

한국의 봄-가을은 짧아지고 있는가?

김동현 · 신하용[†]

KAIST 산업 및 시스템 공학과

Are Spring and Fall in South Korea Getting Shorter?

Dong Hyun Kim · Hayong Shin

Department of Industrial and Systems Engineering, KAIST

A clear increase in the average annual temperature is observed worldwide, and climate changes take place in response to that increase. This affects not only the ecosystem, but also to mankind. Of all those aspects of climate change, people are especially interested in the length of each season, and people acknowledge that the duration of spring and fall has been shortened over the past several years. Still, it is difficult to observe this kind of phenomenon with the simple analysis of dividing the seasons and calculating the duration. Therefore, this study attempted to set up a more intuitive standard which well reflects the current situation. This study also divided the daily climate into 4 states using the daily maximum and minimum temperature. Moreover, using the Hidden Markov Model, this study calculated the duration of each season and analyzed its tendency based on the daily temperature data of the last 53 years (1960~2012). According to the result, the duration of spring and fall showed mild decreasing tendency over the past 53 years, and the duration of fall decreased even more during the past 30 years in the Korean peninsula. After 1960, the start of spring was advanced, which decreased the length of winter for about 11 days. On the other hand, the duration of summer increased for about 25 days, which is consistent with the worldwide tendency of temperature increase.

Keywords: Hidden Markov Model, Seasonal Change

1. 서론

1.1 연구의 배경 및 목적

전 세계적으로 뚜렷한 연평균기온의 상승이 보이는 가운데, 그에 따른 기후 변화가 진행되고 있다. 계절의 변화는 생태계 뿐만 아니라 사람들에게도 큰 영향을 미치게 되는데, 이러한 변화를 분석하고 동향을 파악하는 것은 중요하다.

많은 기후 변화에 대한 연구들은 수학적 편의를 위해 3달 간격으로 나눈 계절을 사용하고 있다. 3~5월을 봄, 6~8월을 여름, 9~11월을 가을, 12~2월을 겨울이라 정의하고 사용한다. 하지만 실제로 사람들이 느끼는 계절은 수학적 편의를 위해 나눈 계절과는 다르다. 위와 같은 기준이라면 각 계절의 지속 일은 변하지 않아야 하지만 본 연구의 사전 자료 조사로 수행

한 간단한 설문조사 결과에 따르면, 설문조사에 참여한 인원 211명 중에 약 87%가 봄과 가을이 짧아지고 있다고 생각한다고 답변을 하였고, 약 93%는 여름은 길어지고 있다고 답변하였다. 이 설문조사 결과는 사람들이 느끼는 계절은 수학적 편의로 나눈 기준과는 다른 기준이 필요함을 보여준다.

사람들이 계절을 나누는데 있어서 기온이 가장 큰 영향을 미친다. 기온은 위치와 시간에 따라 크게 변하는데 3달 간격으로 나눈 계절은 이러한 변화를 잘 반영하고 있지 않다. 이러한 이유 때문에 기존의 여러 연구에서 정량적 기준을 세우고 그에 따른 계절의 변화 동향을 분석하였지만 봄과 가을이 짧아진다는 분석은 찾아볼 수 없었다. 따라서 기준에 나와 있는 정량적 기준보다 직관적이고 현 기온변화의 동향을 잘 반영하는 기준을 세우고 그에 기초하여 히든 마르코프 모델을 통해 계

이 논문은 2013년도 정부(교육과학기술부)의 재원으로 한국연구재단-공공복지안전사업의 지원을 받아 수행된 연구임(No. 2011-0029881).

[†] 연락저자 : 신하용 교수, 305-701 대전광역시 유성구 과학로 335 KAIST 산업 및 시스템 공학과, Fax : 042-350-3110,

E-mail : hyshin@kaist.ac.kr

2013년 5월 4일 접수; 2013년 6월 12일 수정본 접수; 2013년 6월 24일 게재 확정.

절의 변화의 동향을 분석하고자 한다.

1.2 논문의 구성

본 연구는 총 6장으로 이루어져있다. 제 1장 서론에 이어 제 2장에서는 지금까지 연구되어 온 계절 변화에 대한 선행연구를 알아보고 제 3장과 제 4장에서는 은닉 마르코프 모델에 대한 설명과 이를 이용한 연구방법에 대해 설명 하였다. 은닉 마르코프 모델을 그리고 제 5장에서는 연구 결과에 대해 서술하였고 제 6장에서 결론을 지으며 마무리 하였다.

2. 선행 연구

전 세계적으로 기후 변화를 분석하기 위해 많은 연구가 진행되었다. 우리나라에서도 이러한 연구를 위해 사계절을 구분하기 위해서 일별 기온자료를 바탕으로 Lee(1979)의 연구에서는 <Table 1> 과 같이 구분하였다.

Table 1. Onset of each seasons in South Korea using daily temperature(Lee, 1979)

계절	기준
봄의 시작	최저 기온 $\geq 0^{\circ}\text{C}$ and 평균 기온 $\geq 5^{\circ}\text{C}$
여름의 시작	최고 기온 $\geq 25^{\circ}\text{C}$ and 평균 기온 $\geq 20^{\circ}\text{C}$
가을의 시작	최고 기온 $< 25^{\circ}\text{C}$ or 평균 기온 $< 20^{\circ}\text{C}$
겨울의 시작	최저 기온 $< 0^{\circ}\text{C}$ or 평균 기온 $< 5^{\circ}\text{C}$

Choi et al.(2006) 연구에서는 계절이 변할 때 일 최저, 평균, 최고 기온의 불일치성을 고려하여 Lee(1979)의 방법을 개선하여 7일간의 최저, 평균, 최고 기온 합의 이동평균(SDT)을 정의하여 <Table 2>와 같은 새로운 기준을 세웠다.

Table 2. Onset of each seasons in South Korea using temperature indices(SDT)(Choi et al., 2006)

계절	기준
봄의 시작	Last day satisfies $SDT < 15^{\circ}\text{C}$
여름의 시작	First day satisfies $SDT \geq 60^{\circ}\text{C}$
가을의 시작	Last day satisfies $SDT \geq 60^{\circ}\text{C}$
겨울의 시작	First day satisfies $SDT < 15^{\circ}\text{C}$

봄의 개시일이 빨라지고 겨울의 개시일이 늦어짐에 따라 겨울의 길이가 짧아지고 있고, 각 계절의 지속일의 변화가 뚜렷하게 나타나고 있다(Choi et al., 2006). 현재의 봄 시작은 20세기 초에 비해 같은 기준 기온을 가정하여 빨라졌다고 볼 수 있다(Yoo and Kang, 2002).

계절 지속일의 변화가 뚜렷하게 변화하고 있음을 보인 연구

는 있지만 봄과 가을의 지속일이 줄어들고 있다는 연구 결과는 아직까지 없다. 이는 아마도 단순한 분석을 통해서만 지속일의 뚜렷한 변화를 관측할만한 결과를 얻을 수 없기 때문이다.

Lee(1979)의 연구 및 Choi et al.(2006)의 연구에 나온 기준을 이용해 봄과 가을을 계산하고 지속 일을 구해보면 <Figure 1> 과 <Figure 2> 와 같은 결과를 얻을 수 있는데 각각 위 그래프는 봄의 지속 일을 표시한 그래프이고 아래 그래프는 가을의 길이를 표시한 그래프이다. 매 해 봄과 가을의 길이 모두 크게 변화는 현상이 나타나면서 회귀분석 결과 가을기는 양수이고 변동이 커서 어떤 동향을 분석하기엔 무리가 있다.

이렇게 단순한 기준을 통해서 계절을 구분한 경우에는 봄과 가을의 지속일의 변화를 유의하게 관찰하기는 어렵다. 따라서 계절 변화와 같이 직접 관찰이 불가능한 상태를 표현하고 최적의 값을 예측할 수 있는(Rabiner, 1989) 은닉 마르코프 모델(HMM; Hidden Markov Model)을 통해 분석을 해보았다.




Figure 1. Duration of spring and fall of Seoul using seasonal onset defined by Lee(1979)





Figure 2. Duration of spring and fall of Seoul using seasonal onset defined by Choi et al.(2006)

Table 3. F-test for slope in <Figure 1> and <Figure 2>

	Slope	P-value
1-Spring	0.14199	0.485
1-Fall	0.072246	0.855
2-Spring	0.23367	0.583
2-Fall	0.015965	0.999

3. 은닉 마르코프 모델(HMM)

본 논문에서는 관측된 일별 기온으로부터 계절을 추정하기 위해 은닉 마르코프 모델을 사용하였다. 은닉 마르코프 모델은 시스템의 상태 X_t 가 Markov Process를 따라 변화하지만, X_t 는 직접 관측이 되지 않고 X_t 에 종속적인 관측 값 O_t 만을 얻을 수 있는 상황을 표현하는 모델이다. HMM은 <Figure 3> 와 같이 표현할 수 있다.



State Transition Probability = $P(X_{t+1} | X_1, \dots, X_t) = P(X_{t+1} | X_t)$

Emission(Observation) Probability = $P(O_t | X_t)$

Figure 3. Basic structure of Hidden Markov Model

은닉 마르코프 모델의 미지의 모수를 추정하는 과정에는 2 가지 중요한 문제를 해결해야 한다.

- 학습(Learning) : 관측 값과 기본적인 모델의 구조에 대해서 확률을 최대화하는 모델의 모수를 예측하는 과정.
- 디코딩(Decoding) : 모델의 모수와 구조가 모두 주어진 상황에서 주어진 data를 가장 잘 설명할 수 있는 은닉 state에 대한 최우추정 과정(maximum likelihood estimation of hidden states).

기본적으로 이 두 문제에 대해서 널리 알려져 있는 Baum-Welch Learning algorithm과 Viterbi Decoding algorithm을 각각 사용하였다.

모든 마르코프 모델은 한 state에 머무르는 시간이 Transition Probability Matrix에 의해서 정해지며 기하 분포를 따르게 된다. 하지만 이것은 어떠한 현상을 분석하기에는 큰 제약조건이다. 계절을 분석하는 경우에 한 계절이 짧은 며칠 안에 끝나버린다면 실제와는 전혀 다른 상황과 원치 않는 결과를 얻게 될 것이다. 이러한 취약점을 보완해주는 방법은 여러 가지가 있지만 가장 쉬운 방법으로는 Modified Viterbi algorithm이 있다. 이 방법은 Viterbi Decoding algorithm의 백트래킹(Back-tracking)에 해당되는 부분을 개선한 알고리즘이다. 백트래킹 과정에서 한 state에 머무르는 시간을 계산하여 기준에 부합되지 않을 경우 최적의 state열을 변경해나가는 방법이다. <Figure 4>의 예제에서 머무르는 시간은 2로 지정되어있지만 일반 Viterbi algorithm을 사용할 경우, t시점에서 정해진 기간 동안 머무르지 않고 바로 다른 state로 전이되는 최적의 열을 구했다. 하지만 Modified Viterbi algorithm은 t시점에서 지속시간 2를 만족하지 못할 것을 미리 계산하여, t-1시점에도 B로 state를 지정하고 다시 알고

리즘을 진행한다.

이 방법은 간단하지만 한 state에 머무르는 시간이 길어질수록 <Figure 5>과 같이 정해진 기간을 만족시키지 못하는 모든 부분을 마지막 state와 같은 state로 만들어버리는 문제가 발생하여 원하지 않는 결과를 얻게 될 수 있다.




Figure 4. Modified Viterbi algorithm




Figure 5. Limitation of Modified Viterbi algorithm

따라서 Emission Probability Matrix를 통해 확률을 구하여 머무르는 일수를 만족하는 최적의 state열을 구하는 과정을 채택하였다. <Figure 6>에 나온 'CCAAABBB'와 같은 부분을 Short cycle이라 명명하면 이 방법은 머무르는 시간을 지키면서 Short cycle을 대체할 여러 state열중에서 가장 확률이 높은 state열을 찾고 변경하는 알고리즘으로 단순히 백트래킹에 해당되는 부분을 개선한 알고리즘보다 더 의미 있는 결과를 얻을 수 있다. 따라서 이 연구에는 Emission Probability Matrix를 사용한 Modified Viterbi algorithm을 사용하였다.




Figure 6. Modified Viterbi algorithm using Emission Probability Matrix

4. 연구 방법

본 연구에서는 우리나라 기상청에서 제공하는 1960년부터

2012년도까지 서울과 부산에서 측정된 일 최저기온, 일 최고기온을 사용하였다. 많은 연구에서 일 평균 기온을 사용하였는데, 일 평균기온은 <Figure 7>와 같이 일 최저기온과 일 최고기온의 평균과 큰 차이가 없으므로 사용하지 않았다.




Figure 7. Annual mean temperature and average of annual maximum and minimum temperature of Seoul

우리가 세우는 은닉 마르코프 모델의 기본적인 모델은 <Figure 8>과 같다. 봄, 여름, 가을, 겨울은 각각 현재 또는 다음 state로만 갈 수 있고 반대로 돌아가는 경우는 없다. 즉, 오늘이 여름이라면 내일은 여름이거나 가을일 수 있지만 다시 봄으로 돌아가거나 가을을 뛰어넘고 겨울이 될 수 없다. 각 계절에 대응하는 숫자를 부여하여 1 : 봄 2 : 여름 3 : 가을 4 : 겨울로 정의하면 Transition Probability Matrix를 다음과 같이 표현할 수 있다.

$$\text{Transition Probability Matrix} = [T_{ij}] = P(X_{t+1} = j | X_t = i)$$




Figure 8. Transition model of seasonal changes




Figure 9. Annual average temperature difference of Seoul, 1960~2012




Figure 10. Daily average temperature difference of Seoul, 1960~2012

우리가 실제로 관측 가능한 변수는 매일 매일에 해당하는 계절이 아니라 그 날의 기온이다. 그렇기 때문에 은닉 마르코프 모델을 사용하고, 일 최고기온과 최저기온을 이용하여 총 4개의 관측 구간으로 나누었다. 이 관측 구간은 설문조사(Population: 187)를 통해서 사람들이 언제 추위를 느끼고 더위를 느끼는지에 대해 조사하고 먼저 Hot, Cold 기준을 세웠다. 그리고 <Figure 10>에서 보이듯이 봄과 가을의 일교차가 여름과 겨울의 일교차에 비해 커지는 현상과 <Figure 9>에서 지난 53년간 일교차가 변하고 있음을 반영하여 Mild, Transient 기준을 세웠다. 봄, 가을이라 느끼는 계절은 일교차가 많이 나고 춥지도 덥지도 않은 날씨가다. 그리고 봄과 가을이 짧아졌다는 생각을 하는 큰 이유 중 하나는 겨울에서 봄으로 넘어가는 기간이 길어지고 봄에서 여름으로 넘어가는 기간이 짧아졌기 때문이다. 따라서 봄, 가을이라 느끼는 시기와 이 과도기적인 시기를 구분하고자 Mild와 Transient로 구분하였다.

Table 4. Classification of observation using daily temperature indices

High = 최고기온, Low = 최저기온, D = 지역평균일교차

관측분류	기준
Hot	High > 25°C and Low > 17°C
Cold	Low < 0°C
Mild	Hot, Cold 가 아닌 경우, 일교차 > D
Transient	Hot, Cold 가 아닌 경우, 일교차 ≤ D

은닉 마르코프 미지의 모수는 봄, 여름, 가을, 겨울 각각의 state가 현재 시점에서 다음 시점에 전이할 확률을 나타내는 Transition Probability Matrix와 각 state에서 위에서 정의한 4개의 분류가 관측될 확률을 나타내는 Emission Probability Matrix이다. 따라서 <Figure 8>의 전이 모델을 은닉 마르코프 모델 형태로 확장시키면 다음과 같다.




Figure 11. Hidden Markov Model for seasonal changes

은닉 마르코프 모델을 세운 다음, Baum-Welch Learning algorithm을 적용하기 위해서 두 미지의 모수에 초기 값을 부여하여야 한다. 하지만 이 알고리즘은 전역 최적을 보장하는 알고리즘이 아니기 때문에 초기 값을 아무렇게나 설정하게 되면 잘못된 결과를 얻을 수 있으므로 data를 이용하여 의미 있는 초기 값을 설정하여야 한다.

먼저 비교적 직관적인 Transition Probability Matrix의 초기 값을 구해보면, 1년은 4종류의 계절이 있다. 즉 1년 동안 총 4번, 현재 state에서 다른 state로 전이된다. 그렇기 때문에 Transition Probability Matrix의 초기 값은 다음과 같이 부여한다. 각 state에서 다시 자신의 state로 돌아오는 확률은 높고 다른 state로 전이될 확률은 낮다. 그리고 한 번에 봄에서 가을을 가는 경우, 여름에서 겨울로 가는 경우 등의 계절을 역행하거나, 뛰어넘는 경우는 없으므로 확률은 0으로 설정하였다.

$$Initial\ Transition\ Probability\ Matrix = \begin{pmatrix} 0.99 & 0.01 & 0.00 & 0.00 \\ 0.00 & 0.99 & 0.01 & 0.00 \\ 0.00 & 0.00 & 0.99 & 0.01 \\ 0.01 & 0.00 & 0.00 & 0.99 \end{pmatrix}$$

Emission Probability Matrix의 경우 Transition Probability Matrix와 같이 직관적으로 설정할 수 없다. 따라서 53년 치의 Data를 통해 <Figure 12>와 같이 일별 평균 최고 기온을 구하고 7일 이동평균을 계산하였다. <Table 4>의 기준에서 여름에는 Hot이 많이 관측 될 것이고 겨울에는 Cold가 많이 관측 될 것이다. 따라서 Hot을 만족하는 첫날을 여름의 시작으로 마지막 날을 여름의 끝으로 Cold를 만족하는 첫날을 겨울의 시작으로 마지막 날을 겨울의 끝으로 가정하여 각 계절의 시작과 끝을 계산하였다. 그 경우에 각 계절에서 다시 <Table 3>에서 분류한 4가지의 관측분류가 나타나는 확률을 계산하였다.

$$Initial\ Emission\ Probability\ Matrix = \begin{pmatrix} 0.042 & 0.243 & 0.694 & 0.022 \\ 0.000 & 0.150 & 0.141 & 0.709 \\ 0.088 & 0.264 & 0.634 & 0.014 \\ 0.736 & 0.135 & 0.129 & 0.000 \end{pmatrix}$$

<Table 3>의 기준에서 최저, 최고 기온을 모두 사용하였기 때문에 최저기온을 이용하여 구한 초기 값과 최고기온을 이용하여 구한 초기 값이 다르게 나온다. 하지만 Baum-Welch algorithm을 이용하여 학습한 후에는 같은 Emission Probability Matrix를 얻을 수 있다.




Figure 12. 7-day moving average of mean daily maximum temperature, 1960~2012

5. 연구 결과

먼저 서울의 지난 53년간 데이터를 이용하여 <Table 3>에서 세운 기준으로 분류를 하게 되면 <Figure 13>과 같이 나타낼 수 있다. 산포도의 각각 가로축과 세로축은 최저기온, 최고기온을 나타낸다. <Table 4>에서 정의한 지역 평균 일교차(D)는 서울의 경우 8.56 정도이다. 이렇게 분류한 53년간 데이터를 위에서 세운 은닉 마르코프 모델을 이용하여 분석을 해보았다. Baum-Welch Learning algorithm을 적용하여 Transition, Emission Probability Matrix를 계산하면 다음과 같다. 예를 들어, $T_{1,2} = 0.0131$ 은 '봄'에서 '여름'으로 전이될 확률을 나타내고, $E_{2,4} = 0.8366$ 은 '여름'에 'Hot'을 관측할 확률을 나타낸다.

$X_t = \text{계절분류} = \{봄, 여름, 가을, 겨울\}$

$O_t = \text{관측분류} = \{Cold, Transient, Mild, Hot\}$

$$Transition\ Probability\ Matrix = \begin{pmatrix} 0.9869 & 0.0131 & 0.0000 & 0.0000 \\ 0.0000 & 0.9884 & 0.0116 & 0.0000 \\ 0.0000 & 0.0000 & 0.9825 & 0.0175 \\ 0.0094 & 0.0000 & 0.0000 & 0.9906 \end{pmatrix}$$

$$Emission\ Probability\ Matrix = \begin{pmatrix} 0.0191 & 0.3095 & 0.6426 & 0.0288 \\ 0.0000 & 0.1302 & 0.0333 & 0.8366 \\ 0.0213 & 0.3282 & 0.6243 & 0.0262 \\ 0.7898 & 0.1558 & 0.0544 & 0.0000 \end{pmatrix}$$

Baum-Welch algorithm을 통해서 얻은 Emission, Transition Matrix와 <Table 4>와 같이 분류된 53년치의 관측치를 이용하여 Viterbi algorithm을 적용하였다. Viterbi algorithm은 주어진 data와 Probability Matrix에 대하여 maximum likely hidden state




Figure 13. Scatter plot of Min-Max temperature of Seoul

를 추정하는 동적계획법 중 하나로, 제 3장에서 제시된 최소지속일을 보장하는 Viterbi algorithm을 사용하였다. 기존 Viterbi algorithm에 대한 자세한 설명은 Rabiner *et al.*(1986)을 참고할 수 있다.

최소지속일을 보장해야 하는 이유는 이상기온이 발생했을 때, 아주 짧은 기간(ex, 1주일)을 봄-여름-가을-겨울의 한 cycle이라 판단할 가능성이 있기 때문이다. 따라서 일반적으로 한 계절이 4주, 즉 약 한 달 보다 짧아진다고 생각하지 않기 때문에 최소지속일을 28일로 정하였다. 이는 20~35일 정도의 범위에서는 같은 결과를 보여주므로, 최소지속일 28일을 보장하며




Figure 14. Duration of each season using Hidden Markov Model in Seoul, 1960~2012

주어진 관측 열이 가장 높은 확률로 관찰될 hidden state를 추정하고, 각 계절에 해당하는 hidden state의 수로 각 계절의 지속일을 유추하였다. 매 해 각 계절 지속일의 변화를 그래프로 그려보면 <Figure 14>와 같다.

이 지속일의 변화 그래프들 역시 앞에서 제시했던 <Figure 1>의 그래프와 비슷하게 매 해 크게 변하는 것 같지만 Y축의 단위가 앞의 그래프와는 다르다. 그래서 먼저 이 계수들이 얼마나 유의한지 각각 F-test를 통해서 계산을 해보았다.

Table 5. ANOVA table for spring in <Figure 14>

H0 : $\beta = 0$	SS	DF	MS	F	P-val
Regression	227.6	1	227.6	1.52	0.223
Residual	7639.1	51	149.8	slope = -0.13546	
Total	7866.7	52	Significance level = 10%		

Table 6. ANOVA table for fall in <Figure 14>

H0 : $\beta = 0$	SS	DF	MS	F	P-val
Regression	184.3	1	184.3	1.69	0.199
Residual	5552.9	51	108.9	slope = -0.12192	
Total	5737.3	52	Significance level = 10%		

Table 7. F-test for slope in <Figure 14>

	Slope	P-value
Spring	-0.13546	0.223
Summer	0.46218	<0.001
Fall	-0.12192	0.199
Winter	-0.20481	0.069

본 논문에서 제시한 HMM 방법을 통하여 얻은 봄-가을 길이의 변화에 대한 추세선은 약간 감소하는 경향을 보이기는 하지만, 이는 통계적으로 유의미한 기울기를 갖는다고 말할 수는 없다. 일반적으로 사람들이 느끼는 봄가을의 길이 변화를 조금 더 가깝게 표현할 수 있는 방법에 대해서는 추가 연구가 필요하다.

봄과 가을 같은 경우에 지난 53년간 지속일은 각각 약 7일 정도 짧아지고, 봄 개시일 역시 약 8일 정도 짧아졌다. 겨울은 11일 정도가 짧아졌지만, 반면에 여름은 약 25일 정도 늘어나면서 전 세계적인 온난화현상의 추이와 같은 결과를 보여준다.

지난 53년간 전체적인 추이는 그렇지만 그래프를 부분별로 보게 되면 해석은 달라질 수 있다. 봄의 지속일 그래프를 보면 약 1990년대까지는 감소하는 듯 하는 모습이 보이지 않다가 1990년대 이후에 감소하는 모습을 보여주고, 겨울의 경우에도 1990~2000년대까지는 점차적으로 감소하고 있지만 최근에는 다시 증가하는 듯 하는 경향을 보인다. 하지만 이러한 부분에 대해서는 추가적인 연구가 필요할 것이다.

우리나라의 수도인 서울이 우리나라를 대표한다고 할 수는 없다. 우리나라의 서울에 버금가고 지리적 특성이 다른 부산에 대해서도 계산을 해보았다. 부산의 경우 지역 평균 일교차(D)는 7.4611 정도이다. 이 경우에 지속 일을 계산하게 되면 <Figure 15>과 같이 결론을 얻을 수 있는데, 이 경우 전체적으로 서울의 경우와는 형태가 비슷하지만 계절별로 조금 다른 것을 볼 수 있다. 따라서 이 경우에도 F-test를 통해서 유의수준을 계산해보면 다음과 같다.

이 경우에는 유의수준 10%에서 여름과 겨울의 기율기만 유의하다고 말할 수 있고, 봄과 가을의 기율기에 대한 p-value는 서울의 경우에 비해서도 훨씬 크며, 따라서 이러한 자료와 기준으로는 부산의 봄-가을의 길이는 경향성을 가지고 변화하고 있다고 말할 수 없다.

이렇게 지역별로 다른 결과를 주기 때문에 모든 지역은 아니지만, 전국 8개 주요 도시(서울, 대전, 인천, 강릉, 부산, 대구, 광주, 제주)에 대해서 추가 실험을 하였다. 이 경우 똑같이 1960년도부터 2012년까지의 데이터를 사용하였고 대전의 경우 1969년도부터 측정이 시작되어 부득이하게 1969년부터 2012년까지의 데이터를 사용하였다. 전국 8개 주요 도시를 분석한 결과, 위도에 따라서 분석 결과에 차이가 나고 있음을 알 수 있었다. 위도가 높아질수록 봄과 가을의 지속일의 변화는 약간씩 줄어드는 경향을 보이고, 위도가 낮아질수록 여름과 겨울의 지속일의 변화는 더욱 뚜렷하게 나타났지만, 봄과 가을의 경우에는 그 변화를 유의미하게 해석하기는 어려웠다. 이러한 현상에 대한 자세한 분석이나 이유에 대해서는 지역을 더욱 확대하여 추가적인 연구가 필요하다.

Table 8. ANOVA table for spring in <Figure 15>

H0 : $\beta = 0$	SS	DF	MS	F	P-val
Regression	320.3	1	320.3	1.17	0.284
Residual	13953.0	51	273.6	slope = -0.1607	
Total	14273.3	52	Significance level = 10%		

Table 9. ANOVA table for fall in <Figure 15>

H0 : $\beta = 0$	SS	DF	MS	F	P-val
Regression	26.8	1	26.8	0.26	0.614
Residual	5296.7	51	103.9	slope = 0.04644	
Total	5323.5	52	Significance level = 10%		

Table 10. F-test for slope in <Figure 15>

	Slope	P-value
Spring	-0.1607	0.284
Summer	0.41405	<0.001
Fall	0.046444	0.614
Winter	-0.29979	0.037




Figure 15. Duration of each season using Hidden Markov Model in Busan, 1960~2012

6. 요약 및 결론

계절의 전환에 대한 사람들이 인지 방식은 단순하지 않다. 본 연구에서는 기존 연구에서 직접적으로 정의해서 사용하던 단순한 계절의 구분 대신 간접적으로 은닉 마르코프 모델을 이용하여 계산을 해보았다. 지난 53년간(1960~2012) 일별 최고 기온과 최저 기온을 이용하여 일별 기후를 4가지 상태로 분류하고 은닉 마르코프 모델을 통해 계절의 지속 일을 계산하고 동향을 분석하였다.

은닉 마르코프 모델을 이용하여 분석해본 서울의 봄, 가을의 지속 일은 서서히 감소하고 있고, 지난 53년간 약 7~8일 감소하였다. 하지만 통계적으로 유의미한 경향을 찾기는 어려웠다. 은닉 마르코프 모델을 이용한 계절 전환 분석 방법은 사람이 인지하는 계절의 전환에 보다 가까운 결과를 줄 수 있다는 가능성을 제시하였다. 본 연구결과에 기반하여, 사람이 계절의 변화와 그에 대한 경향을 인식하는 과정을 보다 잘 묘사하는 분석 방법과 기준을 추후 연구 과제로 남긴다.

반면 온난화 현상이 지속되면서 여름은 약 25일 증가하였고, 겨울은 약 11일 감소하였다. 이러한 각 계절의 지속일의 변화는 지역별로 다른 경향을 보인다. 위도가 높은 지역(인천, 강릉, 서울)에서는 봄, 가을, 겨울의 지속일이 조금씩이나마 줄어들고 있었지만, 그 외 지역(대전, 부산, 대구, 광주, 제주)에서

는 여름과 겨울의 변화는 더 뚜렷했지만, 봄과 가을의 지속 일의 변화를 설명할 수 없었다.

본 연구에서 밝혀낸 우리나라 계절의 변화는 추후에 장기적 기후정책이나 농, 수산업 등의 여러 사람들의 생활에 관한 연구에 기초가 될 수 있을 것이라 생각한다.

참고문헌

- Yoo, J. H. and Kang, I. S. (2002), Temperature variation related to seasonal transition and secular trend of season in Korea, *Daegi*, **12**(1), 107-110.
- Lee, B. S. (1979), A Study of Natural Seasons in Korea, *Journal of the Korean Geographical Society*, **14**(2), 1-11.
- Choi, G. Y., Kwon, W. T., and Robinson, David A. (2006), Seasonal Onset and Duration in South Korea, *Journal of the Korean Geographical Society*, **41**(4), 435-456.
- Lawrence, R. Rabiner (1989), A tutorial on hidden Markov models and selected applications in speech recognition, *Readings in Speech Recognition*, 267-296.
- Lawrence, R. Rabiner, and Juang, B.-H. (1986), An introduction to hidden Markov models, *IEEE ASSP Magazine*, **3**(1), 4-16.