층은 네트워크가 고차 통계량 (higher-order statistics)에 대한 정보를 함축적으로 반영할 수 있는 구조를 형성한다. 본 연구에서는 비선형 회귀의 한 종류인 비선형 주성분 분석을 수행하기 위하여 Fig. 2와 같은 네트워크를 사용하였다. Fig. 2에서 숨김층은 하나만 존재하는데, 숨김층은 전이 함수 (transfer function)로 하이퍼 탄젠트 (tanh)를 이용하여 입력층 뉴런과 숨김층 뉴런을 다음과 같이 연결한다.

$$h_k = \tanh\left(\sum_i w_{ki} x_i + b_k\right) \quad (1)$$

여기서,  $w_{ki}$ 와  $b_k$ 는 각각 가중합수와 바이어스 매개 변수이다.  $\tanh(z)$  함수는  $z$ 가  $\pm\infty$ 값을 지닐 때  $\pm 1$ 을 지닌다. 이 함수는 비선형 함수로서 자료에 존재하는 비선형성을 모델링하는데 필수적인 역할을 한다. 전방향 피드백 신경망이 비선형 회귀에 사용되는 경우에는 출력 뉴런  $y_i$ 는 일반적으로 다음과 같이 숨김층 뉴런의 선형 결합으로 표현되게 된다.

$$y_i = \sum_k \tilde{w}_{jk} h_k + \tilde{b}_j \quad (2)$$

신경망 학습에 사용되는  $y_{oj}$ 가 주어지면 신경망의 실제 구조 결정에 필요한  $w_{ki}, \tilde{w}_{jk}, b_k, \tilde{b}_j$ 가 학습에 의해 결정된다. 실제 전방향 피드백 과정을 통해 계산된 출력값  $y_j$ 와 target 관측값  $y_{oj}$ 의 평균제곱 오차로 정의되는 다음과 같은 비용함수:

$$J = \left\langle \sum_j (y_i - y_j)^2 \right\rangle \quad (3)$$

를 최소화하게 된다. 여기서  $\langle \rangle$ 는 샘플 평균을 의미한다. 수행되는 최적화에 있어 충분한 갯수의 뉴런이 숨김층에 사용된다면 숨김층의 개수는 하나로 충분하다는 선행 연구가 있다 (Hornik et al., 1989). 따라서, 신경망을 이용하여 비선형 회귀를 수행할 때 층의 개수는 일반적으로 고정시키고 숨김층의 뉴런의 개수에 따른 민감도를 반드시 조사하여야 한다. 그 이유는 비선형 회귀의 경우 선형 회귀와는 달리 비용함수를 최소화하는 과정이 필요한데 그 과정에서 크게 다음의 두가지 문제점이 존재한다. 먼저 비용함수 주변의 국지적인 최소값이 존재할 가능성이 있다. 이러한 경우, 비용함수를 최소화할 때 사용되는 결합 정도법 (conjugate gradient method)이 국지 최소값으로 인하여 목표값인 광역 최소값 (global minima)에 도달하지 못하고 국지 최소값에 수렴하여 계산이 중단될 가능성이 있다. 이 문제점을 해결하기 위하여 비용함수를 최소화할 때 초기 조건의 앙상블을 이용하여 광역 최소값을 추정하는 방법이 널리 사용되며 본 연구에서는 25개의 초기 앙상블을 구성하였다. 다음 문제로는 오버피팅 (overfitting)이다. 이는 지나치게 과도한 수의 숨김 뉴런을 사용할 때 나타나는 데, 너무 많은 숨김 뉴런을 사용할 경우에 신경망은 자료에 존재하는 어떠한 형태의 변화에도 민감하게 반응하여 적응할 능력을 갖추게 된다. 따라서, 자료에 존재하는 노이즈에 피팅되는 경우를 말하며, 비선형 회귀를 사용할 때에는 반드시 뉴런의 개수에 따른 민감도 실험을 통하여 오버피팅이 일어나지 않도록 주의하여야 한다. 오버피팅이 일어나면 일반적으로 학습기간에는 훌륭한 결과를 보여주지만, 예측 혹은 실제 자료의 보정에 있어서는 매우 좋지 않은 결과를 얻을 수 있다. 본 연구에서는 이러한 오버피팅을 방지하기 위해 부트스트랩 방법을 이용하였다. 자료의 트레이닝 기간동안 전체 자료 개수 중 특정 비율만큼 자료를 랜덤하게 추출하여 여러번의 피팅을 수행하고, 이를 통해 피팅되는 곡선의 형태가 일정하게 수렴하는지를 체크한다.




Figure 1. The results of linear regression analysis by using both SDT and AODT CI indexes of typhoon events occurred in 2004. AODT CI index is used as a predictor (independent variable) and SDT CI index is used as a predictand (response variable). The regression coefficient is 0.92 and bias parameter is estimated as 0.07.




Figure 2. The schematic diagram of neural network for conducting nonlinear principal component analysis.

### 5. SDT와 AODT 선형회귀 분석결과

AODT 방법을 사용하여 산출된 CI 수와 기존의 SDT 방법을 사용하여 산출된 CI 수간의 상관관계를 조사하였으며, 이는 AODT와 SDT로부터 추정된 CI 수가 선형적으로는 어떤 연관성이 있으며 두 지수 사이의 선형적 관계를 바탕으로 한 AODT에 대한 보정 가능성을 알아보기 위함이다. 사용한 자료는 2004년

태풍분석결과로 도출된 CI 수이다. 분석 및 검증을 위하여, 2004년 자료의 맨 처음 두개 태풍인 2004년 4월 5일에 발생한 태풍 SUDAL과 2004년 5월 15일 발생한 태풍 NIDA는 분석에 포함하지 않았으며, 단지 산출된 보정식을 검증 (verification)하는데에만 사용되었다. 이는 다음 장에서 기술될 비선형 회귀 분석에서도 동일하게 적용된다. 기본적으로 2004년 자료에서는 AODT와 SDT 사이의 상관계수가 0.83으로 비교적 높게 나타났다. 따라서, 두 자료 사이에는 이미 높은 상관성이 존재함을 알 수 있다. Fig. 1은 선형회귀에서 예측인자 (predictor)로 AODT를 사용하고, 반응인자 (response)로 SDT를 사용하여 회귀식을 도출한 결과이다. 회귀식에서 기울기를 나타내는 회귀 계수는 95% 유의수준에서 0.92 (+/- 0.09)이며 y축 절편에 해당하는 바이어스는 95% 유의수준에서 0.07 (+/- 0.45)로 분석되었다. SDT와 AODT 방법은 각각 계통적 오차를 지니고 있는 지수이며 현실적으로 현 단계에서는 이들 계통적 오차를 구별해 낼 방법이 존재하지 않는다. 본 분석에서는 태평양 상에서 발생하는 태풍에 대한 보다 타당한 추정치라고 고려되는 SDT 지수를 참값으로 보고 이를 이용하여 AODT 지수에 존재하는 지역적 차이에 기반한 계통적 오차를 보정하고자 한다. 이 점은 추후, AODT 지수와 SDT 지수 사이의 계통적 오차에 대한 원인이 밝혀진다면 보다 정밀한 통계분석이 가능할 것이다. Fig. 1에서의 결과를 이용하여 선형 보정식을 추정해보면 다음과 같다.

$$LC\_AODT=0.92*AODT+0.07 \quad (4)$$

여기서, LC\_AODT는 보정된 태풍 CI 수를 의미하며, AODT는 원래의 AODT로부터 도출된 CI 수를 의미한다. Fig. 4(a)와 4(b)는 2004년 전체 태풍 CI 수중 전처리 과정을 통과한 자료들만을 이용하여 SDT와 AODT 지수 및 SDT와 위 식으로부터 선형적으로 보정된 AODT 지수를 함께 나타낸 것이다. 두 지수를 이용하여 상관 계수를 구해보면 보정되기 전

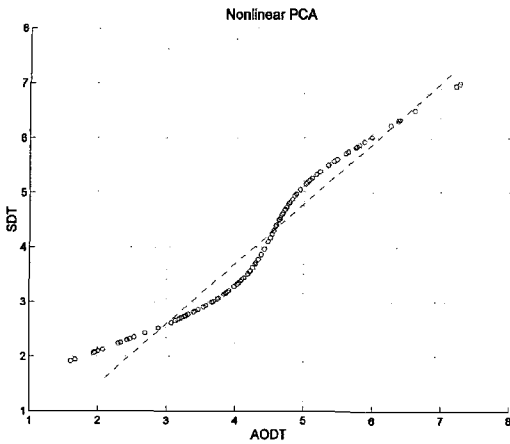


Figure 3. The result of nonlinear regression analysis. X-axis shows the input AODT CI index and Y-axis corresponds to SDT CI index. The curve connected by red circle shows the nonlinear regression curve. Blue line indicates the linear PCA result.

과 같은 상관 계수 (0.83)가 나온다. 따라서, 위의 식을 이용한 선형 보정의 경우 개선의 효과가 거의 없음을 알 수 있다. 또한, 잔차 분석등을 통한 자료의 정규성 분석에서는 SDT와 AODT사이의 비선형성이 감지되었으며 두 지수값의 차이가 클수록 오차가 커지는 경향을 보였다 (not shown). 이러한 경우는 선형 분석의 기본 가정인 오차 분산의 크기가 일정해야 함에 위배된다 (윤상운 · 이 태섭, 2005). 본 연구에서는 따라서, 비선형 방법을 통한 보정식을 개발을 시도하였다.

## 6. SDT와 AODT 비선형회귀 분석결과

Fig. 3은 Fig. 2와 같이 구축된 비선형 회귀 분석을 수행한 결과이다. 최소 제곱 오차는 숨김층의 갯수가 4개일 때 최소가 되었으므로, 4개의 숨김층을 사용한 결과를 제시하였다. 파란색 점선은 일반적인 PCA 분석에서의 첫번째 모드를 의미한다. 선형 모드의 경우와 달리 2004년 자료를 활용한 비선형 주성




Figure 4. (a) AODT CI index(dotted) and SDT CI index(solid) during the training period of 2004. (b) CI index (LC\_AODT, dotted) from linear regression analysis by using data over the training period (c) corrected CI index(NC\_AODT, dotted) by using nonlinear PCA analysis during the training period and SDT CI index (solid).

분 분석에서는 SDT와 AODT 사이에서 뚜렷한 비선형성이 감지되었다. 곡선 형태로 두 변수 사이의 관계가 결정되고 있음을 확인할 수 있다. Fig. 3에서 보면 CI 수가 약 4.5 이상 6.0 이하일 때, AODT로 도출된 CI 수가 다소 약하게 묘사하는 경향이 있고, 나머지 구간에서는 대체적으로 AODT가 다소 강한 결과를 나타냄을 알 수 있다. 이는 태풍 초기 발생 48시간 동안에는 SDT 분석 결과가 보다 낮은 CI 수를 나타냄을 의미한다. 이 결과로부터 AODT를 보정하는 식을 Fig. 3의 붉은색 점들로 구성된 커브를 다항 함수를 이용하여 커브 피팅을 수행하여 하나의 함수를 얻을 수 있다. 이 함수로부터 AODT로부터 얻어진 CI 수를 입력으로 하고 출력으로 보정된 CI 수인 NC\_AODT를 얻을 수 있다. Fig. 4 (c)는 이렇게 얻어진 NC\_AODT를 보여준다. Fig. 4 (a)와 (c)를 비교하여 볼때, 비선형 회귀 결과를 활용하여 보정된 CI 수가 SDT로부터 도출된 CI 수에 비해 더 개선되고 있음을 확인할 수 있다.

선형 회귀로부터 도출된 결과 (Fig. 4 (b))와 비교하여 볼때, 육안으로는 대동소이하나, 실제적으로 상




Figure 5. Correction result applied to two typhoon NIDA and SUDAL occurred in 2004 independent of training period. (a) and (c) shows AODT CI index (solid) and SDT CI index(dotted). (b) and (d) shows the result of corrected (solid) NC\_AODT.In each figure, RMSE(root mean square error) value is shown to quantitatively estimate the effect of correction.

관 계수는 0.86으로서 확실히 더 향상되고 있음을 알 수 있다. 다음으로 이러한 비선형 보정의 검증에 위하여 학습 기간에 사용되지 않은 NIDA와 SUDAL에 보정을 적용한 결과를 제시한다. Fig. 5의 (b)와 (d)로부터 태풍 발생 초기와 태풍 쇠퇴 단계에서 확실히 보정의 효과가 나타나고 있음을 알 수 있다. 즉, 다시 말하면 비선형 회귀를 이용한 보정의 결과, 태풍 초기에 존재하는 AODT 지수의 과도 추정 (over-estimation)과 말기에 존재하는 AODT 지수의 과소 추정 (underestimation)을 비선형 회귀 분석이 잘 보정하고 있음을 알 수 있다. 지금까지의 결과는 2004년 자료를 이용하여 도출된 결과이다. 2005년의 경우 자료 축적이 용이하지 않아 확보할 수 있는 샘플의 수가 80여개밖에 되지 않는다. 따라서, 자료 검증은 무리가 있으며, 본 연구에서는 주어진 샘플로 도출된 보정식 및 훈련기간동안의 보정 결과만을 제시한다.

## 7. 요약 및 결론

본 연구에서는 2004년과 2005년 발생한 41개 태풍에 대해 GOES-9과 MTSAT-1R 위성의 적외관측 채널 영상을 이용하여 기존의 주관적 강도분석 방법과 객관적 강도분석 방법에 의한 결과들을 비교분석하였다. AODT와 SDT로 산출된 CI 수간의 상관관계가 약 0.83으로 비교적 높은 상관관계를 보이고 있음을 알 수 있었다. AODT의 CI 수 보정을 위해 먼저 SDT의 CI 수와 선형회귀분석을 수행한 결과, 상관관계수가 약 0.83으로 비교적 높은 상관관계를 보이고 있음을 알 수 있었다. AODT의 CI 수 보정을 위해 먼저 SDT의 CI 수와 선형회귀분석을 수행한 결과, 상관관계수는 0.83으로 그 효과가 거의 없었고, 정규성 분석 등에서도 비선형이 감지되었다. 이에 향후 태풍 분석을 위한 위성자료의 지속적인 축적을 고려하여 신경망을 이용한 비선형분석을 시도하였다. Hsieh



(2004)의 신경망을 통한 비선형 다변수 시계열 분석법을 사용하여 본 연구에서 최소제곱오차가 최적으로 나타난 4개의 숨김층을 사용한 결과, 주성분의 첫 번째 모드에서도 뚜렷한 비선형성이 감지되었으며,

CI 수 약 4.5 이상 6.0 이하 구간에서 AODT의 CI 수가 다소 약하게, 나머지 구간에서는 대체로 다소 강하게 나타나는 경향을 보였다. 이는 태풍이 발생하여 초기단계를 지나 어느정도 발달한 경우에 AODT가 다소 약한 CI 결과를 도출하지만, 대부분의 구간에서 다소 강하게 모사함을 알 수 있다. 그러나, 태풍이 발달할 수록 SDT의 CI 수와 일치하고 있다. 본 연구에 사용된 자료량을 고려할 때 지속적인 자료의 축적을 통해 보다 정확한 결과를 얻을 수 있을 것으로 보인다. 또한 태풍중심 위치에 따라 AODT가 도출하는 CI 수가 민감하게 반응하였고, 기상청 자체의 정확한 태풍중심 결정에 따라 더 정확한 CI 수를 얻을 수 있을 것으로 기대된다. 그러나, AODT 개발 기관인 SSEC의 주요관심사가 대서양에서 발생하는 허리케인이며 1990년대 이후로 북서태평양에서는 비행기 관측자료를 이용한 보정도 이루어지지 않고 있는 점을 고려할 때, 기상청 자체에서 새로운 드브락강도분석기법의 객관화를 시도하고, SSEC의 AODT 및 보정된 AODT 결과와의 비교분석을 통해 보다 정확하고 개선된 태풍강도분석의 객관화가 이루어질 수 있을 것으로 기대된다.

### 참고문헌

1. 윤상운, 이태섭, 2005: 실용 회귀 분석. 자유 아카데미, p. 307.
2. Christopher S. Velden, Timothy L. Olander and Raymond M. Zehr, 1998: Development of an Objective Scheme to Estimate Tropical Cyclone Intensity from Digital Geostationary Satellite Infrared Imagery. Weather and Forecasting. Vol. 13, No. 1, pp. 172-186.
3. Dvorak, V. F., 1975: Tropical cyclone intensity analysis and forecasting from satellite imagery. Mon. Wea. Rev. 103, pp. 420-430.
4. Dvorak, V. F., 1984: Tropical cyclone intensity analysis using satellite data. NOAA Tech. Rep. NESDIS 11, National Oceanic and Atmospheric Administration, Washington, D. C., pp. 47.
5. Hornik, K., M. Stinchcombe, and H. White (1989): Multilayer feedforward networks are universal approximators, Neural Networks, 2, 359-366.
6. William W. Hsieh, 2004: Nonlinear Multivariate and Time series Analysis by Neural Network Methods. Review of Geophysics. Vol. 42, RG1003/2004.
7. Velden, Christopher S., Timothy L. Olander, and Raymond M. Zehr, 1998: Development of an objective scheme to estimate tropical cyclone intensity from digital geostationary satellite infrared imagery. Wea. Forecasting, 13, 172-186.
8. Zehr, R., (1989): Improving objective satellite estimates of tropical cyclone intensity. Extended abstracts, 18th Conf. on Hurricanes and Tropical meteorology, San Diego, CA, Amer. Meteor. Soc., J25-J28.