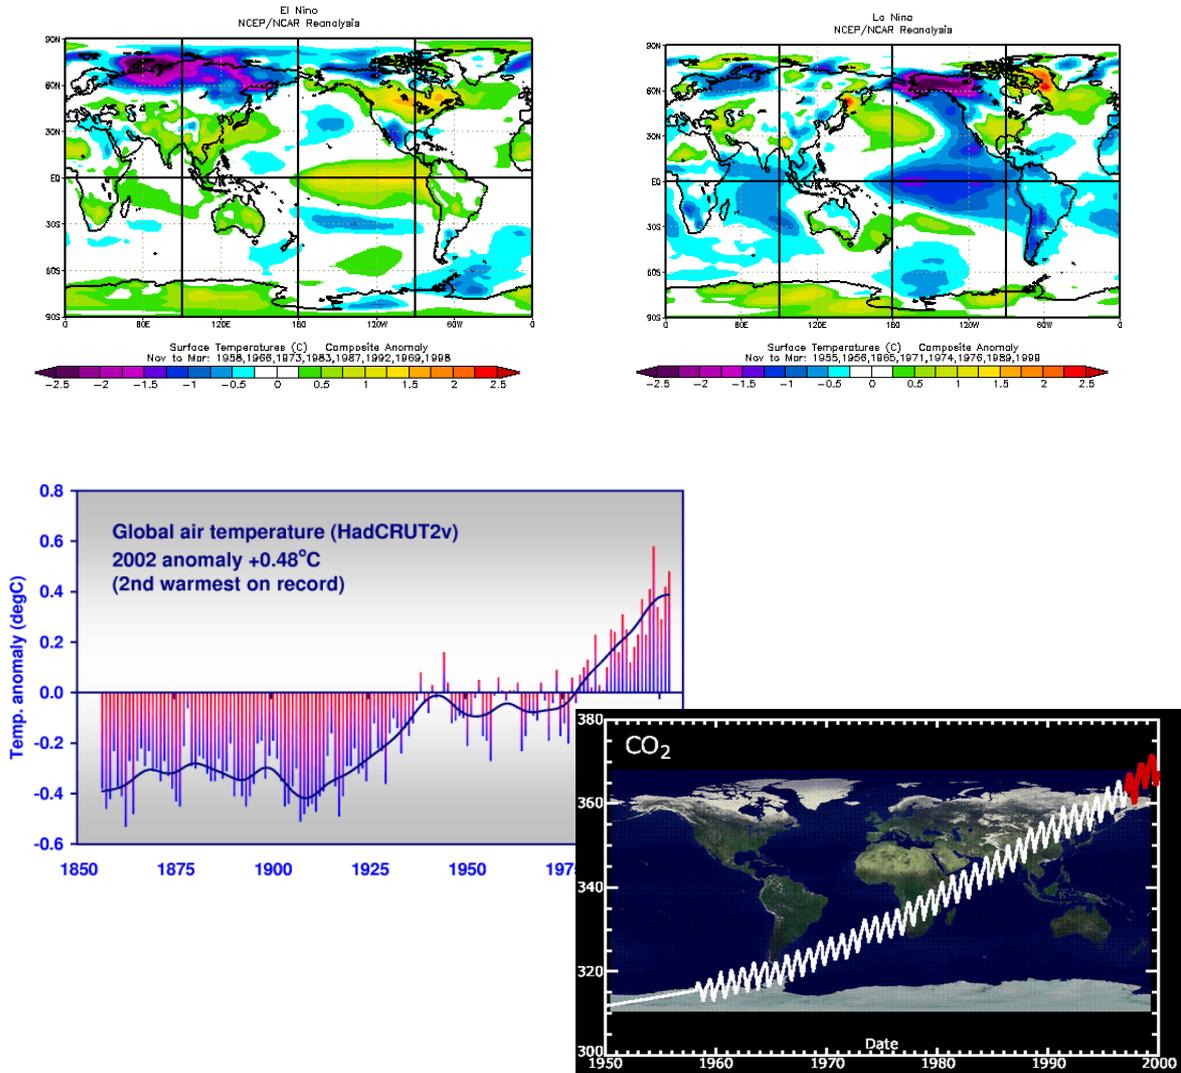


Empirical evidence for Thailand surface air temperature change : Possible causal attributions and impacts



Dr. Atsamon Limsakul

**Environmental Research and Training Center
Department of Environmental Quality Promotion**

August 2004

CONTENTS

Abstract	
บทสรุปสำหรับภาษาไทย	i
1. Introduction	1
2. Analytical methods and data sources	
2.1. <i>Basic concepts of EOF analysis</i>	5
2.2. <i>Data sources</i>	10
2.3. <i>EOF computation using the scatter matrix method</i>	13
3. Results	
3.1. <i>Physical interpretation of EOF analysis</i>	17
3.2. <i>Temporal variability of EOF1 coefficient series and its relation to ENSO signature</i>	32
3.3. <i>Linear trends in surface air temperature in Thailand</i>	51
4. Discussion	
4.1. <i>Analytical methodology</i>	54
4.2. <i>Possible causal attribution of interannual and long-term changes in surface air temperatures in Thailand</i>	55
4.3. <i>A reduction of diurnal temperature ranges</i>	58
4.4. <i>Changes in temperature extreme events</i>	58
4.5. <i>Possible biophysical and socio-economic impacts</i>	59
5. Implications for future research	62
6. Acknowledgement	63
References	64

Abstract

This study attempts to investigate the dominant spatio-temporal structure of mean, maximum and minimum surface air temperatures (T_{mean} , T_{max} , T_{min}), dewpoint temperature (T_{dew}) and computed mean, maximum and minimum apparent temperatures (T_{amean} , T_{amax} , T_{amin}) in Thailand. The atmospheric data used in this study are based on monthly data collected from 33 stations for period of 1951-2003. Empirical Orthogonal Functions (EOF) analysis and other multivariate statistical techniques were used to reveal the dominant modes and temporal patterns.

An analysis indicates that the EOF1 mode of all temperature variables accounts for substantial amount of the total variance ranging from 61.2% to 71.3%. The EOF1 mode of all temperature variables is characterized by a monopole of spatial patterns, which correlations coefficients are positive and relatively high and about the same magnitude at all stations. Such a unique pattern implies a high intercorrelation and a relatively uniform variance distribution of surface air temperatures at all stations. Hence, the EOF1 mode is a robust representative of the dominant spatio-temporal structure of surface air temperatures in Thailand that probably share a common influence from the same origins.

On the basis of the EOF results, the time variability of the EOF1 mode of all temperature variables in Thailand has oscillated at three dominant timescales over the last 53 years: interannual/decadal timescales and long-term trends. The El Niño-Southern Oscillation (ENSO) cycles are the most prominent timescale of interannual variability in surface air temperatures in Thailand. There is a significant indication that all temperature variables tend to be higher (lower) than normal during the El Niño (La Niña) years. The possible linking pathway between ENSO event and interannual changes in surface air temperature in Thailand may be through the “atmospheric teleconnections”, establishing by the shifts in the location of the organized rainfall in the tropics and the associated latent heat release.

The EOF1 coefficient series of T_{max} , T_{amax} , T_{min} and T_{amin} also exhibit salient decadal changes which are significantly related to the low-frequency component of ENSO cycles. The overall warming trends of T_{max} , T_{amax} , T_{min} and T_{amin} since the late 1970s have been in phase with the persistent and exceptionally strong warm phase of ENSO cycles. Furthermore, the EOF1 coefficient series of T_{min} and T_{amin} have monotonically increased at a faster rate than those of T_{max} and T_{amax} since the mid 1950s that resemble the greenhouse warming fingerprint observed in instrumental records and predicted by some models. At this point, however, it is unclear whether the recent changes in T_{max} , T_{amax} , T_{min} and T_{amin} are in direct response to greenhouse gas forcing, or whether these changes are associated with the natural decadal timescale variation in the atmospheric circulation. Another conspicuous feature is that there is a significant narrowing for diurnal temperature ranges over most parts of Thailand, resulting from the differential changes in maximum and minimum temperatures.

The results from this study provide a vital clue of some key aspects of short-and-long term climate change in Thailand that has important implications for future prediction and environmental management. There is little doubt that climate change is an active and critical component of “our Earth System” as current and future threats for

human and environmental systems that is now happening even on regional/local scales and will likely continue or even intensify in the near future.

บทสรุปสำหรับภาษาไทย

ความแปรปรวนหรือการเปลี่ยนแปลง เป็นสิ่งปกติที่เกิดขึ้นในระบบภูมิอากาศและสภาวะสมดุลแทบจะไม่เกิดขึ้นทุกคาบเวลา (Timescale) หรือแม้กระทั่งคาบเวลาใดเวลาหนึ่งในระบบดังกล่าว หลักฐานจาก palaeo-records ระบุชัดเจนว่า ภูมิอากาศของโลกมีการเปลี่ยนแปลงอย่างต่อเนื่องทุกคาบเวลา โดยสภาวะเฉลี่ยของโลกอยู่ภายใต้ความแปรปรวนที่สูงของระบบภูมิอากาศในระดับภูมิภาค ความแปรปรวนของอุณหภูมิอากาศ จัดว่าเป็นดัชนีที่สำคัญของการเปลี่ยนแปลงสภาพภูมิอากาศของโลกที่มีการศึกษาวิจัยกันมาก เนื่องจากอุณหภูมิมีบทบาทที่สำคัญในการควบคุมและกำหนดขบวนการระเหยและการคายน้ำของพืช ซึ่งมีการเชื่อมโยงโดยตรงกับวัฏจักรของน้ำและสมดุลของความร้อนที่พื้นผิว นอกจากนี้ การเปลี่ยนแปลงอุณหภูมิทั้งอัตรา ทิศทาง และความรุนแรงยังมีบทบาทและอิทธิพลอย่างสูงต่อหน้าที่ พลวัต และโครงสร้างของระบบนิเวศน์วิทยา ตลอดจนสุขภาพและความสะดวกสบายของมนุษย์ Intergovernmental Panel on Climate Change (IPCC) รายงานไว้ในปี ค.ศ 2001 ว่าอุณหภูมิเฉลี่ยของโลกในช่วงศตวรรษที่ 20 เพิ่มขึ้น 0.6 ± 0.2 องศาเซลเซียส และอุณหภูมิเฉลี่ยของโลกเพิ่มขึ้นสูงสุดในช่วงทศวรรษที่ 1990 IPCC ยังยืนยันด้วยว่า "มีหลักฐานที่เชื่อถือได้ว่า กิจกรรมของมนุษย์ได้มีส่วนทำให้ภูมิอากาศโลกเปลี่ยนแปลงไปอย่างมาก โดยเฉพาะอย่างยิ่งการปล่อยก๊าซเรือนกระจก ที่เกิดจากการใช้เชื้อเพลิงฟอสซิลในภูมิภาคต่างๆ ของโลกที่เพิ่มอย่างรวดเร็วในช่วงศตวรรษที่ผ่านมา" ได้มีการคาดการณ์กันว่า ในปี ค.ศ 2100 . อุณหภูมิเฉลี่ยของโลกจะสูงขึ้นประมาณ 1.4-5.8 องศาเซลเซียส ซึ่งเป็นอัตราการเพิ่มที่สูงสุดตั้งแต่สมัยสิ้นสุดยุคน้ำแข็ง (Ice Age) นอกจากนี้ยังมีหลักฐานทางวิทยาศาสตร์ที่บ่งชี้ว่า การเปลี่ยนแปลงของอุณหภูมิอากาศในระยะสั้นและระยะยาว (ปีต่อปีถึงทศวรรษต่อทศวรรษ) ในหลายภูมิภาคของโลก เช่น ทวีปอเมริกาเหนือ-ใต้ ทวีปเอเชียและทวีปแอฟริกา ยังได้รับผลกระทบจากปรากฏการณ์เอลนีโญ (El Niño-Southern Oscillation; ENSO) หรือเอลนีโญ-ความผันแปรของระบบอากาศในซีกโลกใต้ ซึ่งเป็นปรากฏการณ์ธรรมชาติระดับโลกที่เกิดจากการเชื่อมโยงระหว่างการเปลี่ยนแปลงที่ผิดปกติของอุณหภูมิผิวน้ำทะเลบริเวณเส้นศูนย์สูตรทางมหาสมุทรแปซิฟิก และความผันแปรที่ผิดปกติของระบบอากาศในซีกโลกใต้ ถึงแม้ว่าหลักฐานทางวิทยาศาสตร์บ่งชี้อย่างชัดเจนถึงการเปลี่ยนแปลงสภาพภูมิอากาศของโลก การพยากรณ์ผลกระทบที่อาจจะเกิดขึ้นในอนาคตจากการเปลี่ยนแปลงดังกล่าว ยังมีความไม่แน่นอนและมีข้อจำกัดค่อนข้างมาก ในช่วงที่ผ่านมา เนื่องจากยังขาดความรู้ความเข้าใจอย่างถ่องแท้ถึงกลไกการเชื่อมโยง ปัจจัยภายนอกที่บังคับ (Forcings) การตอบสนอง (Responses) และผลที่ตามมา (Consequences) ของการเปลี่ยนแปลงสภาพภูมิอากาศของโลก ดังนั้น การศึกษาวิจัยเรื่องการเปลี่ยนแปลงของอุณหภูมิอากาศ โดยเฉพาะอย่างยิ่งการเปลี่ยนแปลงในระดับภูมิภาค เป็นประเด็นที่ท้าทายและได้รับความสนใจจากนักวิทยาศาสตร์เป็นจำนวนมาก รวมทั้งเป็นวัตถุประสงค์หลักของโครงการวิจัยการเปลี่ยนแปลงของโลก (Global Change Research) สำหรับประเทศไทย ประเด็นดังกล่าวยังไม่ค่อยได้รับความสนใจและมีการศึกษานัก รวมทั้งไม่มีหลักฐานที่แน่ชัดของการเปลี่ยนแปลงอุณหภูมิอากาศทั้งระยะสั้นและระยะยาว ตลอดจนกระทบที่อาจจะเกิดขึ้น

ดังนั้น การศึกษานี้มีวัตถุประสงค์หลัก เพื่อศึกษา 1) รูปแบบความแปรปรวนในเชิงพื้นที่และเชิงเวลาที่มีลักษณะโดดเด่นของอุณหภูมิอากาศในประเทศไทย 2) กลไกการเชื่อมโยงทั้งในระยะสั้นและระยะยาวระหว่างความแปรปรวนดังกล่าวกับพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศของโลก หรือความผันแปรของสภาพภูมิอากาศที่เกิดจากกิจกรรมของมนุษย์ 3) ผลกระทบที่อาจจะเกิดขึ้นต่อสภาพแวดล้อม นิเวศน์วิทยา สภาพเศรษฐกิจและสังคมรวมทั้งสุขภาพอนามัยและความเป็นอยู่ของมนุษย์ ข้อมูลที่นำมาวิเคราะห์ทางสถิติในเชิงลึก ได้แก่

ข้อมูลรายเดือนของอุณหภูมิอากาศเฉลี่ย สูงสุด และต่ำสุด (T_{mean} , T_{max} , T_{min}) และอุณหภูมิจุดน้ำค้าง (T_{dew}) จากกรมอุตุนิยมวิทยา จำนวน 33 สถานี ซึ่งครอบคลุมทั่วทุกภาคของประเทศไทย ในระหว่างปี ค.ศ. 1951-2003 ตลอดจนอุณหภูมิปรากฏ (Apparent Temperature) เฉลี่ย สูงสุด และต่ำสุด (T_{amean} , T_{amax} , T_{amin}) ซึ่งคำนวณจากข้อมูลอุณหภูมิอากาศและอุณหภูมิจุดน้ำค้างดังกล่าวข้างต้น เทคนิคทางสถิติที่ใช้ในการวิเคราะห์ข้อมูล ประกอบด้วย Empirical Orthogonal Functions (EOFs), ค่าเฉลี่ยแบบเคลื่อนที่ (Moving Average), การวิเคราะห์ความแปรปรวน (Variance Analysis), การวิเคราะห์สหสัมพันธ์ (Correlation Analysis), และการวิเคราะห์การถดถอยแบบเชิงเส้น (Linear Regression Analysis) EOFs นับว่าเป็นเทคนิคทางสถิติเชิงตัวแปรพหุ (Multivariate) ที่นิยมใช้กันอย่างแพร่หลาย ในการวิเคราะห์ความแปรปรวนเชิงพื้นที่และเชิงเวลาของชุดข้อมูลที่มีขนาดใหญ่ โดยเฉพาะอย่างยิ่งตัวแปรที่เกี่ยวกับภูมิอากาศ บรรยากาศและมหาสมุทร ที่มีจุดเก็บตัวอย่างเป็นจำนวนมาก ความถี่ในการเก็บตัวอย่างสูงรวมทั้งระยะเวลาในการเก็บข้อมูลที่ยาวนาน ซึ่งทำให้มีชุดข้อมูลในเชิงพื้นที่และเชิงเวลาเป็นจำนวนมากยากต่อการจัดการและวิเคราะห์โดยใช้เทคนิคอื่น ๆ ในกรณีข้อมูลอุณหภูมิอากาศในประเทศไทย ที่ทำการตรวจวัดทุกเดือนตลอดระยะเวลา 53 ปี ณ 33 สถานี จัดว่าเป็นชุดข้อมูลที่ค่อนข้างใหญ่ เนื่องจากมีจำนวนข้อมูลทั้งหมดเท่ากับ 20998 ชุดข้อมูล

ระเบียบวิธีของเทคนิค EOFs อาศัยหลักการของการแปลงเชิงเส้นตรงของชุดข้อมูลเดิมที่มีขนาดใหญ่และมีตัวแปรจำนวนมาก ไปสู่ชุดขนาดเล็กของตัวแปรแต่เป็นตัวแทนความแปรปรวนทั้งเชิงพื้นที่และเชิงเวลาส่วนใหญ่ของชุดข้อมูลเดิม โดยทั่วไปวิธีการวิเคราะห์ EOFs จะคำนวณจากเมตริกซ์ความแปรปรวนร่วม (Covariance Matrix) หรือเมตริกซ์ความสัมพันธ์ร่วม (Correlation Matrix) ของข้อมูล เพื่อจำแนกข้อมูลเดิมออกเป็นค่า Eigenvalue, Eigenvector และอนุกรม Time Coefficient (TC) โดย Eigenvector คือชุดขนาดเล็กของตัวแปรที่ถูกแปลงมาจากชุดข้อมูลเดิม ซึ่งแต่ละชุดของ Eigenvector เรียกว่า EOF โหมด (EOF Mode) และจำนวน EOF โหมดทั้งหมดจะเท่ากับจำนวนตัวแปรในชุดข้อมูลเดิม สำหรับค่า Eigenvalue โดยปกติจะเรียงลำดับจากมากไปหาน้อยและแต่ละค่าของ Eigenvalue จะเป็นสัดส่วนกับเปอร์เซ็นต์ของความแปรปรวนในข้อมูลเดิมที่อธิบายได้จากแต่ละ EOF โหมด ทั้งนี้การเปลี่ยนแปลงเชิงเวลาหรืออนุกรม TC ของแต่ละชุดของ Eigenvector สามารถคำนวณได้จากผลรวมทั้งหมดของข้อมูลเดิมฉาย (Projection) บนแต่ละชุดของ Eigenvector หรือแต่ละ EOF โหมด ในแต่ละชุดของ Eigenvector หรือแต่ละ EOF โหมด มีคุณสมบัติพิเศษคือ เป็นอิสระหรือตั้งฉากต่อกัน (Orthogonality) ในเชิงพื้นที่ เช่นเดียวกับอนุกรม TC ของแต่ละ EOF โหมดมีคุณสมบัติเป็นอิสระหรือตั้งฉากต่อกันในเชิงเวลา จากคุณสมบัติดังกล่าว ความแปรปรวนในข้อมูลเดิมที่อธิบายได้จากแต่ละ EOF โหมด มีคุณสมบัติที่เป็นอิสระต่อกัน ดังนั้น ผลรวมทั้งหมดของความแปรปรวนที่อธิบายได้จากทุก EOF โหมด จะเท่ากับผลรวมทั้งหมดของความแปรปรวนในข้อมูลเดิม โดยปกติ EOF โหมดแรก ๆ เท่านั้น จะอธิบายความแปรปรวนส่วนใหญ่ในข้อมูลเดิม ดังนั้น ชุดข้อมูลใหม่ที่มีความแปรปรวนใกล้เคียงกับความแปรปรวนในข้อมูลเดิม แต่มีจำนวนตัวแปรน้อยกว่ามากเมื่อเปรียบเทียบกับข้อมูลเดิม สามารถสังเคราะห์ได้จากผลรวมของอนุกรม TC คูณด้วย EOF โหมดในโหมดแรก ๆ เท่านั้น

ผลลัพธ์ของการวิเคราะห์ EOFs ประกอบด้วย 1) ค่า Eigenvalue รวมทั้งเปอร์เซ็นต์ของความแปรปรวนที่อธิบายได้จากแต่ละ EOF โหมด 2) ชุดของ Eigenvector สำหรับแต่ละ EOF โหมด โดยแต่ละชุดของ Eigenvector ประกอบด้วยค่าที่เรียกว่า Component Loading ซึ่งปกติจะแสดงในรูปค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) และเป็นค่าที่บ่งชี้ถึงอำนาจความสัมพันธ์ของอนุกรมข้อมูลในแต่ละสถานีหรือจุดของข้อมูลเดิมใน EOF โหมดที่ถูกแยกออกมา และ 3) อนุกรม TC ซึ่งแสดงการเปลี่ยนแปลงเชิงเวลาของแต่ละ EOF โหมด

ผลการวิเคราะห์ EOFs สำหรับข้อมูลอุณหภูมิอากาศในประเทศไทยในระหว่างปี ค.ศ. 1951-2003 ปรากฏว่า EOF โหมดที่ 1 ของอุณหภูมิอากาศทั้งเจ็ดตัวแปร (T_{mean} , T_{max} , T_{min} , T_{dew} , T_{amean} , T_{amax} และ T_{amin}) สามารถอธิบายความแปรปรวนในข้อมูลเดิมได้ถึงร้อยละ 61.2 % ถึง 71.3% สำหรับ EOF โหมดที่เหลือ สามารถอธิบายความแปรปรวนของข้อมูลเดิมได้น้อยมากเมื่อเปรียบเทียบกับ EOF โหมดที่ 1 และร้อยละของความแปรปรวนที่อธิบายได้ในแต่ละ EOF โหมดมีค่าใกล้เคียงกัน จากลักษณะดังกล่าว แสดงว่าความแปรปรวนโดยส่วนใหญ่ของข้อมูลเดิมสามารถอธิบายได้จาก EOF โหมดที่ 1 ส่วนความแปรปรวนที่เหลือส่วนน้อยที่ถูกแยกตามสัดส่วนใน EOF โหมดที่เหลืออาจจะเกิดจาก “noise” หรือความแปรปรวนปลีกย่อยของแต่ละสถานีในข้อมูลเดิม สำหรับแต่ละตัวแปรของอุณหภูมิอากาศ Component Loading ซึ่งแสดงในรูปของค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างชุดข้อมูลในแต่ละสถานีกับ EOF โหมดที่ 1 มีค่าที่สูงและใกล้เคียงกันเกือบทุกสถานี ยกเว้นบางสถานีในภาคใต้ตอนล่างที่มีค่าค่อนข้างต่ำ นอกจากนี้ ชุดข้อมูลทุกสถานีมีความสัมพันธ์ทางสถิติในเชิงบวกอย่างมีนัยสำคัญกับ EOF โหมดที่ 1 จากผลดังกล่าวสามารถสรุปได้ว่า ความสัมพันธ์ของอุณหภูมิอากาศระหว่างสถานีมีค่าสูงและความแปรปรวนของอุณหภูมิอากาศทุกสถานีมีการกระจายตัวค่อนข้างสม่ำเสมอ ดังนั้น ความแปรปรวนเชิงพื้นที่ที่อธิบายได้จาก EOF โหมดที่ 1 ไม่ได้เกิดจากความแปรปรวนของข้อมูลอุณหภูมิอากาศเฉพาะสถานีใดสถานีหนึ่งหรือภาคใดภาคหนึ่งเท่านั้น แต่เกิดจากความแปรปรวนของข้อมูลอุณหภูมิอากาศเกือบทุกสถานีร่วมกัน โดยความแปรปรวนดังกล่าว อาจเกิดจากปรากฏการณ์หรือแหล่งกำเนิดเดียวกัน ที่มีขนาดใหญ่เพียงพอที่จะสามารถมีอิทธิพลต่ออุณหภูมิอากาศทั่วทุกภาคของประเทศไทย ดังนั้น เพียง EOF โหมดที่ 1 สามารถใช้เป็นตัวแทนที่เหมาะสม เพื่อนำไปอธิบายการเปลี่ยนแปลงเชิงพื้นที่และเชิงเวลาของอุณหภูมิอากาศในประเทศไทยโดยส่วนใหญ่และภาพรวมได้

การเปลี่ยนแปลงในเชิงเวลาของ EOF โหมดที่ 1 ดังแสดงในอนุกรม TC จากการสังเกต พบว่า EOF โหมดที่ 1 ของอุณหภูมิอากาศทั้งเจ็ดตัวแปร มีลักษณะการเปลี่ยนแปลงในเชิงเวลาที่ค่อนข้างซับซ้อน ระยะเวลาของการแกว่งไปมาระหว่างค่าสูงสุดและค่าต่ำสุดไม่แน่นอนและไม่สม่ำเสมอ โดยที่การเปลี่ยนแปลงคาบเดือนต่อเดือนหรือการเปลี่ยนแปลงที่ความถี่สูงปรากฏโดดเด่นใน TC นอกจากนี้ การเปลี่ยนแปลงที่ความถี่ปานกลางถึงต่ำ คือตั้งแต่ 2-3 ปี ถึงคาบ 10 ปี ยังเป็นองค์ประกอบสำคัญของการเปลี่ยนแปลงใน TC อีกด้วย เนื่องจาก TC คือ การเปลี่ยนแปลงในเชิงเวลาของ EOF โหมดที่ 1 โดยภาพรวม ซึ่งประกอบด้วยคาบการเปลี่ยนแปลงของทุกคาบเวลารวมกัน ดังนั้นจึงไม่สามารถระบุได้ชัดเจนว่า EOF โหมดที่ 1 มีลักษณะการเปลี่ยนแปลงที่ชัดเจนหรือโดดเด่นในช่วงคาบเวลาใดบ้าง นอกจากนี้ การหาความสัมพันธ์หรือการเชื่อมโยงของ EOF โหมดที่ 1 กับความผันแปรของสภาพภูมิอากาศของโลกทั้งในระยะสั้นหรือระยะยาว อนุกรม TC ดังกล่าวควรที่จะถูกจำแนกออกเป็น ช่วงคาบเวลาของการเปลี่ยนแปลงที่ใกล้เคียงหรือสอดคล้องกับคาบเวลาที่โดดเด่นของความผันแปรของสภาพภูมิอากาศของโลก ด้วยเหตุผลดังกล่าว อนุกรม TC จึงถูกจำแนกออกเป็นสองคาบเวลาของการเปลี่ยนแปลง คือ น้อยกว่า 5 ปีและมากกว่า 5 ปี สาเหตุที่เลือกสองคาบเวลาดังกล่าว เพราะคาบเวลาที่น้อยกว่า 5 ปี แทนการเปลี่ยนแปลงระยะสั้นที่สอดคล้องกับวงจรของปรากฏการณ์เอนโซ (El Niño-Southern Oscillation; ENSO) หรือเอลนีโญ-ความผันแปรของระบบอากาศในซีกโลกใต้ ซึ่งวงจรการเกิดแต่ละครั้งจะมีช่วงระยะเวลาประมาณ 2 ถึง 6 ปี ปรากฏการณ์เอนโซเป็นปรากฏการณ์ทางธรรมชาติของความแปรปรวนของสภาพภูมิอากาศของโลก ที่เกิดจากการเชื่อมโยงระหว่างการเปลี่ยนแปลงที่ผิดปกติของอุณหภูมิผิวน้ำทะเลบริเวณเส้นศูนย์สูตรทางมหาสมุทรแปซิฟิก และความผันแปรที่ผิดปกติของระบบอากาศในซีกโลกใต้ เป็นที่ทราบกันดีว่าปรากฏการณ์เอนโซมีผลกระทบต่อสภาพภูมิอากาศ และสภาพแวดล้อมของโลกทั้งพื้นที่ใกล้เคียงและพื้นที่ห่างไกลในหลายทวีป โดยเฉพาะประเทศในเขตร้อน (Tropical) และกึ่งร้อน (Subtropical) ส่วนคาบเวลาที่มากกว่า 5 ปี แทน

การเปลี่ยนแปลงในระยะยาว (ทศวรรษต่อทศวรรษ) ที่อาจจะมีความสัมพันธ์หรือเชื่อมโยงกับการเปลี่ยนแปลงภูมิอากาศของโลกที่เกิดจากกิจกรรมมนุษย์ เช่น การเพิ่มขึ้นของปริมาณก๊าซเรือนกระจกหรือเกิดจากปรากฏการณ์ทางธรรมชาติอื่น ๆ เทคนิคที่ใช้ในการแยกคาบเวลาของการเปลี่ยนแปลงของอนุกรม TC คือ ค่าเฉลี่ยแบบเคลื่อนที่ (Moving Average) โดยใช้ 60 เดือน อนุกรมเวลา สำหรับคาบเวลาที่มากกว่า 5 ปี ส่วนการหาค่าเฉลี่ยแบบเคลื่อนที่ที่น้อยกว่า 5 ปี ทำได้โดยนำค่าเฉลี่ยแบบเคลื่อนที่ที่มากกว่า 5 ปี ลบด้วย อนุกรม TC เดิม ซึ่งจะได้ผลลัพธ์คือ ค่าผิดปกติ (anomalies) ของอนุกรม TC จากอนุกรมของค่าเฉลี่ยแบบเคลื่อนที่ที่มากกว่า 5 ปี หลังจากนั้นนำค่าผิดปกติดังกล่าวไปคำนวณหาค่าเฉลี่ยแบบเคลื่อนที่โดยใช้ 10 เดือน อนุกรมเวลา

จากผลการวิเคราะห์เพิ่มเติม ปรากฏว่า อนุกรมของ TC ของอุณหภูมิอากาศทั้งเจ็ดตัวแปรสำหรับค่าเฉลี่ยแบบเคลื่อนที่ที่น้อยกว่า 5 ปี แสดงการเปลี่ยนแปลงในระยะสั้นที่ชัดเจน โดยระยะเวลาการแกว่งไปมาระหว่างค่าสูงสุดและค่าต่ำสุดซึ่งอยู่ในช่วงประมาณ 1 ถึง 4 ปี เป็นลักษณะเด่นของอนุกรมดังกล่าว ผลการวิเคราะห์ความแปรปรวน (Variance Analysis) แสดงให้เห็นว่าการเปลี่ยนแปลงที่น้อยกว่า 5 ปีของอุณหภูมิอากาศทั้งเจ็ดตัวแปร มีเปอร์เซ็นต์ความแปรปรวนอยู่ในช่วงของ 17.6 ถึง 25.8 % ของความแปรปรวนทั้งหมดของอนุกรม TC โดยเปอร์เซ็นต์ความแปรปรวนของอุณหภูมิอากาศทั้งเจ็ดตัวแปร ยกเว้น T_{min} เป็นอันดับสองของความแปรปรวนทั้งหมดของอนุกรม TC รวมกัน ลักษณะโดดเด่นอีกอย่างหนึ่งของอนุกรมค่าเฉลี่ยแบบเคลื่อนที่ที่น้อยกว่า 5 ปีของ TC คือ รูปแบบการเปลี่ยนแปลงมีลักษณะคล้ายกับดัชนีของปรากฏการณ์เอลนีโญ (Multiple ENSO Index) โดยที่ค่าผิดปกติบวก (ลบ) ของอนุกรม TC ~~ลักษณะเคลื่อนที่ที่น้อยกว่า~~ 5 ปี ตรงกับหรือสอดคล้องกับปรากฏการณ์เอลนีโญ (ลานีญา) โดยพบว่า อุณหภูมิอากาศในประเทศไทย สูง (ต่ำ) กว่าปกติ ในระหว่างที่เกิดเหตุการณ์เอลนีโญ (ลานีญา) เช่น ในระหว่าง 6 ครั้งที่เกิดปรากฏการณ์เอลนีโญที่มีกำลังรุนแรงที่สุดในรอบ 53 ปี อุณหภูมิอากาศในประเทศไทยสูงกว่าปกติอย่างเด่นชัด เช่นเดียวกับอุณหภูมิอากาศในประเทศไทยต่ำกว่าปกติอย่างชัดเจนในระหว่าง 8 ครั้งที่เกิดปรากฏการณ์ลานีญาที่มีกำลังรุนแรงที่สุดในรอบ 53 ปี นอกจากนี้ ในระหว่าง ค.ศ. 1998-1998 อุณหภูมิอากาศในประเทศไทยได้มีการแกว่งอยู่ในช่วงที่กว้างที่สุดในรอบ 53 ปี ซึ่งสอดคล้องกับการเกิดปรากฏการณ์เอลนีโญและลานีญาที่มีกำลังรุนแรงอย่างต่อเนื่องภายในช่วงสองปีดังกล่าว โดยปี ค.ศ. 1998 เป็นปีที่ร้อนที่สุดในประเทศไทยในรอบ 53 ปี ผลการวิเคราะห์สหสัมพันธ์ (Correlation Analysis) ยืนยันเพิ่มเติมว่า อุณหภูมิอากาศทั้งเจ็ดตัวแปร มีความสัมพันธ์ทางสถิติในเชิงบวกอย่างมีนัยสำคัญกับดัชนีของปรากฏการณ์เอลนีโญ โดยเฉพาะอย่างยิ่ง T_{mean} , T_{max} , T_{amean} และ T_{amax} ที่มีค่าสัมประสิทธิ์สหสัมพันธ์ค่อนข้างสูง (มากกว่า 0.5) ผลการศึกษานี้แสดงให้เห็นว่าปรากฏการณ์เอลนีโญเป็นปัจจัยที่สำคัญที่มีผลกระทบต่อเปลี่ยนแปลงของอุณหภูมิอากาศในประเทศไทยในระยะสั้น และอาจสันนิษฐานได้ว่า ผลกระทบของปรากฏการณ์เอลนีโญต่อการเปลี่ยนแปลงปีต่อปีของอุณหภูมิอากาศในประเทศไทย น่าจะมาจากสาเหตุของการแผ่ขยายกว้างไกลออกไปของปริมาณความร้อน ที่เกิดจากความผิดปกติของอุณหภูมิผิวน้ำทะเล และการเคลื่อนตัวของแอ่งน้ำอุ่นในบริเวณเส้นศูนย์สูตรทางมหาสมุทรแปซิฟิก โดยกลไกการเชื่อมโยงน่าจะผ่านทาง “Atmospheric Teleconnections” นอกจากนี้ ความผันแปรของระบบอากาศโดยเฉพาะอย่างยิ่งการหมุนเวียนของอากาศแบบวอล์กเกอร์ (Walker Circulation) ที่เกิดจากการเสียดสมดุของการแลกเปลี่ยนความร้อนระหว่างบรรยากาศและทะเล น่าจะเป็นปัจจัยเสริมในการนำพาความร้อนออกจากบริเวณเส้นศูนย์สูตรของมหาสมุทรแปซิฟิกมาสู่ประเทศไทย

นอกจากนี้ การเปลี่ยนแปลงในระยะยาว (ทศวรรษต่อทศวรรษ) ยังปรากฏชัดเจนในอนุกรมค่าเฉลี่ยแบบเคลื่อนที่ที่มากกว่า 5 ปีของ TC ของ T_{max} , T_{amax} , T_{min} และ T_{amin} โดยอุณหภูมิอากาศทั้งสี่ตัวแปรนี้มีแนวโน้มเพิ่มขึ้น

เรื่อย ๆ หลังจากปลายทศวรรษที่ 1970 ซึ่งรูปแบบการเปลี่ยนแปลงดังกล่าวสอดคล้องกับช่วงเวลาที่พฤติกรรมของปรากฏการณ์เอนโซมีแนวโน้มผิดปกติในคาบเวลาที่ยาวนานมากกว่า 10 ปี โคષปรากฏการณ์เอลนีโญเกิดขึ้นเป็นระยะเวลาที่ยาวนานและบ่อยครั้งกว่าปกติรวมทั้งมีกำลังปานถึงรุนแรง ซึ่งรู้จักกันในนาม “Climatic Regime Shift” แต่ปรากฏการณ์ลานีญาแทบจะไม่เกิดขึ้นหรือเกิดขึ้นน้อยมากเมื่อเปรียบเทียบกับปรากฏการณ์เอลนีโญ หลังจากปลายทศวรรษที่ 1970 ผลการวิเคราะห์สหสัมพันธ์ ยังสนับสนุนความสอดคล้องดังกล่าวข้างต้น โดยพบว่าอนุกรมค่าเฉลี่ยแบบเคลื่อนที่ที่มากกว่า 5 ปี ของ TC ของอุณหภูมิอากาศทั้งสี่ตัวแปรมีความสัมพันธ์ทางสถิติในเชิงบวกอย่างมีนัยสำคัญกับดัชนีของปรากฏการณ์เอนโซ เช่นเดียวกับที่พบในการเปลี่ยนแปลงระยะสั้นข้างต้น ภายหลังจากปี ค.ศ. 1990 เป็นช่วงทศวรรษที่อุณหภูมิอากาศในประเทศไทยสูงที่สุดในรอบ 53 ปี ซึ่งสอดคล้องกับอุณหภูมิเฉลี่ยของโลกที่สูงกว่าค่าปกติมากในช่วงเวลาเดียวกัน ผลการศึกษานี้ แสดงให้เห็นว่าปรากฏการณ์เอนโซ อาจจะมีอิทธิพลต่อการเปลี่ยนแปลงของอุณหภูมิอากาศในประเทศไทยในระยะยาวอีกด้วย นอกจากการเปลี่ยนแปลงของอุณหภูมิอากาศในประเทศไทยที่สอดคล้องกับปรากฏการณ์เอนโซแล้ว ยังพบว่า T_{min} และ T_{amin} มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในลักษณะเชิงเส้นตรงตั้งแต่กลางทศวรรษที่ 1950 และอัตราการเพิ่มขึ้นที่รวดเร็วและมากกว่า T_{max} และ T_{amax} รูปแบบการเพิ่มขึ้นอย่างต่อเนื่องของ T_{min} และ T_{amin} ดังกล่าว มีลักษณะเหมือนกับอุณหภูมิเฉลี่ยผิวพื้นโลกที่เพิ่มสูงขึ้นในศตวรรษที่ 20 จากการเพิ่มขึ้นของปริมาณก๊าซเรือนกระจกผลสืบเนื่องมาจากกิจกรรมมนุษย์ ซึ่งรู้จักกันในนามสภาวะโลกร้อน (Global Warming) จากการเปรียบเทียบ พบว่า การเพิ่มขึ้นของ T_{min} และ T_{amin} ในประเทศไทย มีอัตราที่รวดเร็วและมากกว่าอุณหภูมิเฉลี่ยผิวพื้นโลก ดังนั้น การเพิ่มขึ้นของ T_{min} และ T_{amin} ในประเทศไทย น่าจะมีส่วนส่งเสริมในแง่บวกที่ส่งผลให้อุณหภูมิเฉลี่ยผิวพื้นของซีกโลกเหนือรวมทั้งสภาวะโลกร้อนเพิ่มสูงขึ้น ถึงแม้การเปลี่ยนแปลงในระยะยาวของอุณหภูมิอากาศในประเทศไทยซึ่งมีความสัมพันธ์กับปรากฏการณ์เอนโซ และมีลักษณะที่คล้ายคลึงกับสภาวะโลกร้อนอันเนื่องมาจากการเพิ่มขึ้นของก๊าซเรือนกระจก ปรากฏชัดแจ้งจากผลการศึกษาในปัจจุบันหลักที่ก่อให้เกิดการเปลี่ยนแปลงดังกล่าว ยังไม่สามารถแยกแยะหรือสรุปได้ชัดเจน ว่าเกิดจากพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศ เช่น ปรากฏการณ์เอนโซ หรือผลกระทบโดยตรงจากความผันแปรของสภาพภูมิอากาศที่เกิดจากกิจกรรมของมนุษย์ โดยทั่วไป อาจจะเข้าใจว่า การเปลี่ยนแปลงที่เกิดจากความผิดปกติของพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศ น่าจะมีรูปแบบหรือลักษณะในเชิงพื้นที่และเชิงเวลาที่แตกต่างจากการเปลี่ยนแปลงที่เกิดจากกิจกรรมมนุษย์ แต่เมื่อพิจารณาถึงพฤติกรรมของระบบภูมิอากาศ ที่มีรูปแบบกลไกการเชื่อมโยงที่ซับซ้อนและการตอบสนองต่อปัจจัยภายนอกไม่เป็นในลักษณะเชิงเส้นตรง (Nonlinear) ซึ่งสามารถเปรียบเทียบได้กับคำพังเพยที่ว่า “1 บวก 1 ไม่เท่ากับ 2” นักวิทยาศาสตร์หลายท่าน ได้เสนอแนะไว้ว่าสภาวะโลกร้อนในช่วงไม่กี่ทศวรรษที่ผ่านมา อาจเกิดจากพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศ ที่มีแนวโน้มผิดปกติทั้งในแง่ จำนวนครั้งที่เกิดขึ้น ทิศทาง ระยะเวลาและความรุนแรง โดยมีผลกระทบจากการเพิ่มขึ้นของปริมาณก๊าซเรือนกระจก มากกว่าผลกระทบโดยตรงจากปรากฏการณ์เรือนกระจก ตัวอย่างที่เห็นได้ชัดเจน ได้แก่ พฤติกรรมของปรากฏการณ์เอนโซที่มีแนวโน้มผิดปกติในคาบเวลาที่ยาวนานหลังจากปลายทศวรรษที่ 1970 ผลการศึกษาโดยใช้แบบจำลองทางคณิตศาสตร์ ยังระบุว่า การเพิ่มขึ้นของปริมาณก๊าซเรือนกระจกจะทำให้สภาวะเหมือนกับปรากฏการณ์เอลนีโญ (El Niño-like) เกิดขึ้นบ่อยและระยะเวลาที่นานขึ้นในอนาคต ดังนั้น ปัจจัยที่มีผลต่อการเปลี่ยนแปลงอุณหภูมิอากาศในประเทศไทยในระยะยาว จึงเป็นประเด็นที่ท้าทายที่ต้องศึกษาในรายละเอียดต่อไป เพื่ออธิบาย และสามารถแยกสัญญาณการเปลี่ยนแปลงที่เกิดจากความผิดปกติของพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศ ออกจากความผันแปรของสภาพภูมิอากาศที่เกิดจากกิจกรรมของ

มนุษย์ ถ้าไม่คำนึงถึงสาเหตุที่ก่อให้เกิดการเปลี่ยนแปลง ผลจากการศึกษานี้ ได้แสดงอย่างชัดเจน ว่า T_{min} และ T_{amin} ในประเทศไทย ในช่วง 53 ปีที่ผ่านมา เพิ่มขึ้นอย่างต่อเนื่องในอัตราที่น่าตกใจ

จากลักษณะการเพิ่มขึ้นของ T_{min} และ T_{amin} ในอัตราที่รวดเร็วและมากกว่า T_{max} และ T_{amax} ส่งผลให้อุณหภูมิอากาศต่ำสุดทุกภาคของประเทศไทยขยับสูงขึ้นค่อนข้างมากอย่างมีนัยสำคัญในอัตราเฉลี่ย 1.35°C ภายในระยะเวลา 50 ปี ตลอดจนช่วงของอุณหภูมิต่ำสุดและอุณหภูมิสูงสุดรายวัน (Diurnal Temperature Range; DTR) ในประเทศไทย มีแนวโน้มที่แคบลงเรื่อย ๆ อย่างมีนัยสำคัญเช่นกันในอัตราเฉลี่ย -0.99°C ภายในระยะเวลา 50 ปี ปัจจัยเฉพาะแห่งที่มีผลกระทบต่อ DTR อาจเกิดจากการขยายตัวของชุมชนเมือง ระบบชลประทาน การขยายตัวของพื้นที่ที่แห้งแล้งหรือทะเลทราย และความแปรปรวนที่เกิดจากลักษณะการใช้ประโยชน์ของที่ดิน โดยเฉพาะอย่างยิ่ง ในบริเวณชุมชนเขตเมือง ช่วงของ DTR จะแคบกว่าปกติ แต่อย่างไรก็ตาม จากผลการวิเคราะห์ผลกระทบของชุมชนเมืองต่อลักษณะการเปลี่ยนแปลงของอุณหภูมิอากาศ พบว่า ค่าเฉลี่ยรายปีของอุณหภูมิอากาศต่ำสุดและสูงสุดรวมทั้ง DTR ของโลก และซีกโลกเหนือหรือใต้ที่คำนวณจากสถานีที่ไม่ตั้งอยู่ในชุมชนเมือง แตกต่างเพียงเล็กน้อยเมื่อเปรียบเทียบกับค่าดังกล่าวข้างต้นที่คำนวณจากสถานีที่ตั้งอยู่ในเขตชุมชนเมือง นอกจากนี้ ปัจจัยที่มีผลกระทบต่อ DTR อาจเกิดจากการเปลี่ยนแปลงของระบบหมุนเวียนของสภาพภูมิอากาศโลก ซึ่งประกอบด้วย การเพิ่มขึ้นของเมฆและละอองในชั้นบรรยากาศ และการเพิ่มขึ้นของความชื้นพื้นผิวเนื่องมาจากฝนและของปริมาณก๊าซเรือนกระจก สำหรับประเทศไทย DTR ที่มีแนวโน้มที่แคบลงเรื่อย ๆ ซึ่งมีลักษณะการเปลี่ยนแปลงที่เหมือนและสอดคล้องกันทุกภาค บ่งชี้ถึงแหล่งกำเนิดของการเปลี่ยนแปลงของ DTR ไม่น่าจะเกิดจากผลกระทบของปรากฏการณ์เฉพาะแห่ง แต่เป็นการสะท้อนให้เห็นถึง การเพิ่มขึ้นค่อนข้างมากของอุณหภูมิอากาศต่ำสุด เนื่องจากการตอบสนองต่อความผิดปกติของพฤติกรรมของความแปรปรวนตามธรรมชาติของสภาพภูมิอากาศโลก หรือความผันแปรของสภาพภูมิอากาศโลกที่เกิดจากกิจกรรมของมนุษย์ การเปลี่ยนแปลงที่เหมือนกับผลดังกล่าวข้างต้น ไม่ได้เกิดขึ้นในประเทศไทยเท่านั้น ผลการศึกษาในหลาย ๆ พื้นที่ของโลก ระบุถึง การเปลี่ยนแปลงของอุณหภูมิอากาศต่ำสุดและช่วงของ DTR ที่ขยับสูงขึ้นอย่างต่อเนื่องและแคบลงอย่างมีนัยสำคัญในศตวรรษที่ 20 ซึ่งส่งผลให้จำนวนวันหรือคืนที่อากาศเย็นลดลงและช่วงของฤดูหนาวสั้นลงแต่ฤดูใบไม้ผลิยาวขึ้น

เป็นที่ยอมรับกันโดยทั่วไปว่า การเปลี่ยนแปลงของสภาพภูมิอากาศโลกทั้งระยะสั้นและระยะยาว ไม่ว่าจะเกิดจากความผิดปกติของพฤติกรรมของความแปรปรวนตามธรรมชาติ หรือเกิดจากกิจกรรมของมนุษย์ เป็นปัจจัยที่สำคัญที่ส่งผลกระทบต่ออย่างกว้างขวางและรุนแรงต่อสภาพแวดล้อม ระบบนิเวศน์วิทยา สภาพเศรษฐกิจและสังคม รวมทั้งสุขภาพอนามัยและความเป็นอยู่ของมนุษย์ เนื่องจากความซับซ้อนของระบบสภาพแวดล้อมและนิเวศน์วิทยารวมทั้งความไหวต่อปัจจัยภายนอกของระบบดังกล่าว การเปลี่ยนแปลงของสภาพภูมิอากาศโลก อาจก่อให้เกิดผลกระทบในลักษณะที่ไม่เป็นเชิงเส้นตรง (Nonlinear) ดังคำพังเพยที่ว่า “the straw that breaks the camel's back” ซึ่งจะส่งผลให้การตอบสนองที่ค่อนข้างรุนแรงของระบบสภาพแวดล้อมและนิเวศน์วิทยา ต่อการเปลี่ยนแปลงเพียงเล็กน้อยของสภาพภูมิอากาศโลก ตัวอย่างที่เห็นได้ชัดเจน ได้แก่ การตอบสนองอย่างรุนแรงและกว้างขวางของระบบสภาพแวดล้อมและนิเวศน์วิทยาทั่วภูมิภาคของโลก ต่อการเปลี่ยนแปลงของอุณหภูมิอากาศของโลกเพียงแค่ 0.6 ± 0.2 องศาเซลเซียส ในช่วงศตวรรษที่ 20

หลักฐานทางวิทยาศาสตร์เท่าที่มีในปัจจุบัน ระบุชัดเจนว่า การเปลี่ยนแปลงของสภาพภูมิอากาศทั้งในระดับภูมิภาคและระดับโลก โดยเฉพาะอย่างยิ่ง การเพิ่มขึ้นของอุณหภูมิอากาศในช่วงไม่กี่ทศวรรษที่ผ่านมา ได้ส่งผล

กระทบต่อระบบสภาพแวดล้อมและนิเวศวิทยาต่าง ๆ ในหลายภูมิภาคของโลก ตัวอย่างของการเปลี่ยนแปลงที่ได้ค้นพบ ได้แก่ การละลายของภูเขาน้ำแข็งในบริเวณขั้วโลกเหนือและใต้ การละลายของหิมะ ระดับน้ำทะเลสูงขึ้น การเคลื่อนตัวของขั้วโลกของพื้นที่ที่สามารถดำรงชีวิตของพืชและสัตว์บางชนิดในเขตร้อน (Tropical) และกึ่งร้อน (Subtropical) การเพิ่มหรือลดลงของจำนวนประชากรของพืชและสัตว์บางชนิด ฤดูกาลเจริญเติบโตของพืชและสัตว์ในบริเวณ mid-to-high latitude ยาวขึ้น พืชและสัตว์ออกดอกและผสมพันธุ์เร็วขึ้น นอกจากนี้ ความสัมพันธ์ระหว่างการเปลี่ยนแปลงของอุณหภูมิในระดับภูมิภาค และการเปลี่ยนแปลงของระบบสภาพแวดล้อมและนิเวศวิทยา ยังปรากฏชัดเจนในมหาสมุทร การเปลี่ยนแปลงของการกระจายตัวและจำนวนประชากรของแพลงตอนพืชและสัตว์ในบริเวณชายฝั่งของรัฐแคลิฟอร์เนีย ต่อการเปลี่ยนแปลงทั้งในระยะสั้นและระยะยาวของอุณหภูมิผิวน้ำทะเล ที่เกิดจากปรากฏการณ์เอลนีโญและสภาวะโลกร้อน เป็นที่ทราบกันดีในช่วงไม่กี่ทศวรรษที่ผ่านมา นิเวศวิทยาชายฝั่งที่มีคุณค่ามหาศาลทางเศรษฐศาสตร์และความหลากหลายทางชีวภาพ รวมทั้งเป็นแหล่งอาหารที่สำคัญของมนุษย์ โดยเฉพาะแนวปะการัง กำลังได้รับภัยคุกคามจากการเพิ่มขึ้นของอุณหภูมิทะเล การเพิ่มขึ้นของปรากฏการณ์ฟอกขาวของปะการัง (Coral Reef Bleaching) อาจเกิดจากการเพิ่มขึ้นของอุณหภูมิทะเลโลก หลักฐานทางวิทยาศาสตร์ ระบุว่า ได้เกิดปรากฏการณ์ฟอกขาวของปะการังที่รุนแรง จำนวน 6 ครั้ง ตั้งแต่ปี ค.ศ. 1979 และความรุนแรงรวมทั้งจำนวนครั้งมีแนวโน้มเพิ่มขึ้นตั้งแต่นั้นมา ซึ่งปรากฏการณ์ฟอกขาวของปะการังที่รุนแรงที่สุด เกิดขึ้นในช่วงที่ตรงกับหรือสอดคล้องกับการเกิดปรากฏการณ์เอลนีโญในระหว่างปี ค.ศ. 1997-1998 โดยทั้ง 10 แนวเขตปะการังที่มีขนาดใหญ่ของโลกได้รับผลกระทบอย่างรุนแรง นอกจากนี้ การเปลี่ยนแปลงของอุณหภูมิ ยังเป็นปัจจัยเสี่ยงต่อการสูญพันธุ์ของพืชและสัตว์ โดยเฉพาะอย่างยิ่ง ตระกูลหรือชนิดที่ได้รับภัยคุกคามจากการเปลี่ยนแปลงของสิ่งแวดล้อมแล้วในปัจจุบัน

การเพิ่มขึ้นของระดับน้ำทะเลจากสภาวะโลกร้อน เป็นประเด็นที่ได้รับความสนใจอย่างกว้างขวาง และส่งผลกระทบต่อหลายประเทศที่มีพื้นที่เป็นเกาะและอาณาเขตติดกับทะเล การเพิ่มขึ้นของระดับน้ำทะเลยังมีอัตราที่ไม่แน่นอน แต่จากการประมาณครั้งล่าสุดของ IPCC พบว่าอยู่ในช่วง 10-94 เซนติเมตร ภายในปี ค.ศ. 2100 เนื่องจากการเคลื่อนตัวของความร้อนเกิดขึ้นช้าในมหาสมุทร การเพิ่มขึ้นของระดับน้ำทะเลจะเกิดขึ้นอย่างต่อเนื่องนานกว่าการเปลี่ยนแปลงของอุณหภูมิ ถึงแม้ปริมาณการปล่อยก๊าซเรือนกระจกจะถูกควบคุมให้อยู่ในระดับที่ทันทีทันใดในปัจจุบันก็ตาม การเพิ่มขึ้นของระดับน้ำทะเลจะเกิดขึ้นอย่างต่อเนื่องเป็นระยะเวลาที่ยาวนานร่วมศตวรรษ ซึ่งจะส่งผลกระทบต่อประชากรของโลกเป็นล้าน ๆ คน ประเทศในแถบตะวันตกเฉียงเหนือของมหาสมุทรแปซิฟิก หมู่เกาะในมหาสมุทรแปซิฟิก และในแถบตะวันออกของทวีปเอเชียรวมทั้งประเทศไทย มีโอกาสสูงที่จะได้รับผลกระทบจากการเพิ่มขึ้นของระดับน้ำทะเล เนื่องจากพื้นที่ดังกล่าวมีลักษณะสูงกว่าระดับน้ำทะเลเพียงเล็กน้อย จากผลการประมาณอัตราการเพิ่มขึ้นของระดับน้ำทะเลในบริเวณอ่าวไทยตอนบน โดยใช้แบบจำลองทางคณิตศาสตร์ พบว่า ระดับน้ำทะเลจะเพิ่มขึ้นในช่วง 1-3 เมตร ภายในปี ค.ศ. 2100 ระดับน้ำทะเลที่เพิ่มขึ้นในอัตราดังกล่าว จะทำให้พื้นที่ที่มีความสูงเฉลี่ยประมาณ 1 เมตร ซึ่งส่วนใหญ่จะเป็นพื้นที่ป่าชายเลนและพื้นที่ชายฝั่ง จะจมอยู่ใต้น้ำในศตวรรษหน้า โดยการเพิ่มขึ้นของระดับน้ำทะเล อาจจะมีอัตราที่เร็วขึ้นกว่าที่คาดการณ์ไว้ เนื่องจากการทรุดตัวของแผ่นดินในบริเวณกรุงเทพฯ และปริมณฑล ผลสืบเนื่องจากการสูบน้ำบาดาลมาใช้ ผลกระทบจากการเพิ่มขึ้นระดับน้ำทะเล จะทำให้ปัญหาสิ่งแวดล้อมที่เกิดขึ้นแล้วในปัจจุบันในบริเวณดังกล่าว เช่น การกัดเซาะของชายฝั่ง การรุกคืบของน้ำเค็ม ความเสื่อมโทรมของทรัพยากรธรรมชาติและมลพิษและน้ำท่วม มีทวีความรุนแรงและเลวร้ายเพิ่มขึ้น

จากการประยุกต์ใช้เทคนิคทางสถิติตัวแปรพหุ โดยเฉพาะอย่างยิ่ง EOFs ในการวิเคราะห์ข้อมูลอุณหภูมิอากาศ มีส่วนช่วยให้เข้าใจถึงแง่มุมที่สำคัญบางประการของการเปลี่ยนแปลงของสภาพภูมิอากาศในประเทศไทย โดยหลักฐานจากการศึกษานี้ จะมีประโยชน์อย่างยิ่งต่อการศึกษาวิจัยเพิ่มเติมในรายละเอียดของเรื่องกลไกการเปลี่ยนแปลงของสภาพภูมิอากาศ การพยากรณ์ผลกระทบที่อาจจะเกิดขึ้น รวมทั้งการอนุรักษ์และการจัดการสิ่งแวดล้อมในระดับภูมิภาคในอนาคต นอกจากนี้ หลักฐานดังกล่าว ยังเป็นข้อมูลพื้นฐานที่สำคัญในการสร้าง พัฒนา และปรับเทียบแบบจำลองทางคณิตศาสตร์ ซึ่งเป็นงานที่ทำมาของการเปลี่ยนแปลงสภาพภูมิอากาศของโลกในอนาคตอีกด้วย อย่างไรก็ตาม ยังมีหลายประเด็นที่สำคัญที่ต้องศึกษาในรายละเอียดและควรที่จะมุ่งเน้นในการศึกษาวิจัยในอนาคตอันใกล้ ประเด็นที่สำคัญอันดับต้น ๆ คือ “ผลกระทบที่อาจจะเกิดขึ้นต่อสภาพแวดล้อม นิเวศน์วิทยา สภาพเศรษฐกิจและสังคมรวมทั้งสุขภาพอนามัยและความเป็นอยู่ของมนุษย์ จากสภาวะโลกร้อนที่เพิ่มขึ้นอย่างต่อเนื่องและแนวโน้มผิดปกติทั้งในแง่ จำนวนครั้งที่เกิดขึ้น ทิศทาง ระยะเวลาและความรุนแรงของปรากฏการณ์เอลนีโญ” การตอบคำถามนี้ นับว่าเป็นขั้นตอนเบื้องต้นที่สำคัญในการกำหนดยุทธศาสตร์การตั้งรับและการปรับตัวเข้ากับสภาพการเปลี่ยนแปลงที่อาจจะเกิดขึ้น เพื่อลดความรุนแรงแต่แสวงหาผลประโยชน์สูงสุดจากผลกระทบดังกล่าว เนื่องจากหลักฐานได้เสนอแนะว่า การเปลี่ยนแปลงสภาพภูมิอากาศทั้งในระดับภูมิภาคและระดับโลก มีแนวโน้มเกิดขึ้นอย่างต่อเนื่องและอาจจะทวีความรุนแรงภายในระยะเวลา 50-100 ปีข้างหน้า ดังนั้นข้อมูลทางวิทยาศาสตร์ดังกล่าวข้างต้น นับว่ามีความสำคัญอย่างยิ่งยวดในการลดความไม่แน่นอนในการประเมินผลกระทบ เพื่อให้ผู้บริหารระดับนโยบายมีความมั่นใจในการตอบสนองต่อผลกระทบ ที่อาจจะเกิดขึ้นจากการเปลี่ยนแปลงของสภาพภูมิอากาศโลก

จะเห็นได้ว่า การเปลี่ยนแปลงของสภาพภูมิอากาศของโลก เป็นองค์ประกอบที่สำคัญและวิกฤติ ของระบบ “Integrated Earth System” ซึ่งเป็นปัจจัยคุกคามในปัจจุบันและอนาคตต่อระบบสภาพแวดล้อมและนิเวศน์วิทยาในหลายพื้นที่รวมทั้งประเทศไทยด้วย การเตรียมพร้อมที่จะเผชิญกับสภาพภูมิอากาศเปลี่ยนแปลงนับว่าเป็นประเด็นที่สำคัญซึ่ง หากไม่รีบกระทำตอนนี้ เมื่อการเปลี่ยนแปลงมาถึงเราอาจไม่สามารถปรับตัวเข้ากับการเปลี่ยนแปลงได้ หรืออาจส่งผลเสียหายมากกว่าที่ควรจะเป็น ดังนั้น การป้องกันน่าจะดีกว่าการแก้ไข (Better to be safe than sorry) เน้นอนปัญหาของสภาพภูมิอากาศเปลี่ยนแปลงไม่ใช่เรื่องปัจจุบันทันด่วนที่รัฐบาลจะต้องแก้ไขทันที แต่จะเพิกเฉยโดยไม่ให้ความสำคัญไม่ได้ ควรมีการกำหนดนโยบายในการศึกษาด้านนี้อย่างชัดเจน และจัดสรรงบประมาณแทรกซึมไว้ในกระทรวงหรือหน่วยงานที่เกี่ยวข้อง เพื่อสามารถดำเนินการศึกษาด้านนี้ได้ การเชื่อมโยงข้อมูลของแต่ละหน่วยงานเป็นสิ่งจำเป็นอย่างยิ่งในการศึกษาวิจัยเพื่อสามารถมองภาพรวมได้ถูกต้อง ในการสร้างนโยบายระดับประเทศนั้น ต้องมองให้เห็นภาพรวมทั้งในและต่างประเทศให้ชัดเจน เพื่อแจกแจงแยกแยะจัดลำดับประเด็นที่สำคัญและจำเป็นต่อประเทศชาติเป็นลำดับแรก นอกจากนี้ ควรศึกษาแบบครบวงจร เนื่องจากผลกระทบไม่ได้เกิดขึ้นแต่เพียงภาคใดภาคหนึ่งเท่านั้น จะเห็นได้ว่า การเปลี่ยนแปลงสภาพภูมิอากาศนั้น เกี่ยวข้องกับหลายหน่วยงาน ศาสตร์หลายด้าน งานวิจัยหลายสาขา ดังนั้น แนวทางในการดำเนินงาน เพื่อการเตรียมความพร้อม อาจแบ่งได้เป็นประเด็นด้านโครงสร้างพื้นฐาน สำหรับหน่วยงานและบุคลากรเพื่อรองรับการทำงานและการศึกษาด้านสภาพภูมิอากาศเปลี่ยนแปลง ประเด็นด้านนโยบายซึ่งรัฐบาลต้องให้ความสำคัญและสนับสนุนทั้งด้านการวางแผนระยะยาวและด้านงบประมาณ เพราะหากไม่มีงบประมาณสนับสนุน การศึกษาวิจัย อาจไม่เป็นไปตามความคาดหมาย และประเด็นการศึกษาวิจัยซึ่งควรพิจารณาให้ความสำคัญเฉพาะส่วนที่ส่งกระทบโดยตรงกับประเทศไทยเท่านั้น งานวิจัย

ที่ควรส่งเสริมได้แก่ การศึกษาแบบจำลองทำนายการเปลี่ยนแปลงสภาพภูมิอากาศในประเทศไทย การศึกษาผลกระทบ การปรับตัวและพื้นที่ล่อแหลมต่อการเปลี่ยนแปลง

1. Introduction

Variability and change are realities of the climate system, and static, so-called equilibrium, conditions are unlikely to be a part of the system on almost any time scale. The palaeo-records clearly show that the global climate has varied continuously on all time scales, with global mean condition masked by immense variations in regional responses (Kasting, 1993; Petit et al., 1999; IGBP, 2001a,b; IPCC, 2001a). Fluctuations of surface temperature are the most obvious and probably well-documented key indicator of global climate change (*e.g.*, Hurrell, 1995,1996; Easterling et al., 1997; Enfield and Mestas-Nuñez, 1999; Mann et al., 1999; Easterling et al., 2000b; IPCC, 2001a; Trenberth, 2001). Surface temperature plays a crucial role in regulating evaporation and transpiration processes and so have direct connections to both the hydrological cycle and surface energy budget. Because temperature significantly affects biological processes and metabolic rates at almost every trophic levels (Hughes, 2000; McCarty, 2001; Ottersen et al., 2001; Walther et al., 2002), ecosystem functioning and dynamics, as well as human health and comfort are all inevitably influenced by changes in both magnitude and rate of surface temperature through a variety of mechanisms. The additional stress of surface temperature changes will interact in different ways across regions that may reduce the ability of some environmental systems to provide, on sustained basis, key goods and services needed for successful economic and social development. However, there are many uncertainties in determining their impacts and predicting probable climate scenarios for the future, due to our incomplete understanding of interlinks of global climate system, forcings, responses and consequences (IPCC, 2001a). Studies of global and regional surface temperature variations and their impacts have, therefore, undergone a quantum jump and are one of the fundamental aims of global change research (IGBP, 2001a,b; IPCC, 2001a).

There is now growing evidence that human activities have increasingly influenced the global climate through the enhanced greenhouse effect, by past and continuing emission of carbon dioxide (CO₂) and other gases which will cause the temperature of the Earth's surface to increase –popularly termed the “global warming”(IGBP, 2001a,b; IPCC, 2001a; Trenberth, 2001). For a thousand years prior to the industrial revolution, abundance of the greenhouse gases was relatively constant. However, as the world's population increased, as the world became more industrialized and as agriculture developed, abundance of the greenhouse gases increased markedly. The amount of CO₂ in the atmosphere has increased by about 31 percent since 1750 (IPCC, 2001a). The modern instrumental records indicate that surface temperature changed in a similar sense to atmospheric CO₂ concentrations, with a global mean warming of 0.6 ± 0.2 °C over the past 100 years and the 1990s being the warmest decade on record (IPCC, 2001a). Synthesis of information from tree rings, corals ice cores, and historical data further indicates that the 1990s were the warmest decade in at least the past 1,000 years (IGBP, 2001a,b; IPCC, 2001a). In the light of new and stronger evidence and taking into account the remaining uncertainties, the Intergovernmental Panel on Climate Change (IPCC) concluded in 2001 that most of the warming observed over last 50 years is attributable to the increase in atmospheric greenhouse gases due to human activities, and that global warming was indeed happening faster, and the consequences looked more severe than predicted.

On interannual and decadal timescales, there is also good evidence that fluctuations of regional surface temperatures are somewhat closely linked to changes in large-scale atmospheric and ocean circulations, as well as deep ocean heat content (*e.g.*, Loon and Rogers, 1978; Rogers, 1984; Li, 1990; Leathers et al., 1991; Yasunari and Seki, 1992; Trenberth and Hurrell, 1994; Hurrell, 1995, 1996; Mantua et al., 1997; Zhang et al., 1997; Qian and Zhu, 2001). Persistent large-scale atmospheric patterns tend to be wavelike so that regional changes of atmospheric heating, if powerful and persistent enough, can give rise to a sequence of remote atmospheric teleconnections (Horel and Wallace, 1981; Wallace and Gutzler, 1981; Trenberth, 1990; Zahn, 2003). Thus a number of well-separated areas of anomalous temperature with opposite character may be produced. The strongest teleconnection pattern which has well documented within the earth's climate on seasonal to decadal timescales is the set of processes known as the El Niño-Southern Oscillation (ENSO). This phenomenon is the strongest natural mode and involves a set of complex interactions between the tropical oceans and the atmosphere centered on the Pacific and Indian Ocean basins with the life-cycle typically lasting from 2-7 years (*e.g.*, Horel and Wallace, 1981; Philander, 1990; McPhaden, 1999). The ENSO is now known to be at the root of many of the disastrous interannual climate fluctuations affecting tropical and subtropical countries (Rasmusson and Wallace, 1983; Hawana et al., 1989b; Philander, 1990; Li, 1990; Wang and Li, 1990; Janicot et al., 1996; Ware and Thomson, 2000; Barlow et al., 2002; Hoerling and Kumar, 2003; Huber and Caballero, 2003). Moreover, warming over the large continental areas and cooling over the North Pacific and North Atlantic in the winter during the past three decades is another example of more complex consequences of interconnected climate networks and interplay of different climate modes (IPCC, 2001a). This cold ocean-warm land pattern has been linked to changes in the atmospheric circulation over the northern hemisphere, in particular, to the tendency in the past few decades for the North Atlantic Oscillation (NAO) to be in its positive phase (Hurrell, 1995; Hurrell and Loon, 1997). Similarly, the Pacific-North American (PNA) teleconnection pattern has been in a positive phase in association with the tendency for favoring more the warm El Niño phase of ENSO phenomenon following the 1976/77 climatic regime shift (Nitta and Yamada, 1989; Trenberth, 1990; Hurrell, 1996; Zhang et al., 1997).

Although global temperature has increased in the past century, its pattern was not spatial uniform or temporal monotonic, with large regional differences (Chapman and Walsh, 1993; Schlesinger and Ramankutty, 1994). For example, the winter temperature in northern Europe has increased during the past 30 years, whereas northeastern America and Greenland have experienced increasingly colder winters in the same period (Hurrell and Loon, 1997). Much of this variation in regional winter climate conditions in the northern hemisphere can be attributed to variations in the natural climate pattern over the North Atlantic or NAO (Hurrell and Loon, 1997). The climate of a given region is determined by the interaction of forcings and circulations that occur at the planetary, regional and local spatial scales, and at a wide range of temporal scales (IGBP, 2001a,b). Planetary scale forcings regulate the general circulation of the global atmosphere. This in turn determines the sequence and characteristics of weather events and weather regimes that characterize the climate of a region. Embedded within the planetary scale circulation regimes, regional and local forcings and mesoscale circulations modulate the spatial and temporal structure of the regional climate signal, with an effect that can in turn influence planetary scale circulation features. Because of their complex interaction, there is

increasing need to better understand the processes that determine regional climate, along with the teleconnection effects of regional forcing anomalies (IPCC, 2001a).

The most highly developed tool which has currently used to predict future climate is known as coupled general circulation models (GCMs). These models are based upon sound, well-established physical principles and use descriptions in simplified physical terms of atmosphere, ocean and land processes. The predictive powers of a model can be tested by running the model with known forcing from the past through it and then comparing the results to actual climate records. Although models are exceedingly useful tools for carrying out numerical climate experiments, they do have limitations and must be used carefully (Trenberth, 2001). The latest models have been able to reproduce the major large-scale features of atmosphere, ocean and land processes in the past century or so with increasing accuracy (IPCC, 2001a). However, on regional scales (2000 km or less), there are significant errors in all models (Mearns et al., 1995; IPCC, 2001a). This is mainly due to the complexity and scale of the physics involved and difficulties in relating the area-mean GCM output to the point or station scale (Osborn, 1997; Osborn and Hulme, 1997; Boyle, 1998). Moreover, our climate models so far are of relatively coarse resolution, and simplified versions of the real world (IPCC, 2001a; Trenberth, 2001). Given the unproven reliability of GCMs at small scales especially in simulating surface temperature, it is desirable to search for signals of surface temperature changes in the observational records.

A surface temperature signal or any other climatic variables at any fixed location/region will typically consists of a complex mixture of variation, resulting from interactions among physical processes within the atmosphere-ocean-cryosphere system that operate on a wide range of spatial and temporal scales. Interactions within the components of the climate system usually include positive and negative feedbacks. When these feedbacks combine properly and balance each other, they can give rise to irregular but can be separated and identified as trends, periodic and random oscillations (Jassby and Powell, 1990; Ware and Thomson, 2000). The motivation for exploratory methods of data analysis in climate comes from the need to separate the climate “signal” from the background climate variability or “noise”. This decomposition of the data is done with the hope of identifying the physical processes responsible for the generation of the signal (Emery and Thomson, 1997). A fundamental characteristic of the statistical methods for signal detection is their ability to represent spatially distributed data in a compressed way such that the physical processes behind the data, or their effects, can best be visualized (Venegas, 2001). As summarized by Emery and Thomson (1997) and Venegas (2001), signal detection in climate is useful to achieve four main goals in climate research:

1. to recognize the patterns of natural climate variability and distinguish them from presumed anthropogenic or other external effects,
2. to use the physical mechanisms inferred from the detection signals to construct numerical climate models,
3. to validate numerical climate models by comparing the fundamental characteristics of the modeled data with those of the observed data, and
4. to use the signals themselves to forecast the behavior of the system in the future.

The complicated behavior and the non-linear character of the climate system provide a real challenge to the exploratory data analysis methods (IPCC, 2001a). Climate variations on different time scales, for example, may be connected with one another by nonlinear mechanisms. Some episodic phenomena, such as the periodic seasonal changes in surface temperatures, are better suited to be analyzed in the frequency domain. For certain phenomena it is not clear whether an oscillatory or episodic picture is most appropriate. Also, a number of signals, such as ENSO, exhibit a mixture of time-domain or “event” characteristics and frequency-domain or “oscillatory” characteristics (Emery and Thomson, 1997). Such quasi-oscillatory signals are characterized by a dominant timescale of variation, and are often combined with frequency modulation and episodic large-amplitude events. The choice of the appropriate analysis method is of extreme importance when the objective is to search for specific signals in time, space, or time and space combined, within large multivariate data sets (Venegas, 2001).

It is usual in climate studies to be presented with a large data set consisting of time series over a grid of stations which we wish to compress into a smaller number of independent pieces of information. Typically it is necessary to deal with an ensemble of instantaneous samples (maps) of geophysical fields (for example, surface temperature) defined at a number of points (stations). In such cases, the data are in the form of simultaneous time series records from a grid on a horizontal plane: $x_i(t)$, $y_i(t)$. The grid points may be regularly spaced (such as model-generated data or grid observation) or irregularly spaced (such as locations of meteorological stations). Analyses of data sets with the described characteristics, that is, consisting of a number of spatially distributed time series are known as multivariate statistical procedure. The method of Empirical Orthogonal Functions (EOFs) is a particularly useful technique for compressing the variability in this type of data sets and is most widely applied to the problem of spatio-temporal signal detection in climatic data sets (Lagerloef and Bernstein, 1988; Preisendorfer, 1988; Emery and Thomson, 1997). This method is also known as Principal Component Analysis (PCA). The EOF procedure is equivalent to a data reduction method widely used in the social sciences known as factor analysis. An advantage of EOF analysis is that it provides a compact description of the spatial and temporal variability of data series in terms of orthogonal functions, or statistical modes.

In this study, the EOF analysis as well as other multivariate statistical techniques were applied. The primary objective is to identify the dominant spatio-temporal patterns of surface air temperature in Thailand, which the time evolution of their leading modes can further be investigated :

1. interannual and multi-decadal variability as well as long-term trends,
2. its relation to the ENSO and anthropogenic-induced climate changes and the possible linking mechanisms, and
3. its possible biophysical and socio-economic impacts.

The paper is organized as follows. An analytical method and data sources are outlined in the next section. Also reviewed in this section will be the basic concepts of EOF analysis and EOF computation using the scatter matrix method. Physical interpretation of EOF analysis and temporal structures of the EOF1 coefficient series and their relations to large-scale climate signals are presented in section 3. The final section goes on discussing advantage/disadvantage of analytical technique, possible causes/effects of surface air temperature changes, and implication for future research.

2. Analytical methods and data sources

2.1. Basic concepts of EOF analysis

EOFs as used by meteorologists and oceanographers are a statistical technique for analysis of the spatial or temporal variability of physical fields. For example, a situation benefiting from such analysis occurs when a succession of snapshots of the surface temperature field over any given region of the globe is made at monthly times during ten years or longer. When these snapshots are viewed in rapid succession, it becomes apparent to the eye where the areas of great variability of surface temperature are. In order to succinctly represent and think about such complex variations, scientists in both meteorology and oceanography have learned over recent decades to use and develop the concept of EOF analysis, a tool arising originally in biology and psychometry, to resolve the complex variance patterns of physical fields. Thus, EOF analysis is simply a method for portioning the variance of a spatially distributed group of concurrent time series. Its goal is to replace the spatial and temporal variability of original data series by a smaller number of new variables, linear combination of the original variables, that capture most of the total original variance but are uncorrected with each other (Davis, 1976; Lagerloef and Bernstein, 1988; Preisendorfer, 1988; Dunteman, 1989; Jassby and Powell, 1990; Emery and Thomson, 1997). The new variables are called orthogonal functions and are arranged in descending order according to the amount of the original variance they reproduce. Usually, most of the variance of a spatially distributed series is in the first few orthogonal functions whose patterns may then be linked to possible dynamical mechanisms. The theory behind EOF computation is straightforward (see, for example, Preisendorfer, 1988, Dunteman, 1989; Emery and Thomson, 1997 for a particularly compact and lucid description). There are two approaches for computing EOFs for a number of time series. The first constructs the covariance matrix of the data series and then decomposes it into eigenvalues and eigenvectors. The second uses the Singular Value Decomposition (SVD) of the data matrix to obtain all the components of the EOFs (eigenvalues, eigenvectors, and time-dependent amplitudes) without computation of the

$$Z' = \begin{array}{c} \left| \begin{array}{ccc} z'_{1,1} & \dots & z'_{1,p} \\ \cdot & \dots & \cdot \\ z'_{n,1} & \dots & z'_{n,p} \end{array} \right| \begin{array}{l} \downarrow \\ \text{Time} \\ \cdot \end{array} \end{array} \quad (4)$$

Data matrix Z' is now used to derive the spatial covariance matrix $R_{ZZ'}$ of the field $z'(t,x)$ by multiplying matrix transpose of Z' (Z'^T) by its matrix Z' :

$$(5) \quad R_{ZZ'} = Z'^T * Z'$$

Expanding the product of matrices :

$$R_{ZZ'} = \begin{array}{c} \left| \begin{array}{cccc} \langle z'_{1,z'_1} \rangle & \langle z'_{1,z'_2} \rangle & \dots & \langle z'_{1,z'_n} \rangle \\ \dots & \dots & \dots & \dots \\ \langle z'_{n,z'_1} \rangle & \langle z'_{n,z'_2} \rangle & \dots & \langle z'_{n,z'_n} \rangle \end{array} \right| \end{array} \quad (6)$$

where $\langle z'_i z'_j \rangle$ is the covariance between time series z'_i and z'_j (z'_i at locations i and j) defined as :

$$\langle z'_i z'_j \rangle = \langle z'_j z'_i \rangle = \frac{1}{n} \sum_{t=1}^n z'_i(t) z'_j(t), \quad (7)$$

where $i, j = 1, \dots, p$. The matrix product $R_{ZZ'}$ is symmetric and square, even if Z' itself is not square. A dimension of $R_{ZZ'}$ is $p \times p$. It should be noted that some authors define the data matrix Z' as the transpose of that defined in equation (4), that is, with n columns corresponding to time steps and p rows corresponding to locations. In such case, the determination of the spatial covariance matrix should be done as

$$R_{ZZ'} = Z' * Z'^T. \quad (8)$$

The rest of the procedure, however, is identical to what is described here.

Once the covariance matrix has been calculated from the data, the EOF analysis can be done by solving eigenvalue-eigenvector problems which $R_{ZZ'}$ is decomposed into matrices L and E :

$$\begin{array}{l} R_{ZZ'} * E = E * L \text{ or} \\ (R_{ZZ'} - L) * E = 0. \end{array} \quad (9)$$

L is the $p \times p$ diagonal matrix containing eigenvalues λ_k ($k = 1, \dots, p$) of $R_{ZZ'}$, and the off-diagonal elements of $R_{ZZ'}$ are all zero:

$$L = \begin{vmatrix} \lambda_1 & 0 & \dots & 0 \\ \dots & \lambda_2 & \dots & \dots \\ 0 & 0 & \dots & \lambda_p \end{vmatrix} . \quad (10)$$

The square matrix E also has dimension $p \times p$. Its column vectors e_k ($k = 1, \dots, p$) are the eigenvectors of $R_{ZZ'}$ corresponding to eigenvalues λ_k :

$$E = \begin{vmatrix} e_1(1) & e_2(1) & \dots & e_p(1) \\ \dots & \dots & \dots & \dots \\ e_1(p) & e_2(p) & \dots & e_p(p) \end{vmatrix} . \quad (11)$$

$$\begin{array}{cccc} \downarrow & \downarrow & \downarrow & \\ \mathbf{e}_1 & \mathbf{e}_2 & \mathbf{e}_p & \rightarrow \text{Eigenvector } e_k \end{array}$$

The equation in (9) governs the required direction e_k of extremal scatter. Non-trivial solutions (*i.e.*, $e_k \neq 0$) of this set of p linear algebraic equations for the components of $e_k = [e_k(1), \dots, e_k(p)]^T$ occur only for special values of λ_k . In theory of linear algebra, it is shown (Wilkinson, 1965; Franklin, 1968) that a symmetric matrix such as $R_{ZZ'}$ in (6) generally has p eigenvectors $e_k = [e_k(1), \dots, e_k(p)]^T$ in E_p and p associated real, non-negative eigenvalues λ_k such that

$$R_{ZZ'} * e_k = \lambda_k * e_k , \quad k = 1 \dots p. \quad (12)$$

The eigenvalue-eigenvector problems in (9) correspond to the series of linear system equations:

$$\begin{aligned} & [\langle z'_1 z'_1 \rangle - \lambda_1] e_1 + \langle z'_1 z'_2 \rangle e_2 + \dots + \langle z'_1 z'_p \rangle e_p = 0 \\ & \langle z'_2 z'_1 \rangle e_1 + [\langle z'_2 z'_2 \rangle - \lambda_2] e_2 + \dots + \langle z'_2 z'_p \rangle e_p = 0 \\ & \dots \dots \dots \\ & \langle z'_n z'_1 \rangle e_1 + \langle z'_n z'_2 \rangle e_2 + \dots + [\langle z'_n z'_p \rangle - \lambda_p] e_p = 0 . \end{aligned} \quad (13)$$

Since the data matrix Z' is real, the covariance matrix $R_{ZZ'}$ is positive definite, which means that all its eigenvalues are greater or equal to zero. Each non-zero eigenvalue λ_k in matrix L is associated with a column eigenvector e_k in matrix E . The eigenvector matrix E has the property that

$$E * E^T = E^T * E = I_p, \quad (14)$$

where I_p is the $p \times p$ identity matrix with ones in the principal diagonal and zeroes elsewhere. $E * E^T = E^T * E = I_p$ simply indicates that the cross products of any two eigenvectors are 0 and the sum of squares of the elements for a given eigenvector are equal to 1. This means that eigenvectors are uncorrected over space, that is, they are orthogonal to one another. Each eigenvector E_k represents the spatial EOF pattern of mode k (it has dimension p , that is, the number of locations in the original data).

From matrix e_k , time-dependent amplitudes, $a_k(t)$, of the data set can be derived by projecting the original data series $z'(t,x)$ onto eigenvector e_k and summing over all locations p :

$$a_k(t) = \sum_{x=1}^p z'(t,x) e_k(x), \quad (15)$$

where $x = 1, \dots, p$ counts the location, $t = 1, \dots, n$ counts the time steps and $k = 1, \dots, p$ counts the EOF modes. These $a_k(t)$, thought of as time series $\{a_k(t) : t = 1, \dots, n\}$, have the important property of temporal uncorrelatedness, and they carry information about the variance of the data set along the direction e_k . In matrix notation, matrix A which has dimension $n \times p$ is obtained by multiplying matrices Z' and E :

$$A = Z' * E. \quad (16)$$

Just as the spatial patterns E_k are orthogonal in space, the $a_k(t)$ are orthogonal in time. This means that the time-averaged covariance of the amplitudes satisfies

$$\overline{a_i(t) a_j(t)} = \lambda_i \delta_{ij} \quad (\text{uncorrected time variability}), \quad (17)$$

$$i, j = 1, \dots, p,$$

where δ_{ij} is the Kronecker delta:

$$\delta_{ij} = \begin{cases} 1, & j=i \\ 0, & j \neq i. \end{cases} \quad (18)$$

The overbar in (17) denotes the time-averaged value and

$$\lambda_i = \overline{a_i(t)^2} = \frac{1}{n} \sum_{j=1}^n [a_i(t_j)^2] \quad (19)$$

is the variance in each EOF mode. The matrix version of this is

$$A^T * A = L. \quad (20)$$

The eigenvalues in L are usually sorted in decreasing order according to its corresponding eigenvector, so that $\lambda_1 > \lambda_2 > \dots > \lambda_p$. Each eigenvalues λ_k is proportional to the percentage of the variance of the original data that is accounted for by mode k . This percentage is calculated as:

$$\% \text{ variance mode } k = \frac{\lambda_k}{\sum_{i=1}^p \lambda_i} * 100 \quad (21)$$

The first mode contains the highest percentage of total variance, λ_1 ; of the remaining variance, the greatest percentage is in the second mode, λ_2 , and so on. Since EOF modes and their time-dependent amplitudes are uncorrected over time and space, each one makes an independent contribution to accounting for the variance of the original data set. If we add up the total variance in all the time series, we get

$$\sum_{x=1}^p \left\langle \frac{1}{n} \sum_{t=1}^n [z_x(t)]^2 \right\rangle = \sum_{k=1}^p \lambda_k \quad (22)$$

Sum of variances in original data = sum of variances in eigenvalues. Finally and most important, the original centered data set can be totally represented in the form:

$$z'(t, x) = \sum_{j=1}^p a_j(t) e_j(x) \quad (23)$$

$$t = 1, \dots, n; x = 1, \dots, p.$$

In matrix notation :

$$Z' = A * E^T. \quad (24)$$

As noted above, if the eigenvalues are ordered by size (that is, by fraction of the variance explained by the corresponding eigenvector), it is usually found that only the first few empirical modes account for a very fraction of the variance. The reconstruction of an approximate, compressed and less noisy version $\underline{z}'(t,x)$ of the original $z'(t,x)$, using only the first few modes (k) with $k \ll p$, can be represented meaningful physical processes, which are associated with fundamental characteristic spatial and temporal variability in a very large data set. This leads to a significant reduction of the amount of data while retaining most of the variance of variables. In addition, the synthetic version $\underline{z}'(t,x)$ can produce a lower total mean-square error, because sum of variances in eigenvalues (right term in (22)) is close to sum of variances in original data (left term in the (22)).

2.2. Data sources

A set of surface weather observations for a 53-year period (1951-2003) collected at 34 stations in Thailand (Table 1) forms the basis for the EOF analysis. The data set obtained from the Meteorological Department of Thailand consists of monthly averaged mean, maximum, minimum temperatures (T_{mean} , T_{max} , T_{min}), and monthly averaged mean dewpoint temperature (T_{dew}) which are all derived from daily observations. The 34 site records used here were chosen on the basis of record length and completeness, the requirement that there were no significant effects from station relocation during the period, and to provide a reasonable spatial coverage over much of Thailand. Monthly averaged mean, maximum and minimum apparent temperatures (T_{amean} , T_{amax} , T_{amin}),

which combine temperature and humidity effects on the human body, were further calculated by using Steadman's (1984) regression equation

$$T_x = -1.3 + 0.92*t + 2.2*e, \quad (25)$$

where T_x is T_{amean} , T_{amax} , or T_{amin} , t is T_{mean} , T_{max} or T_{min} and e is water-vapor pressure (kilopascals). The effects of wind and radiation are ignored in this equation, and e were calculated from T_{dew} as:

$$e = 0.6108 \exp \left[\frac{17.27 T_{dew}}{T_{dew} + 237.3} \right]. \quad (26)$$

Table 1. Listing of weather stations used in this analysis. Asterisks indicate stations which data are available from 1952 to 2003.

Station number	Station Code	Province	Location (latitude; N, longitude; E)
1	303201	CHIANG RAI	19° 55', 99° 50'
2	327501	CHIANG MAI	18° 47', 98° 59'
3	330201	PHARE*	18° 10', 100° 10'
4	331201	NAN	18° 47', 100° 47'
5	351201	UTTARADIT	17° 37', 100° 06'
6	376202	MAE SOT	16° 40', 98° 33'
7	378201	PHITSANULOK	16° 47', 100° 16'
8	379201	PHETCHABUN*	16° 26', 101° 09'
9	354201	UDON THANI	17° 23', 102° 48'
10	356201	SAKON NAKHON*	17° 09', 104° 08'
11	357201	NAKHON PRANOM*	17° 25', 104° 47'
12	381201	KHON KAEN	16° 26', 102° 50'
13	383201	MUKDAHAN	16° 32', 104° 45'
14	405201	ROI ET	16° 03', 103° 41'
15	407501	UBON RATCHATHANI	15° 15', 104° 52'
16	431201	NAKON RATCHASIMA	14° 58', 102° 05'
17	432201	SURIN	14° 53', 103° 30'
18	400201	NAKON SAWAN	15° 48', 100° 10'
19	425201	SUPHAN BURI*	14° 28', 100° 08'
20	426201	LOP BURI	14° 48', 100° 37'
21	450201	KANCHANA BURI	14° 01', 99° 32'
22	455201	BANGKOK METROPOLIS	13° 44', 100° 34'
23	455601	DON MUANG AIRPORT	13° 55', 100° 36'
24	440201	ARANYA PRATHET	13° 42', 102° 35'
25	459204	SATTATHIP	12° 41', 101° 01'

Table 1. (continued)

Station number	Station Code	Province	Location (latitude; N, longitude; E)
26	480201	CHANTHA BURI	12° 37' , 102° 07'
27	500201	PRACHUAP KHIRIKHAN	11° 50' , 99° 50'
28	517201	CHUMPHON	10° 29' , 99° 11'
29	552201	NAKONSI THAMMARAT	8° 28' , 99° 58'
30	532201	RANONG	9° 59' , 98° 37'
31	564201	PHUKET	7° 58' , 98° 16'
32	567201	TRANG AIRPORT	7° 31' , 99° 32'
33	568501	SONGKHLA	7° 12' , 100° 36'
34	583201	NARATHIWAT	6° 25' , 100° 49'

A relatively stable network of stations and consistency in operational procedures ensure that the quality of surface weather observations in Thailand, for climate studies, is somewhat good (Ouprasitwong, 2002; Brikshavana and Ouprasitwong, 2002). However, the obtained data set was subject to further quality control procedures. Two types of erroneous data were identified. The first was an abrupt shift in mean values, associated with station relocations. According to station history information, there were five stations (CHIANG RAI, KHON KAEN, BANGKOK METROPOLIS, SURAT THANI and NAKHONSI THAMMARAT) that locations were changed during 1990-2000 (Ouprasitwong, 2002). Ouprasitwong (2002) used Multiple Analysis of Series for Homogenization (MASH) to examine homogeneity of rainfall data, and found that inhomogeneity of rainfall data at stations BANGKOK METROPOLIS and NAKHONSI THAMMARAT coincided with the years of station relocations. The MASH program can, however, provide the reliable results only for rainfall data (Ouprasitwong, 2002). Thus, the non-parametric Mann-Whitney statistic (U_k) for testing that two samples (x_1, x_2, \dots, x_p) and ($x_{p+1}, x_{p+2}, \dots, x_{p+n}$) come from the same population is alternatively suitable for examining the occurrence of an abrupt change in other climatic variables (Petitt, 1979; Demaree and Nicolis, 1990). An analysis can be done by partitioning the series into two sub-period, before and after site moves, and calculated U_k from:

where M_i is the rank of the i th observation when the values x_1, x_2, \dots, x_N in the series are arranged in ascending order. The results of two-sided Mann-Whitney test indicate that

$$U_k = 2 \sum_{i=1}^k M_i - k(N+1) \quad (27)$$

(Table 2) only temperature value at station BANGKOK METROPOLIS was significantly different between before and after station relocation, and this data record was then excluded for the EOF analysis. Moreover, the remaining station records were visually inspected for any abrupt shift, but there was no evidence for such changes. The geographical distribution of 33 selected weather stations is shown in Fig. 1. The second type of erroneous data involved outlier data that may have been introduced either due to data-entry, data observing or transmitting procedure biases were identified and excluded according to statistical criteria. An objective approach eliminated apparent statistical outliers, which exceeded specified acceptable range, was arbitrarily set 3 standard deviation from monthly mean (mean \pm 3SD) (Limsakul *et al.*, 2001). Any existing errors, which could not be detected by the statistical methods were usually random and equivalent to “noise”.

From 1951 to 2003, each of the station records is, on average, 98% complete, and the overall dataset has only 1.7% missing values. There were missing data in some years and months particularly during 1951-1955 when more data are missing (Fig. 2). However, small amounts of random missing data should not introduce significant biases in temporal trends, since data used to the EOF analysis consist of many stations. To further prevent missing data from introducing any bias, monthly climatological means calculated from entire record were used for missing values.

2.3. EOF computation using the scatter matrix method

Details of the covariance matrix approach can be found in Preisendorfer (1988) and Emery and Thomson (1997). This recipe, which is only one of several possible procedures that can be applied, involves the preparation of the data and the solution of equation (9) as follows:

1. Construct the $n \times p$ matrix Z in equation (1), by organizing the n rows (times) and p columns (locations) of the original data. In case of surface air temperature data used here that were collected at 33 stations and from 1951 through 2003 (53-year period), $n = 1, \dots, 636$ (53 years x 12 months) and $p = 1, \dots, 33$. Care should be taken to ensure that the start and end times for all p time series of length n are identical.
2. Compute the climatological monthly means using equation (2) and subtract them from original data, $z(t,x)$, in the equation (3). The new $n \times p$ matrix Z' can be formed in the manner of equation (1), but consists of the anomalies or departure from climatological monthly means (4). Note that the anomalies of all missing values are equal to 0, since climatological monthly means are used for those missing data.
3. Construct the spatial covariance matrix $R_{zz'}$ by using equations (5), (6) and (7).
4. Solve eigenvalue-eigenvector problems which $R_{zz'}$ is decomposed into eigenvalues and eigenvectors in the equations (9), (10) and (11).
5. Compute time-dependent amplitude, $a_k(t)$, by projecting the original data series onto eigenvector in equation (15).
6. Calculate the percentages of the variance explained by each mode, using equation (21).

Table 2. Results of the two-sided Mann-Whitney test for monthly averaged mean temperature before and after site moves for 4 stations.

Station	Period before/after site move	<i>N</i>	Median (°C)	<i>Uk</i>	<i>p</i> -value
CHIANG RAI	1951-1991	492	25.6	-0.10	0.92
	1992-2003	143	25.6		
KHON KAEN	1951-1997	564	27.4	-0.95	0.34
	1998-2003	72	27.2		
BANGKOK METROPOLIS	1951-1993	515	27.9	-7.63	<0.001
	1993-2003	120	29.0		
NAKHONSI THAMMARAT	1951-1997	501	27.4	-0.73	0.47
	1998-2003	72	27.4		

N – number of observations; *Uk* – Mann-Whitney statistic

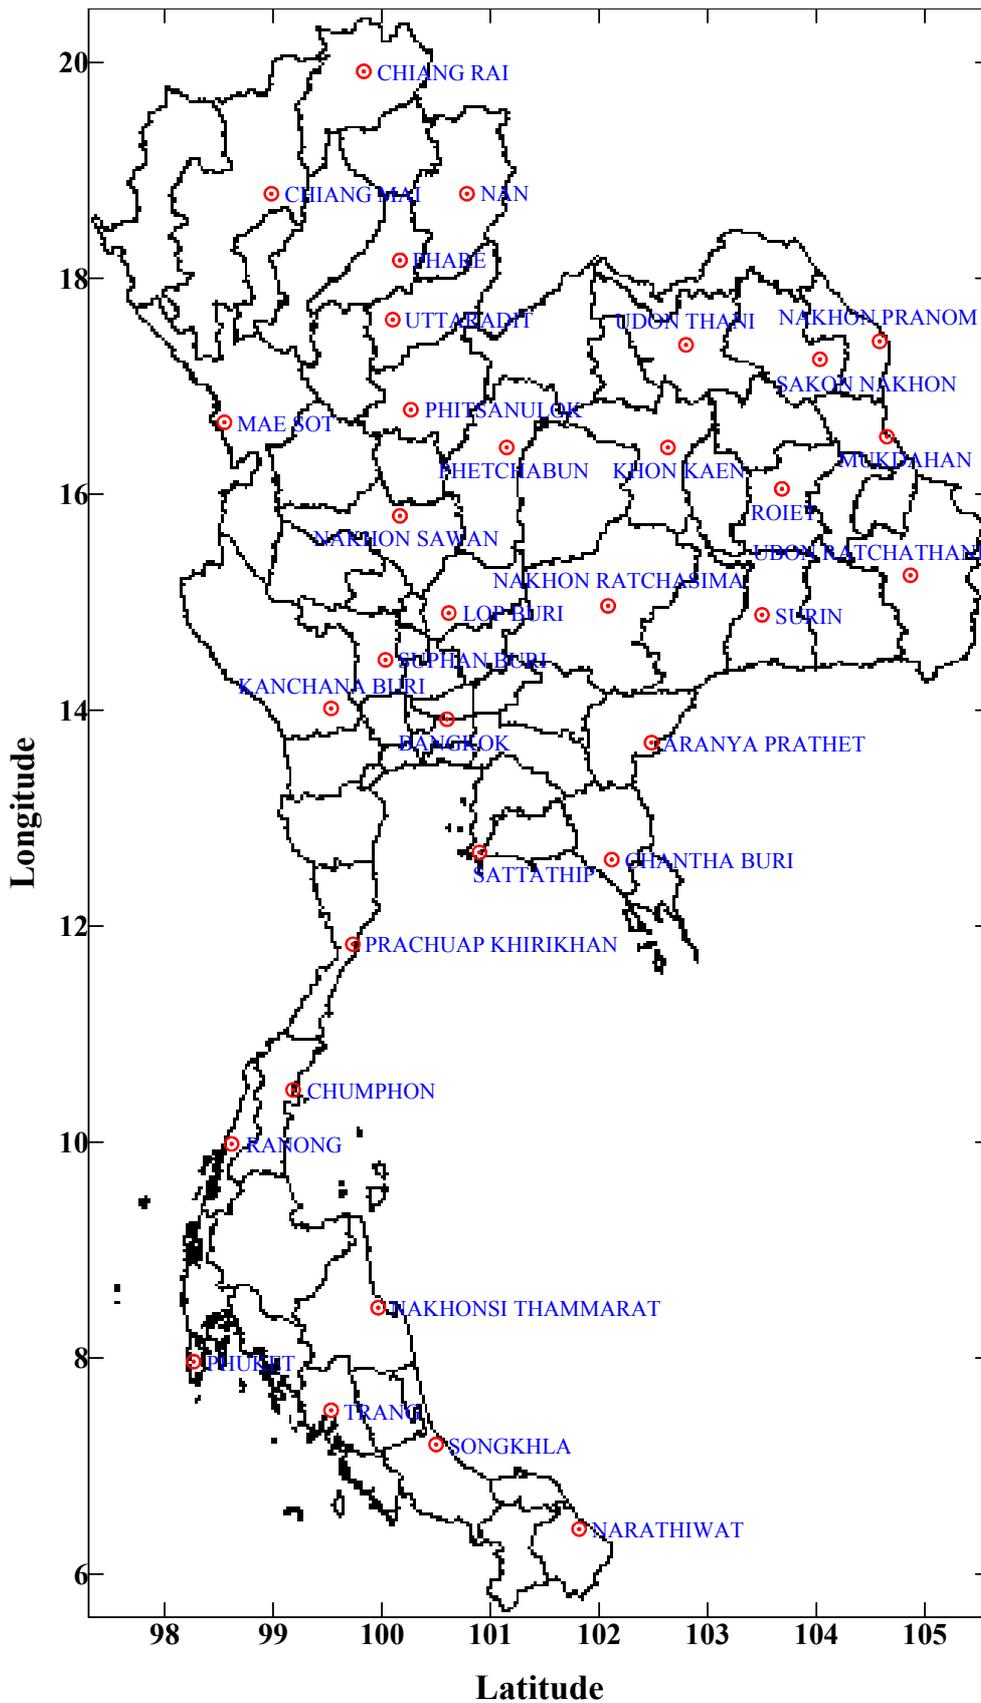


Fig. 1. Geographical distribution of 33 selected weather stations used in this study. The atmospheric variables used to analysis are monthly averaged mean, maximum and minimum temperatures and dewpoint temperature collected from 1951 to 2003.

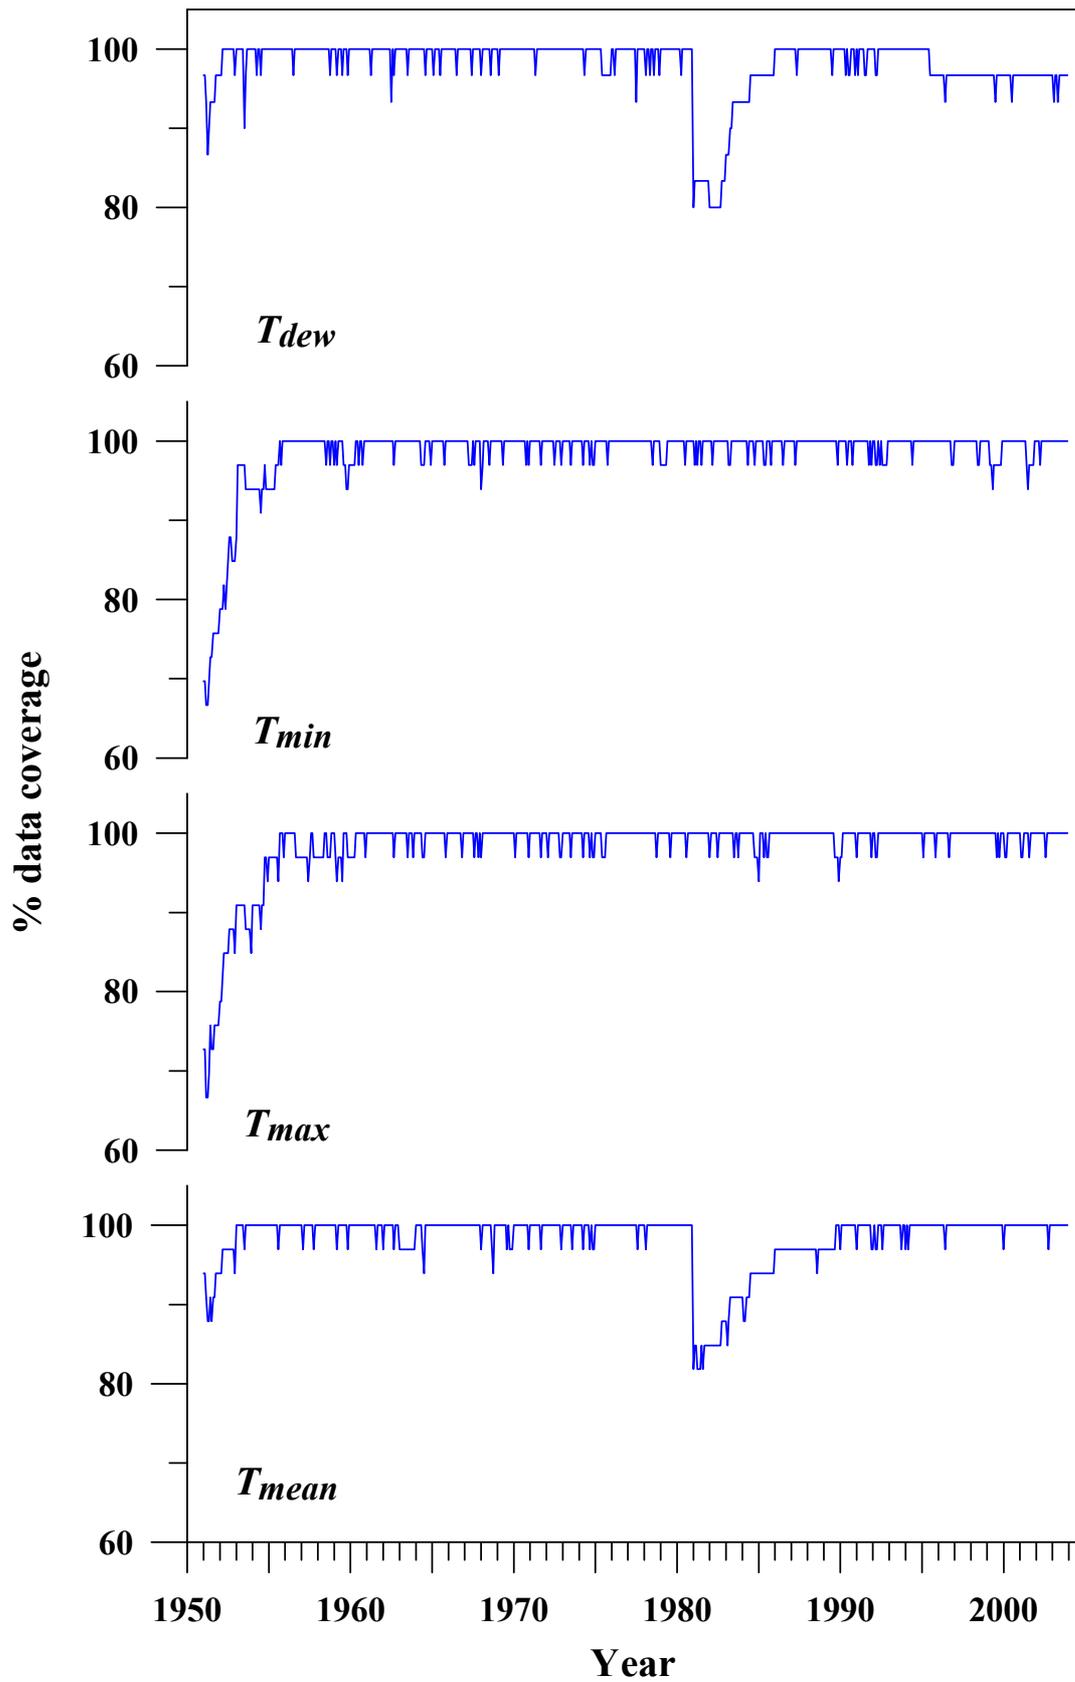


Fig. 2. Monthly percentage of data coverage for 33 stations used in this study.

3. Results

3.1. Physical interpretation of EOF analysis

An EOF analysis generates three types of output. First the eigenvalues together with the percentage of the total variance of each EOF mode are given. In the EOFs these equal the variance accounted by each mode. Also provided are the eigenvectors for each EOF mode. Each eigenvector is composed of values called the component loadings for that mode. These loadings are usually presented as correlation coefficients between each time series and the associated time-dependent amplitudes, and may be considered a measure of the relative importance of each time series in the extracted EOF mode. The sum of the squared correlations for each EOF mode equals the associated eigenvalue. If, for example, surface air temperatures at stations 1, 2 and 3 have high positive loadings on the leading EOF mode and that at station 4 has a high negative loading, this means that the largest proportion of the variance in the original data can be accounted for by the trends in these four stations. The different signs indicate that surface air temperature at station 4 has high values in a certain set of time steps, whereas surface air temperatures at stations 1, 2 and 3 have high values in a completely different set of time steps. The third set of results is a matrix of time-dependent amplitudes or component scores. These series describe the evolution of the EOF's with time. One set of time-dependent amplitudes is provided for each of EOF mode, and each time-dependent amplitude corresponds to one time step. This is computed by simply multiplying the component loadings by the original data.

According to Peixoto and Oort (1992), one way to understand the basic idea behind EOFs is to imagine that each of the n time series as a vector f_n in the p -dimensional space, such that :

$$f_n = \{f_{n1}, f_{n2}, \dots, f_{np}\} \quad \text{at time } t = n.$$

Each vector f_n includes the values of field f at all location $x = 1, \dots, p$ for a given time n . Each of n data vectors is directed from origin to a point in the p space (Fig. 3). If there exists some correlation between the n vectors, we expect that their extremities will be organized in cluster or along some preferred directions. The problem we want to solve with the EOF decomposition is to find an orthogonal basis $\{e_1, e_2, \dots, e_p\}$ in the p -dimensional space, instead of the original basis, such that vector e_1 best represents the largest cluster of the original data vectors, e_2 best represents the second largest cluster of the original data vectors, and so on. In other words, e_1 accounts for the largest portion of the data variance, e_2 for the second largest portion, and so on (Fig. 3). This is equivalent to find a set of p vector e_p whose orientation is such that the sum of the squares of the projections of all the n observation vectors f_n onto each e_p is maximized sequentially. The vectors $e_x, x = 1, \dots, p$ are mutually orthogonal and they are what we called the EOFs. If all possible EOF modes are used, then they define a space which has the same dimension as the original variable space and, hence, completely account for the variance in the original data. However, there is no advantage in retaining all of the EOF modes since there would have as many EOF modes as original variable and, thus, would not have simplified matters.

The first step is to decide on how many EOF modes are needed to adequately describe the dominant spatio-temporal characteristics of surface air temperatures, dewpoint temperature and apparent temperatures in Thailand. The scree plot proposed

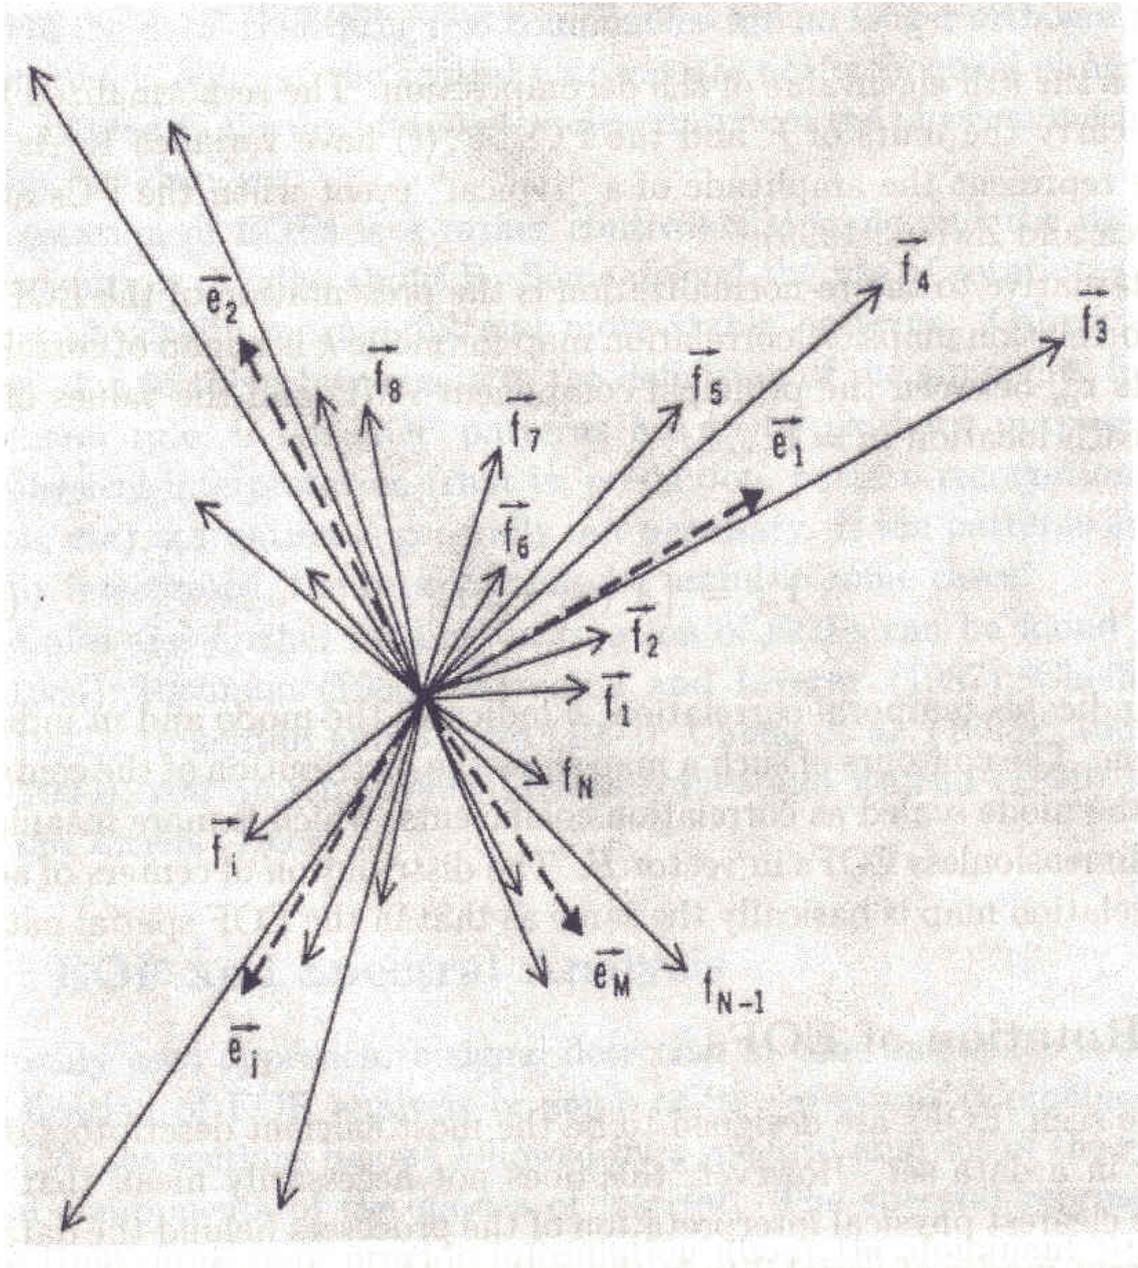


Fig. 3. Example of a possible configuration of the data vectors f_n ($n = 1 \dots N$ denote the time steps) and the empirical orthogonal vectors e_m , $m = 1 \dots M$. From Peixoto and Oort (1992).

by Cattell (1966) is one of the good rules of thumb, providing a means of assessing how many EOF modes to retain. It is constructed by simply plotting either eigenvalues or percentage of the total variance of each EOF mode in descending order to produce a line graph. Since the leading EOF mode has the largest eigenvalue or the largest percentage of the total variance, and the following ones are in descending value, this produces a line graph that slopes down to the right. By looking for the point where a pronounced change in the slope occurs, how many EOF modes to retain can thus be decided. It should be noted that this criterion is somewhat arbitrary, and how many and which EOF modes to retain depend, in part, upon the goals of the analysis.

The scree plots for individual and cumulative percentages of the total variance of monthly averaged mean, maximum and minimum temperatures (T_{mean} , T_{max} , T_{min}), monthly averaged mean dewpoint temperature (T_{dew}) and monthly averaged mean, maximum and minimum apparent temperatures (T_{amean} , T_{amax} , T_{amin}) are presented in Figs. 4, 5 and 6. What stands out from Figs 4, 5 and 6 is that steep slopes are evident from the first to the second EOF modes and the remaining EOF modes can be fitted fairly well by a straight line of negligible slope. The EOF1 mode of all seven temperature variables accounts for substantial amount of the total variance ranging from 61.2% to 71.3%, whereas the remaining modes explain considerably less. These patterns of scree plots indicate that only the first mode is physically meaningful in determining the dominant mode of variability, and higher order modes are potentially mixed and non-interpretible due largely to climatic noise associated with high-frequency variability in the climate system. Consequently, by using Cattell's scree criterion, only the EOF1 mode was retained to describe spatio-temporal characteristics of all temperature variables.

The loadings on the EOF1 mode of all seven temperature variables are graphically illustrated in Figs. 7-13. A visual examination reveals that the EOF1 mode of each temperature variable has positive correlations with all stations, and correlation coefficients are relatively high and are about the same magnitude, excepting for a few stations in the south. High ($r > 0.5$) and low ($r < 0.5$) loadings on the leading modes range from 75% to 90% and from 10% to 25%, respectively. These loading patterns strongly indicate that temperature data at all stations in Thailand are highly intercorrelated and nearly equally important in defining the EOF1 mode. Thus, it can be appropriately viewed that the EOF1 mode is a robust representative of the dominant spatio-temporal structures of T_{mean} , T_{max} , T_{min} , T_{dew} , T_{amean} , T_{amax} and T_{amin} in Thailand.

Time evolution of the leading mode of all seven temperature variables is shown in the time series of their coefficients (Figs. 14, 15 and 16). Note that units are arbitrary, because of EOF calculation based on covariance matrix. As can be seen, all series exhibit irregular oscillations, due to a mixture of several signals of variability contained in the time series. As indicated by the integral timescales, all series form complex long-term patterns and are rather noisy, which month-to-month variations are prominent, superimposed on much lower-frequency variations with timescales of a few years or longer. Some underlying periodic oscillations and trends also seem to be present in the time series. A visual inspection further reveals that two series of T_{min} and T_{amin} do appear to contain the dominant long-term trends. However, inferences about the dominant temporal characteristics of the leading modes from unsmoothed series are relatively obfuscating, due to the presence of various scales of motion in time series. In

order to gain insight on the particular signals blended together and hidden inside a noisy time

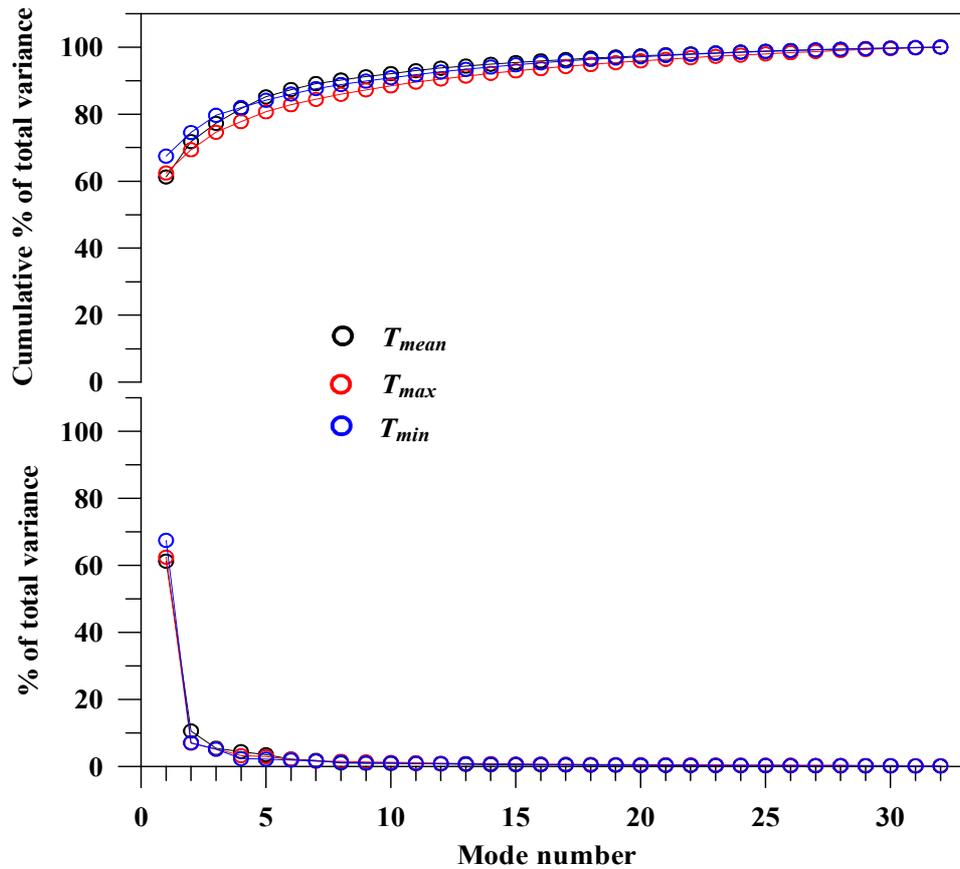


Fig. 4. Scree plot for EOF analysis of monthly averaged mean, maximum, minimum temperatures (T_{mean} , T_{max} , T_{min}) collected during 1951-2003 and at 33 stations in Thailand.

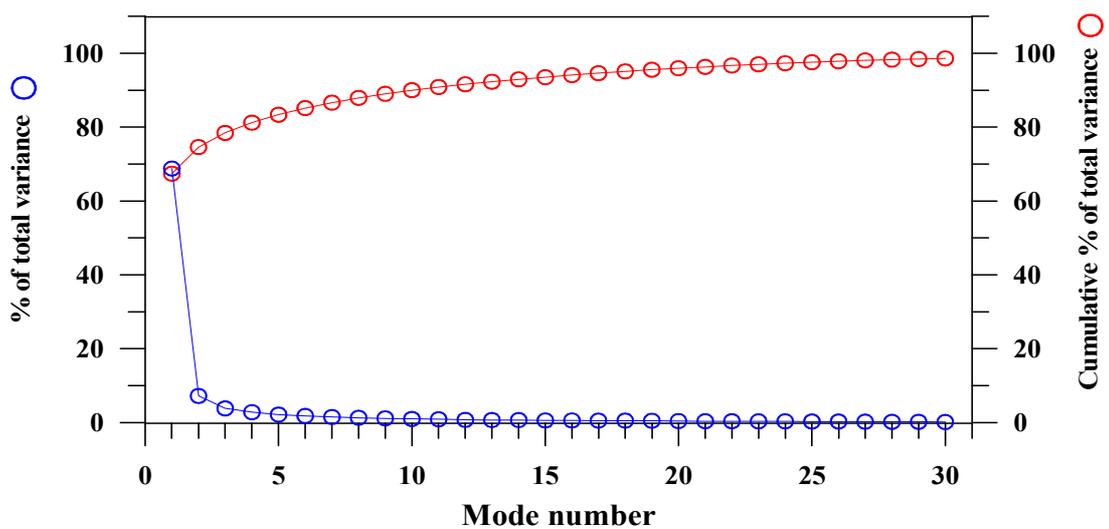


Fig. 5. Scree plot for EOF analysis of monthly averaged mean dewpoint temperature (T_{dew}) collected during 1951-2003 and at 30 stations in Thailand.

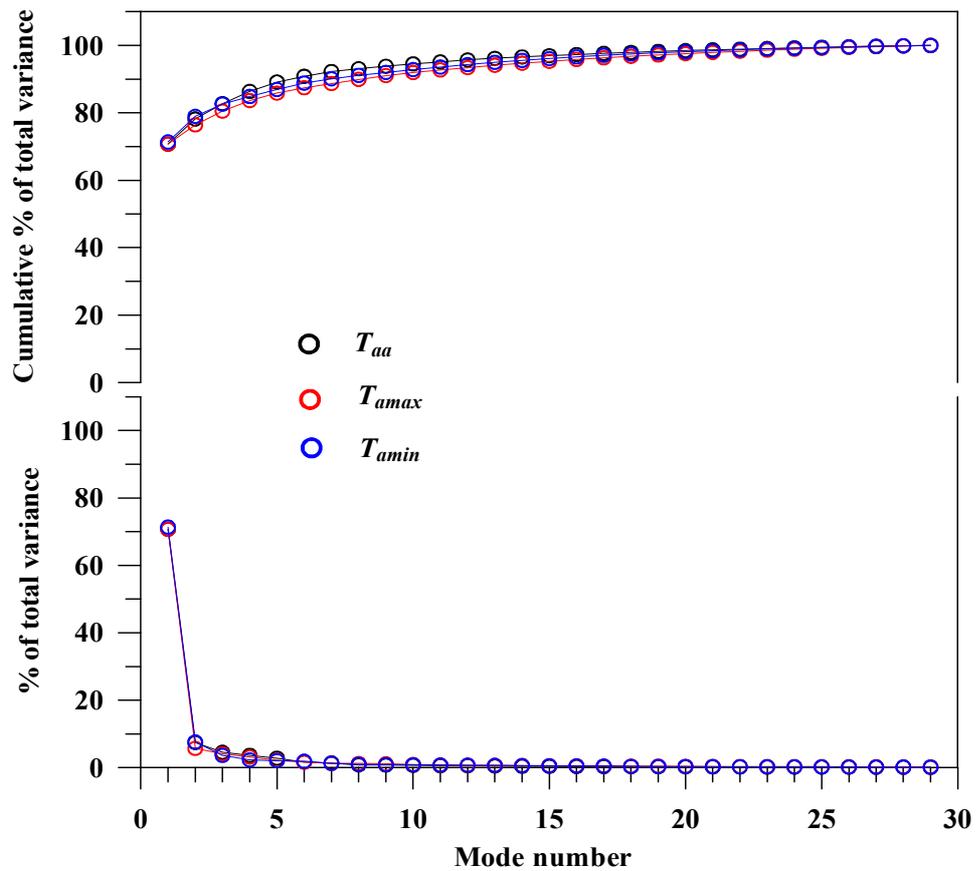


Fig. 6. Scree plot for EOF analysis of monthly averaged mean, maximum and minimum apparent temperatures (T_{aa} , T_{amax} , T_{amin}) calculated by using surface air temperature and dewpoint temperature collected during 1951-2003 and at 29 stations in Thailand.

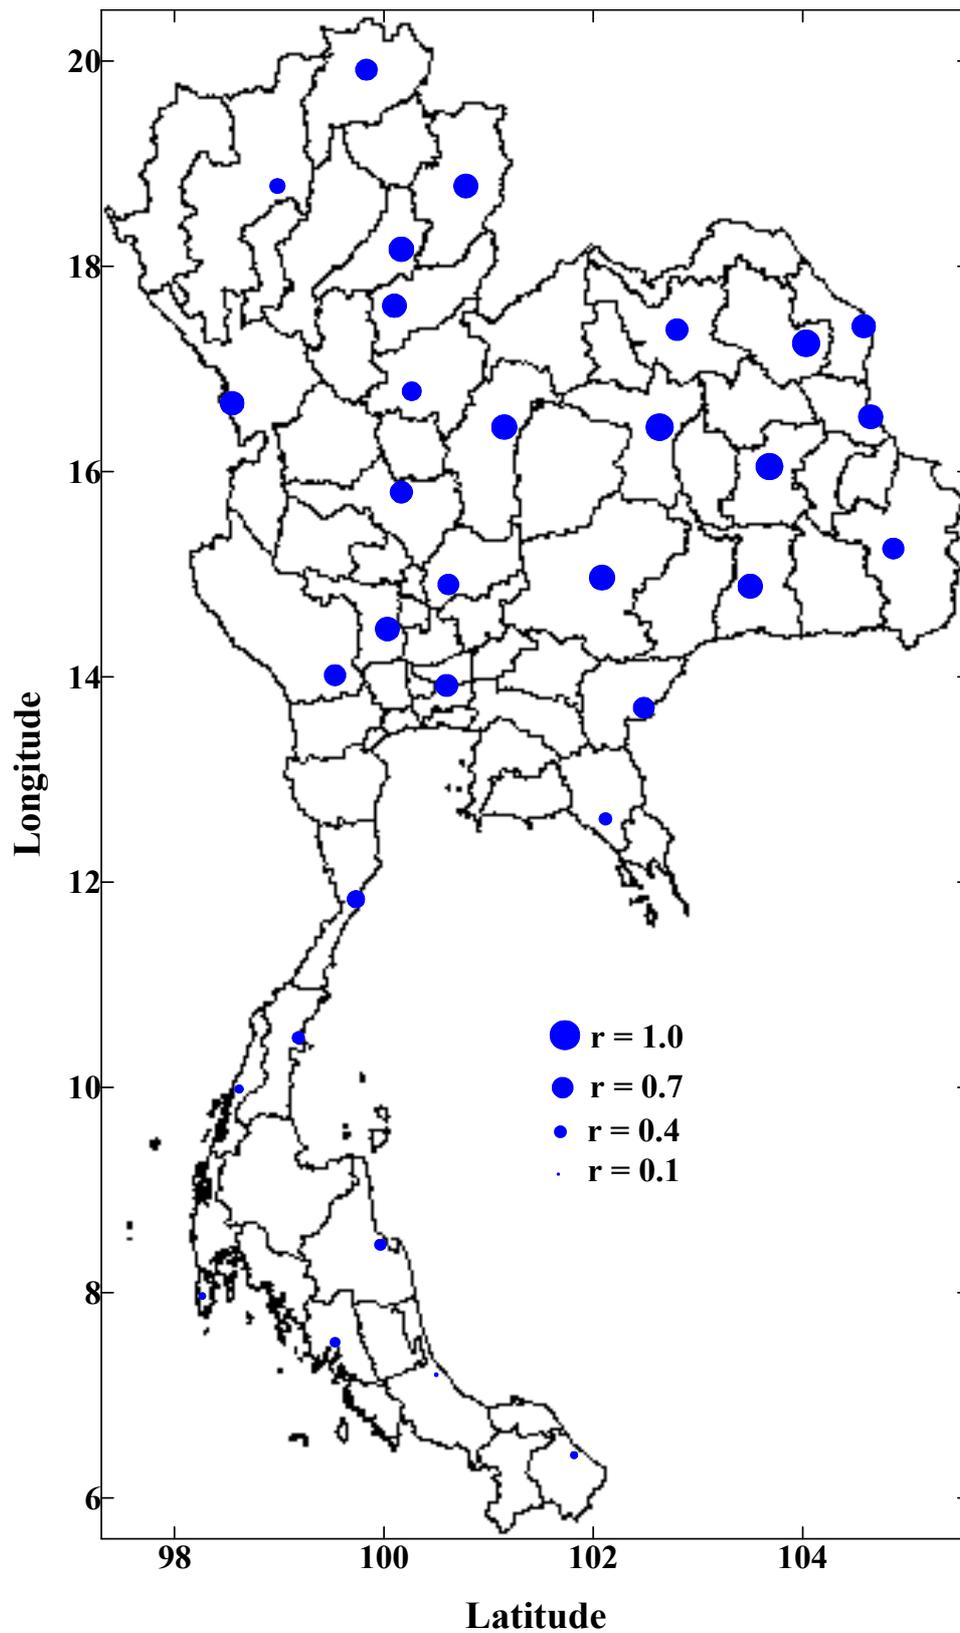


Fig. 7. Loadings on the EOF1 mode of monthly averaged mean temperature. The loadings are correlation coefficients between each time series and the first time-

dependent amplitudes. The sizes of blue circles are proportional to correlation coefficients.

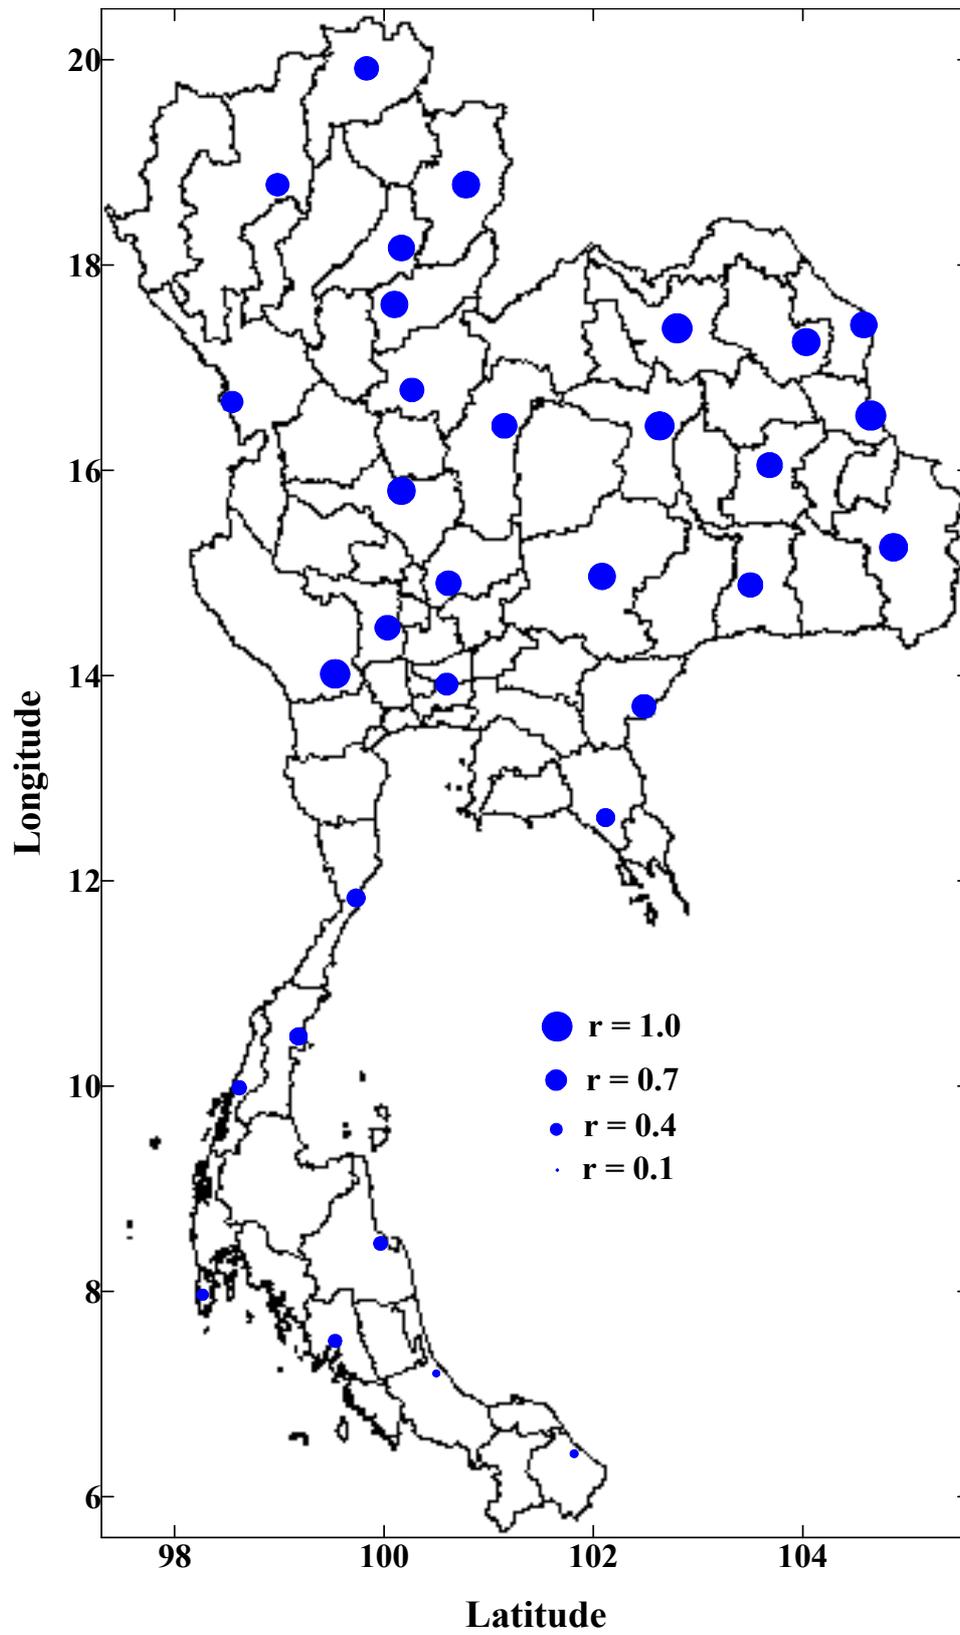


Fig. 8. Loadings on the EOF1 mode of monthly averaged maximum temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

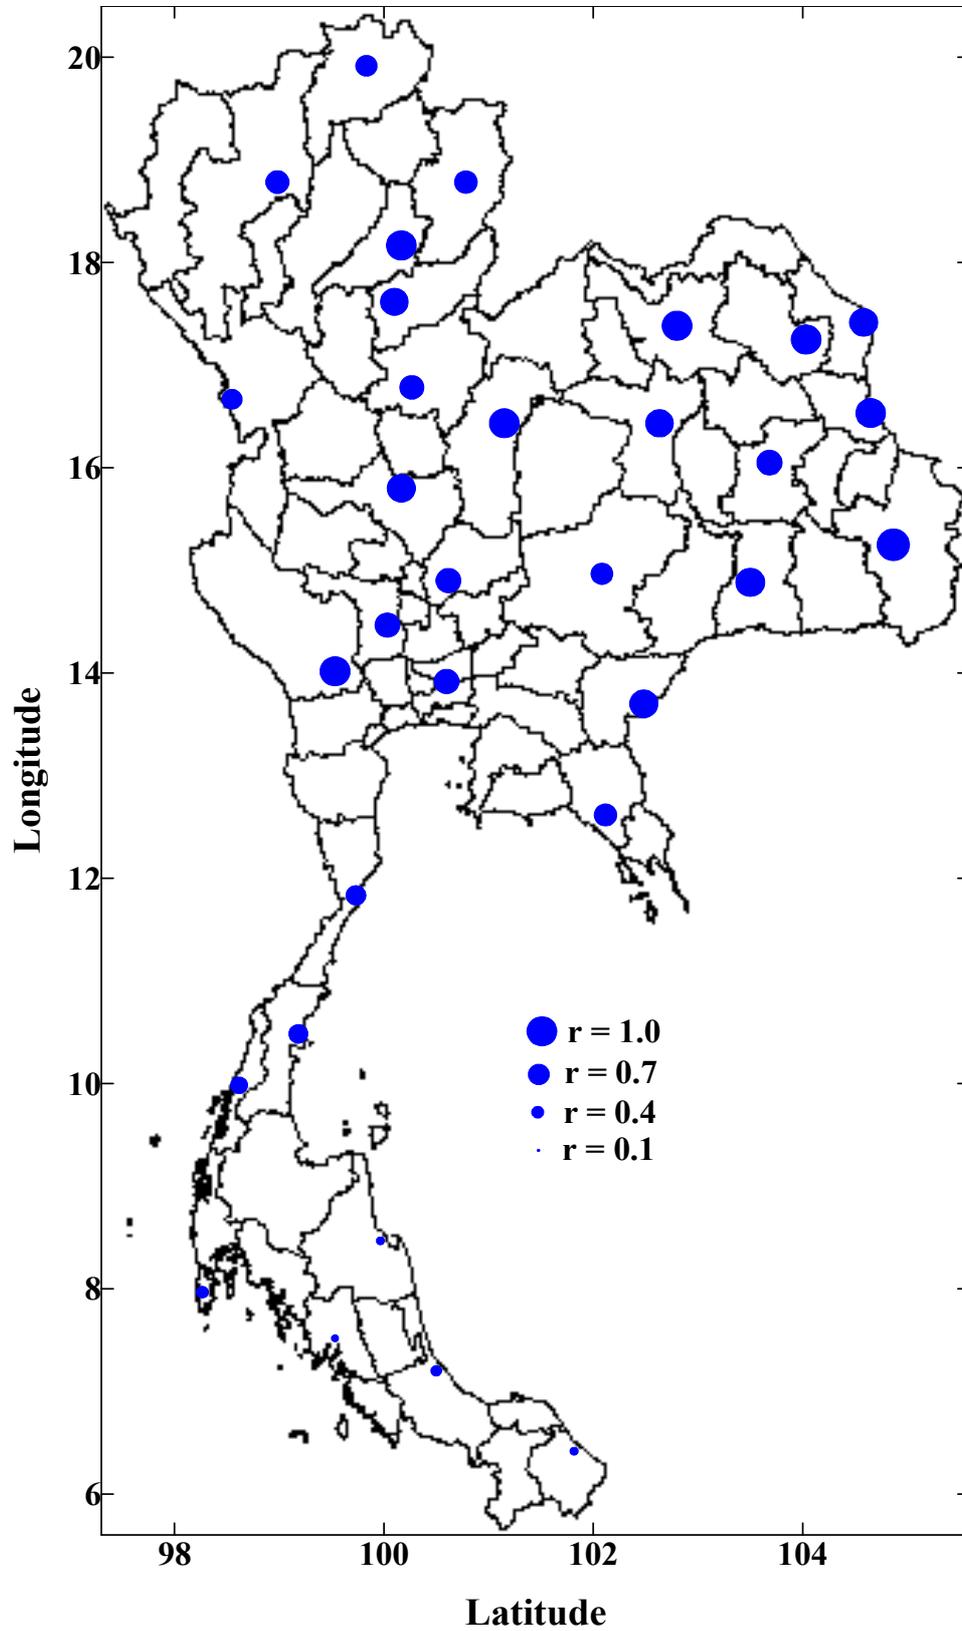


Fig. 9. Loadings on the EOF1 mode of monthly averaged minimum temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

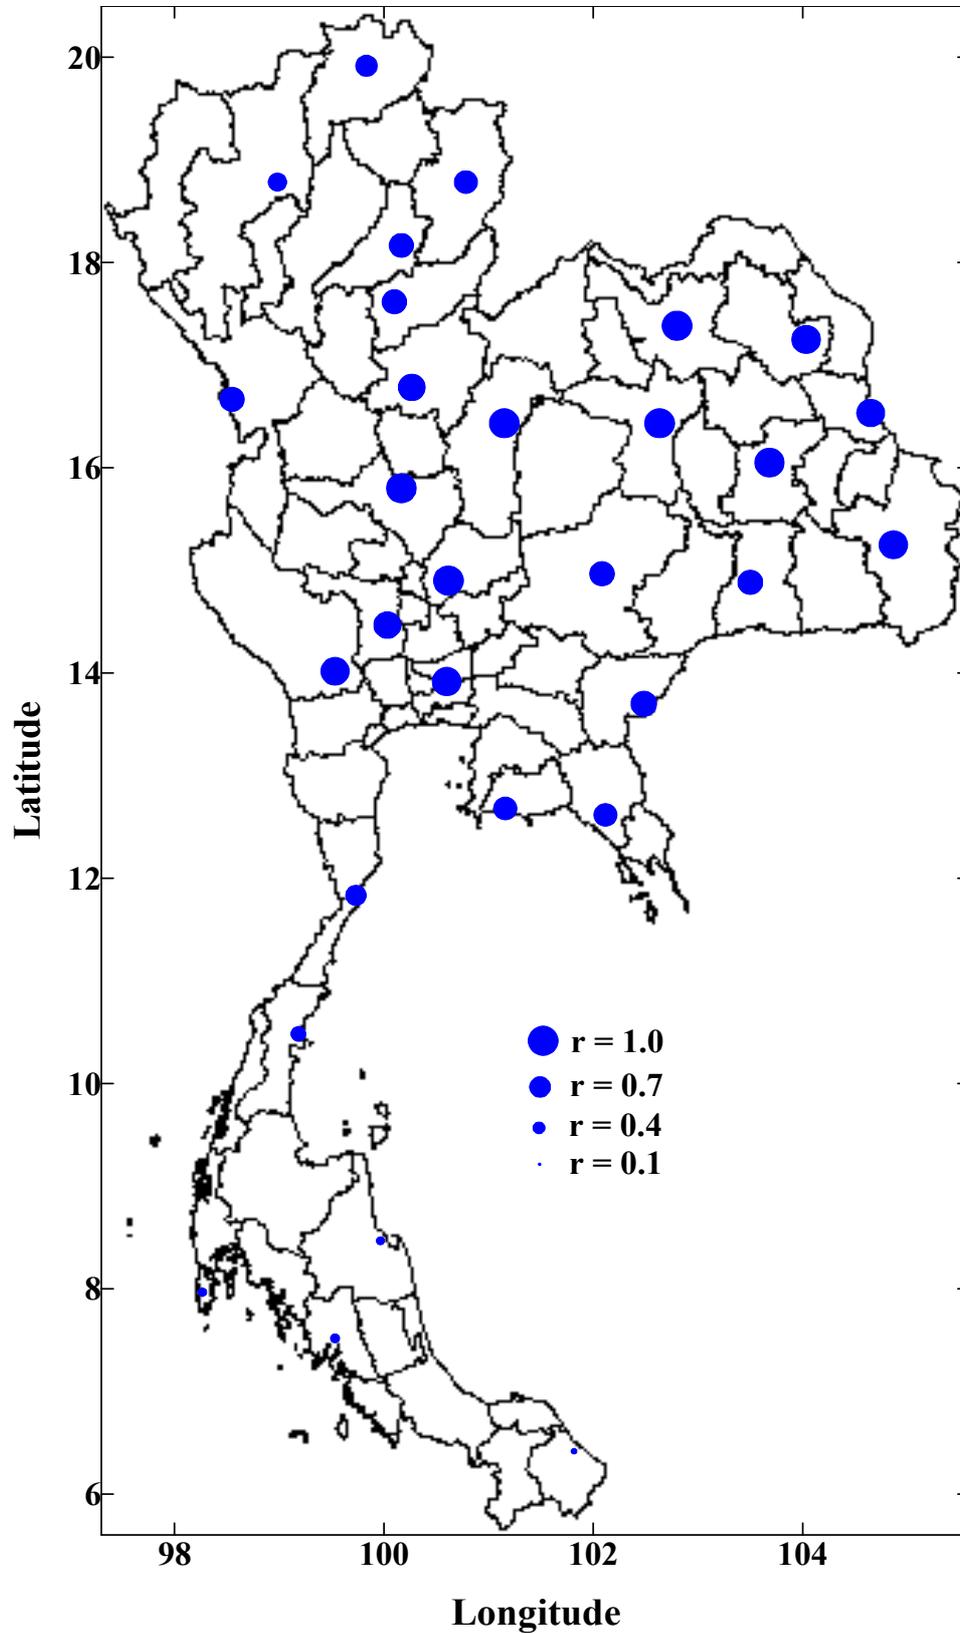


Fig. 10. Loadings on the EOF1 mode of monthly averaged dewpoint temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

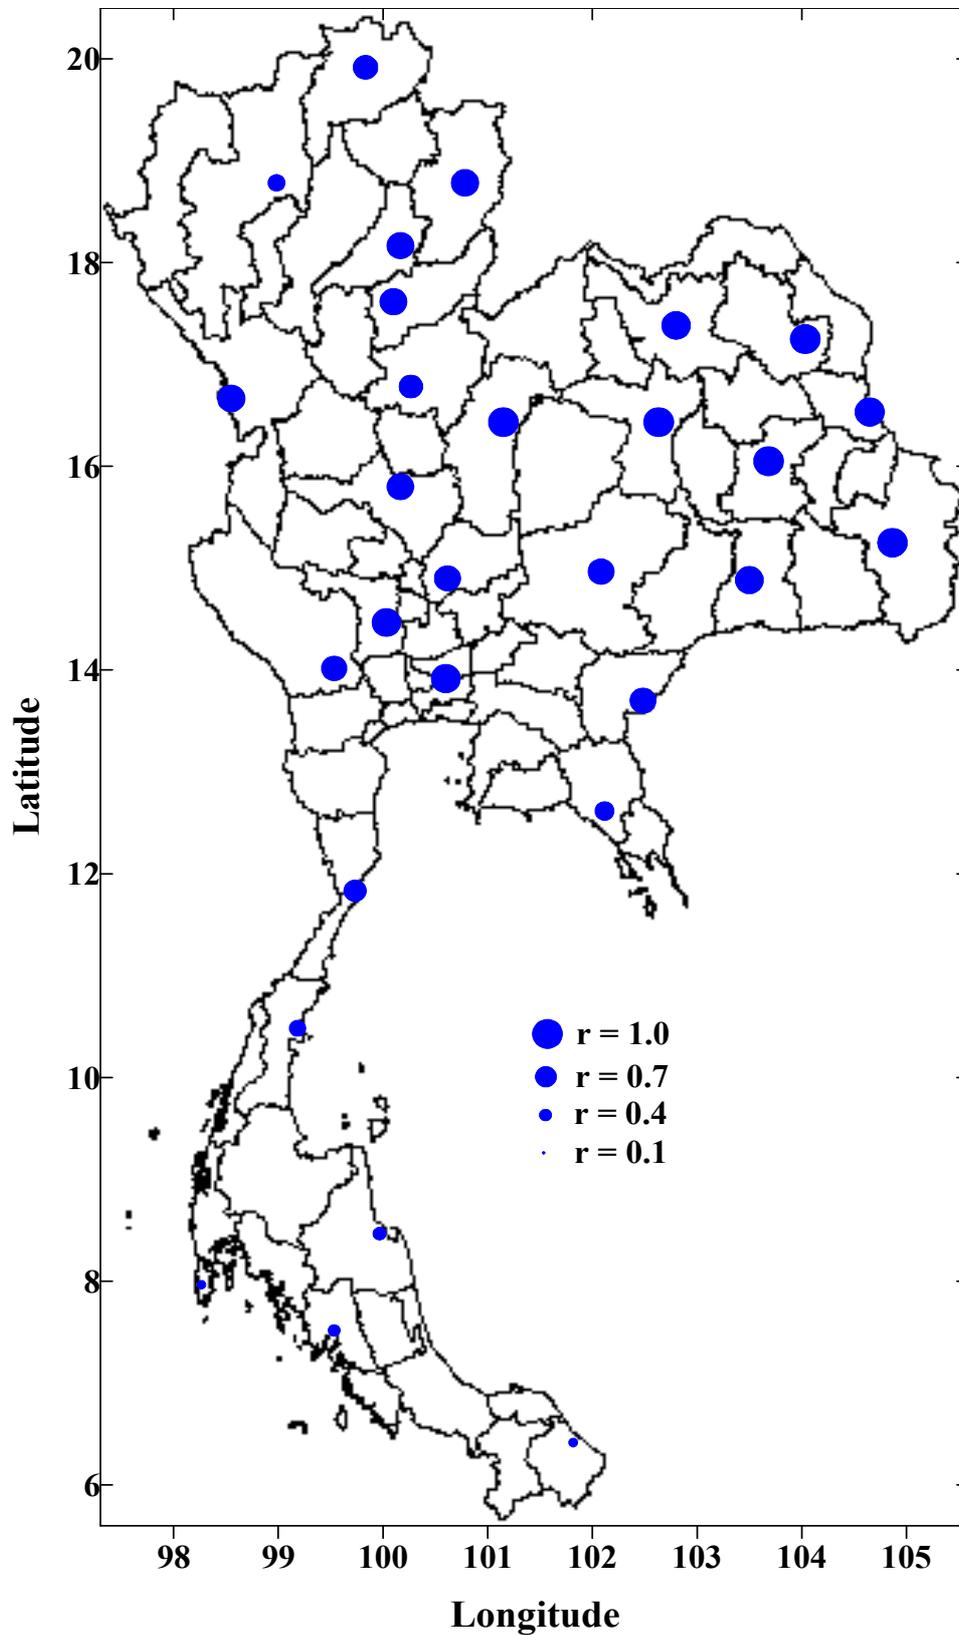


Fig. 11. Loadings on the EOF1 mode of monthly averaged mean apparent temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

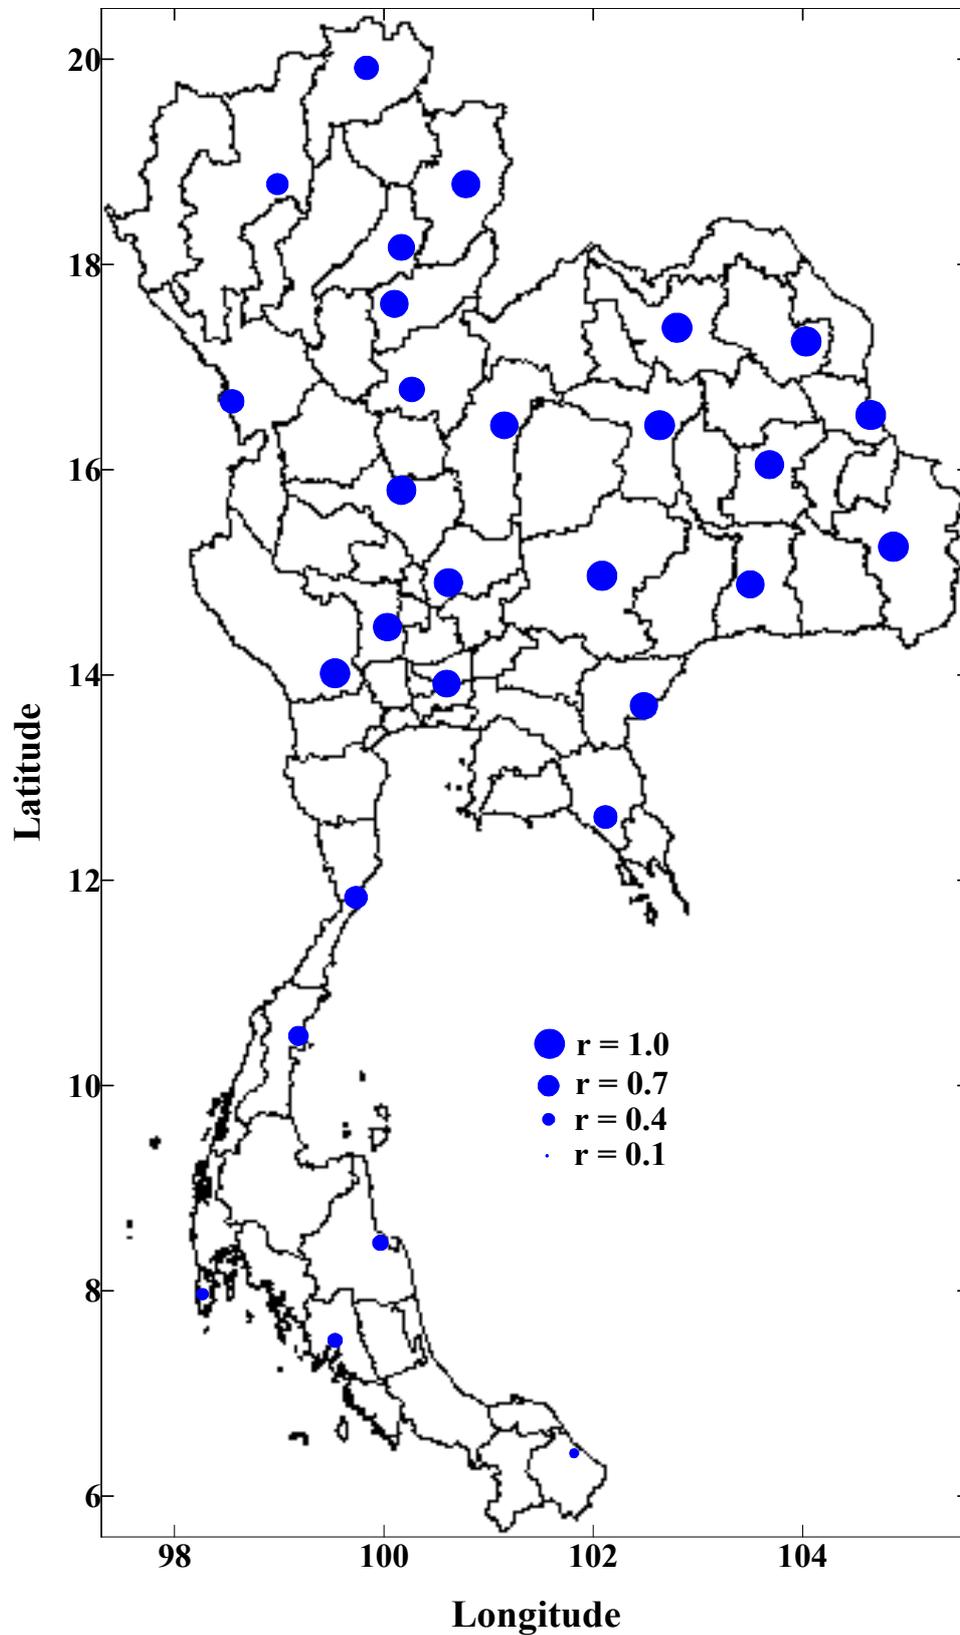


Fig. 12. Loadings on the EOF1 mode of monthly averaged maximum apparent temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

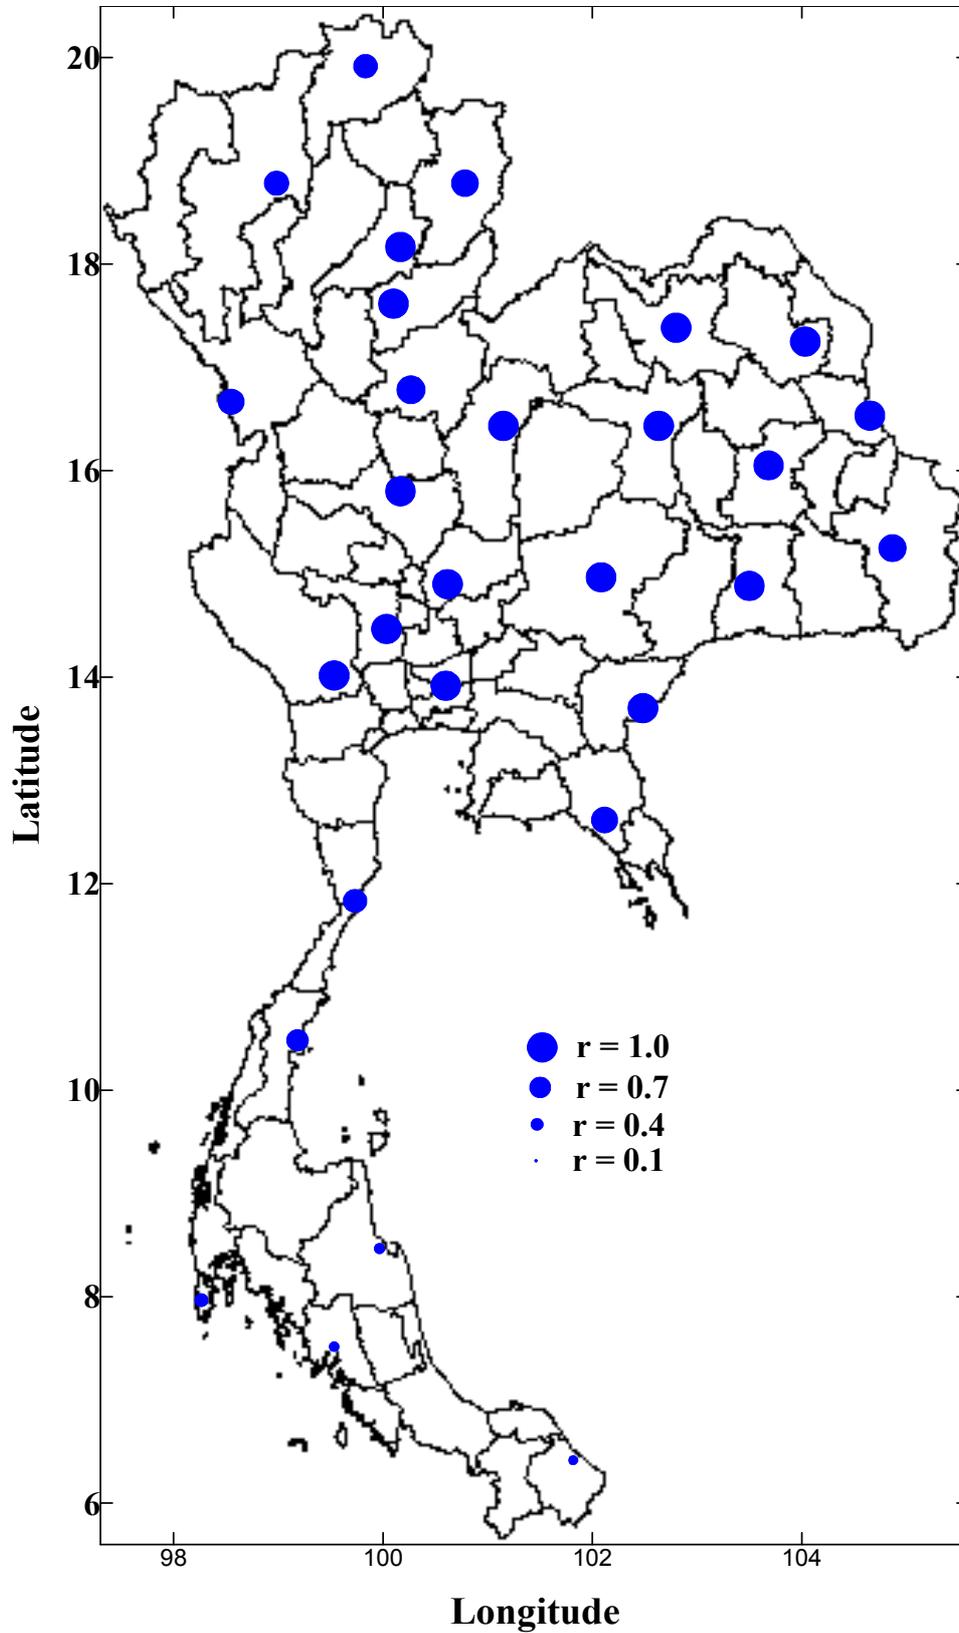


Fig. 13. Loadings on the EOF1 mode of monthly averaged minimum apparent temperature. The loadings are correlation coefficients between each time series and the first time-dependent amplitudes. The sizes of blue cycles are proportional to correlation coefficients.

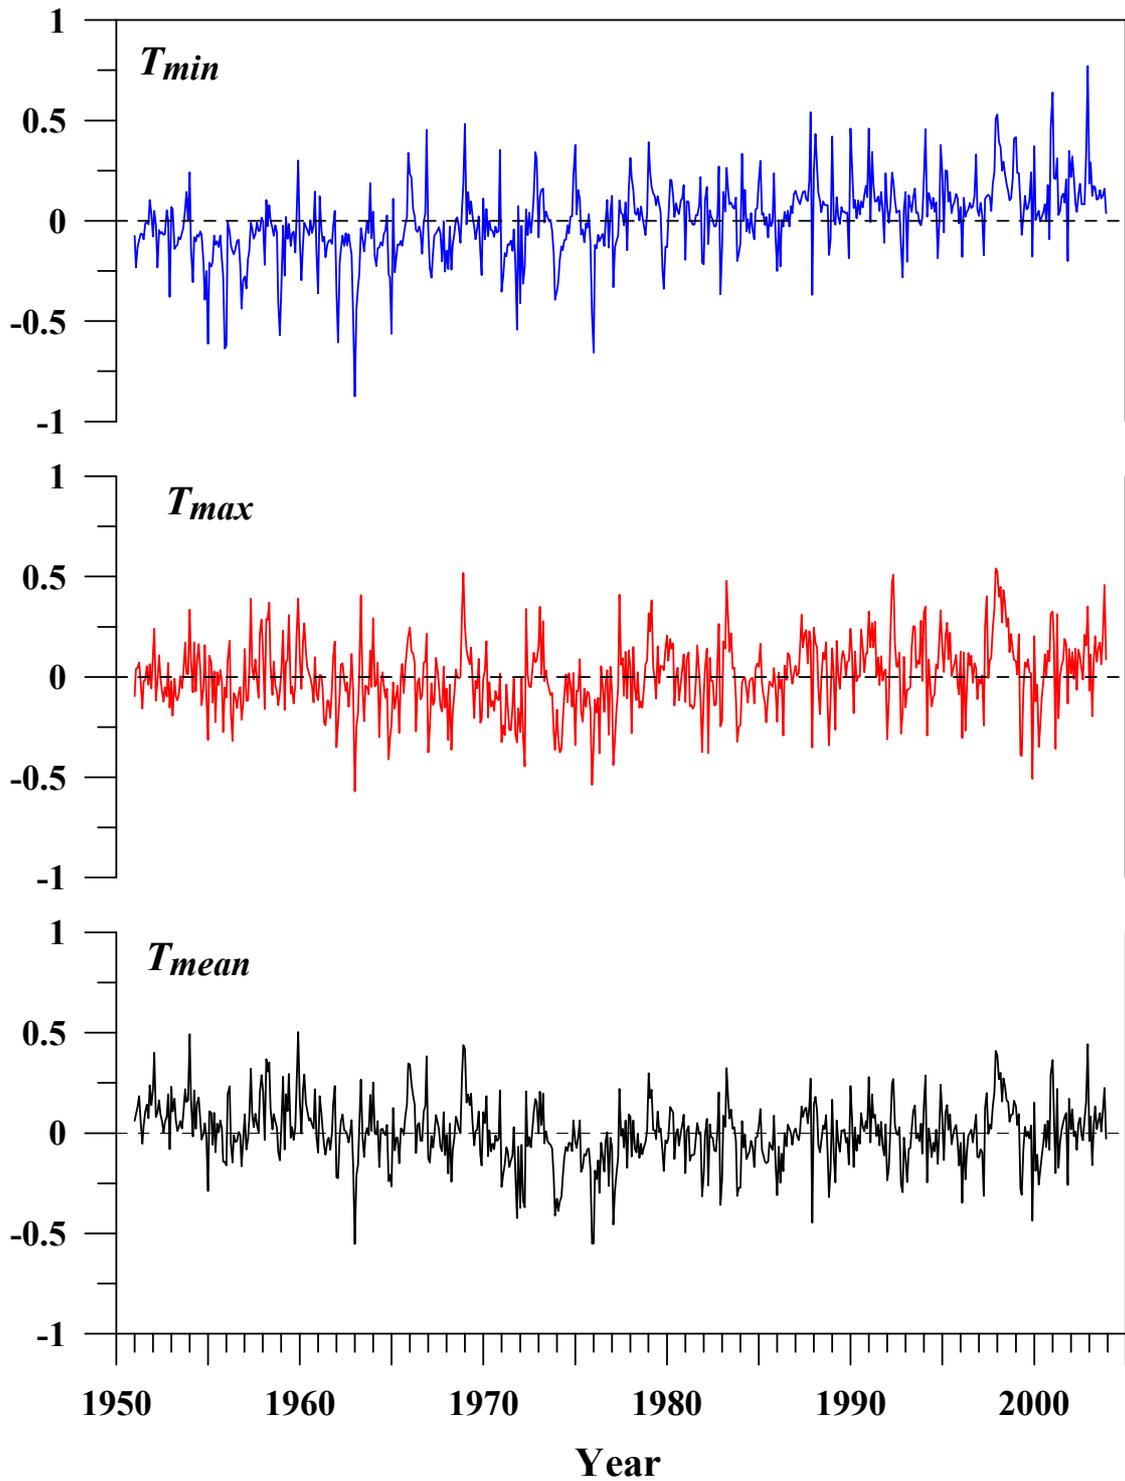


Fig. 14. Coefficient time series of the EOF1 mode. Units are relative.

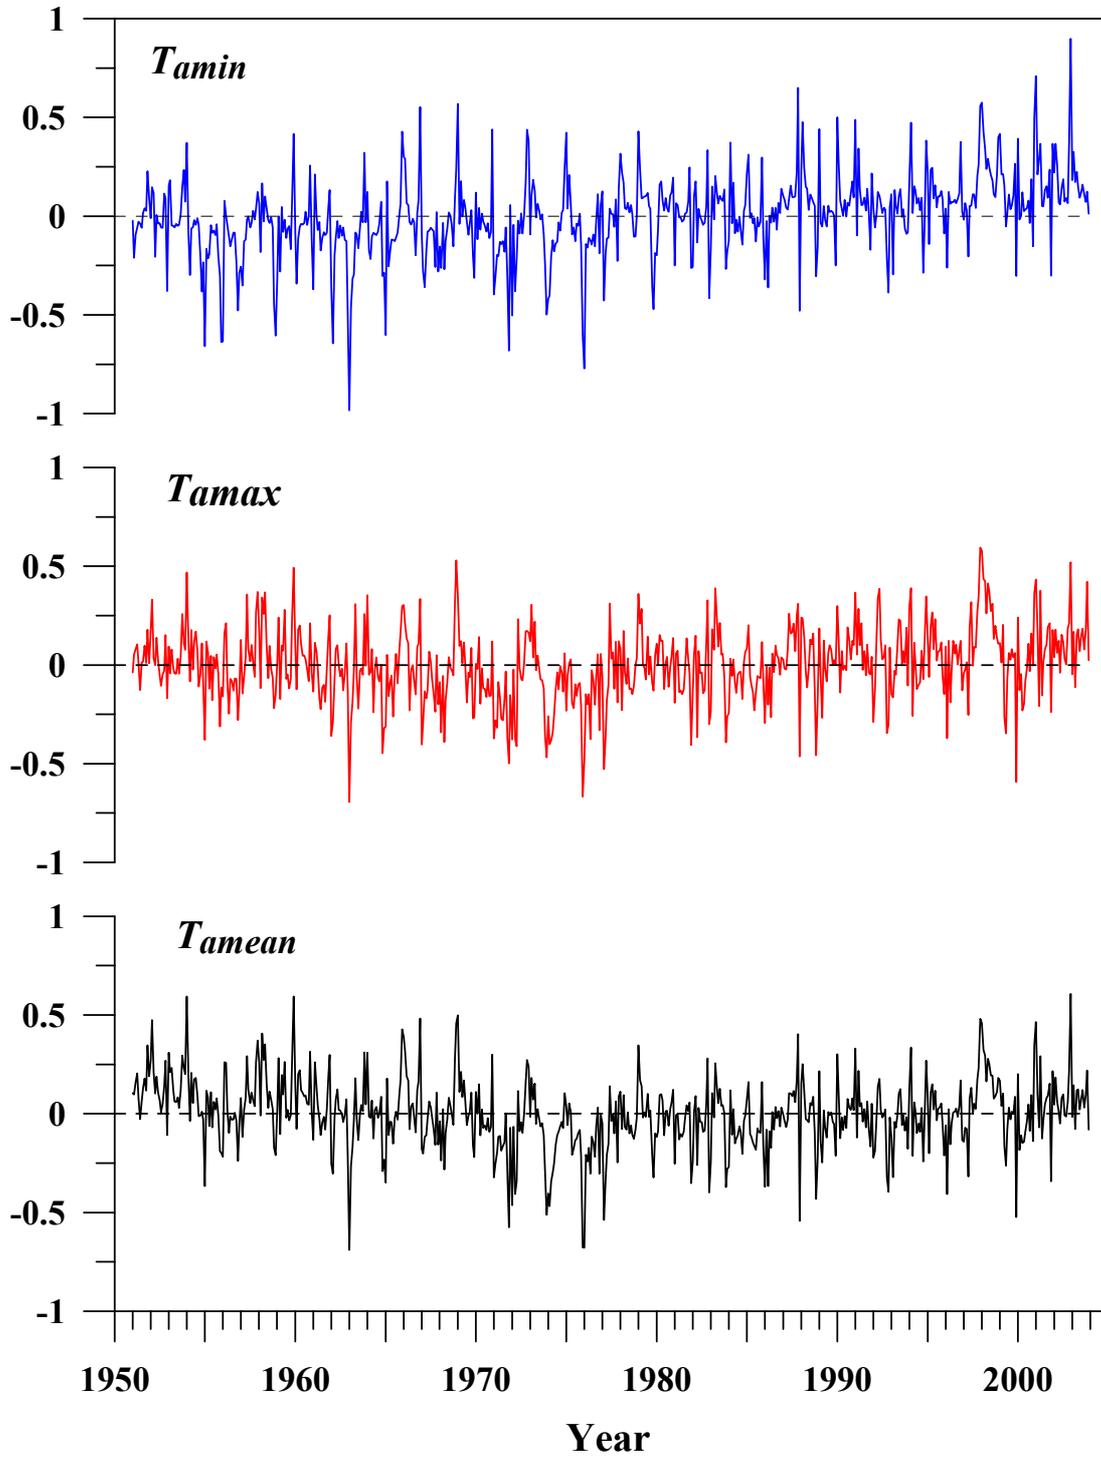


Fig. 15. Same as in Fig. 14.

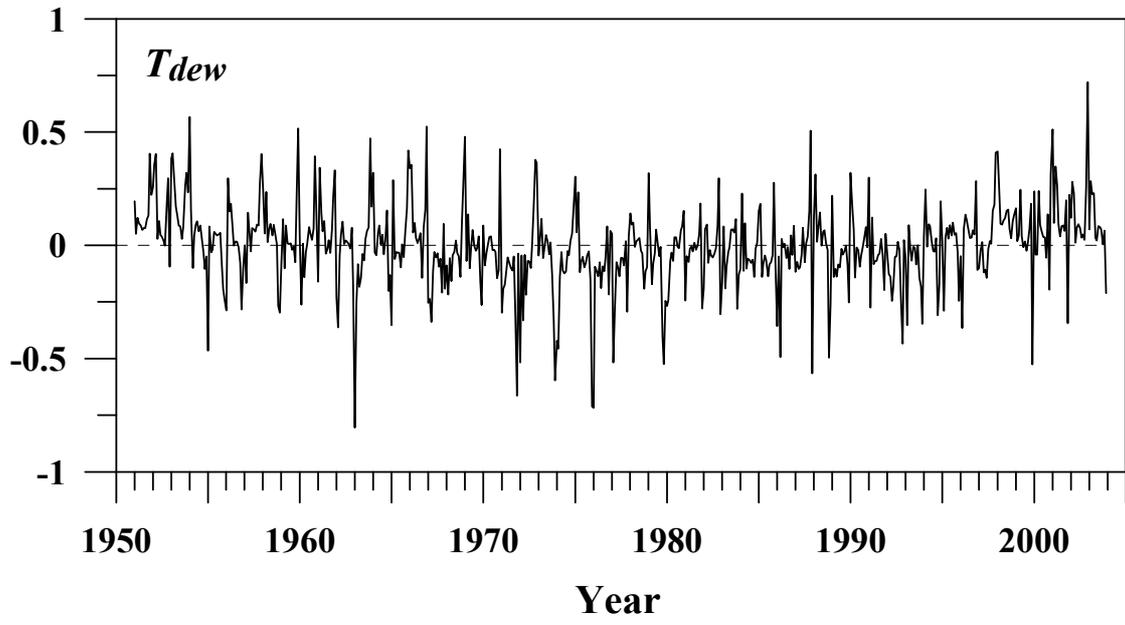


Fig. 16. Same as in Fig. 14.

series, undesired scales of variability must first be removed. The interesting signals can then be examined in isolation without the complications of the other features. The trend and other components can be separated by a smoothing technique (Chatfield, 1989; Jassby and Powell, 1990; Emery and Thomson, 1997). Smoothing always involves some form of local averaging of data such that the nonsystematic components of individual observations cancel each other out. The most common method is moving average smoothing which replaces each element of the series by simple average of n adjacent element, where n is the width of smoothing window (Chatfield, 1989; Jassby and Powell, 1990; Emery and Thomson, 1997; Eskridge et al., 1997). By modifying the window size, the filtering of different scales of motion can be controlled.

To further investigate and compare the standing temporal evolution of the leading mode with the well-known modes of global climate variability, each unfiltered series was decomposed into interannual (1-5 years) and decadal (longer than 5 years) timescales. The two different timescales were chosen on the basis that the separated interannual variability corresponds to the ENSO cycles, while decadal fluctuations represent long-term behavior of variables. Decomposition of the coefficient time series can be done by first applying a centered 60-term moving average. The resulting filtered series represent long-term variations. Interannual variability was subsequently estimated by subtracting the smoothed from the original series, forming the residual series. A centered 10-term moving average was then employed to the residual series to eliminate the variability less than ten months.

3.2. Temporal variability of EOF1 coefficients series and its relation to ENSO signature

3.2.1. Fundamental mechanisms of ENSO and the commonly used indices

The term El Niño is widely used to refer to a phenomenon associated with the unusually warm water that occasionally forms across much of the tropical eastern and central Pacific (Fig. 17). The time between successive El Niño events is irregular but they typically tend to recur every 2 to 7 years (*e.g.*, Horel and Wallace, 1981; Philander, 1990; Trenberth, 1984, 1997; McPhaden, 1999). A La Niña is the counterpart to an El Niño and is characterized by cooler than normal Sea Surface Temperatures (SSTs) across much of the equatorial eastern and central Pacific (Fig. 18). A La Niña event often, but not always, follows an El Niño and vice versa. Once developed, both El Niño and La Niña events tend to last for roughly a year although occasionally they may persist for 18 months or more. El Niño and La Niña are both a normal part of the earth's climate and there is recorded evidence for their occurrence for hundreds of years (Trenberth, 1997; Gill and Rasmusson, 1983; Gu and Philander, 1995; Huber and Caballero, 2003; Fedorov and Philander, 2000).

Although El Niño and La Niña events are characterized by warmer or cooler than average SSTs in the tropical Pacific, they are also associated with changes in patterns of wind, pressure, rainfall, air temperature and total cloudiness fraction of the

sky (Horel and Wallace, 1981; Philander, 1983, 1990; McPhaden, 1999). Schematic views of the links between SSTs and other atmospheric components are illustrated in Fig. 19. In normal conditions, the trade winds blow towards the west across the tropical Pacific. These winds pile up warm surface water in the western Pacific, so that the sea surface is about 0.5 meter higher at Indonesia than at Ecuador. The SST is about 8 °C higher in the west, with cool temperature off South America, due to an upwelling of cold water from deeper levels (Fig. 19a). Rainfall is found in rising air over the warmest water, and the east Pacific is relatively dry (Fig. 19a). During El Niño events, the trade winds relax in the central and western Pacific leading to strong countercurrent which carries warm water across the equatorial region, and a depression of the thermocline in the eastern Pacific and an elevation of the thermocline in the west (Fig. 19b). This reduces the efficiency of upwelling to cool the surface, resulting in a dramatic rise in SST off South America (Fig. 19b). Rainfall follows the warm water eastward, with associated flooding in Peru and drought in Indonesia and Australia (Fig. 19b). The eastward displacement of the atmospheric heat source overlying the warmest water results in large changes in the global atmospheric circulation, which in turn force changes in weather in remote regions far from the tropical Pacific (Troup, 1965; Horel and Wallace, 1981; Wallace and Gutzler, 1981). While, La Niña conditions could be thought of as an enhancement of normal condition. During these events the trade winds strengthen, colder than average ocean water extends westward to the central Pacific, and the warmer than average SSTs in the western Pacific are accompanied by heavier than usual rainfall (Fig. 19c).

While the tropical ocean affects the atmosphere above it, so too does the atmosphere influence the ocean below it. In fact, the interaction of the atmosphere and ocean is an essential part of El Niño and La Niña events (the term coupled system is often used to describe the mutual interaction between the ocean and atmosphere). During an El Niño, sea level pressure tends to be lower in the eastern Pacific and higher in the western Pacific, while the opposite tends to occur during a La Niña. This see-saw in atmospheric pressure between the eastern and western tropical Pacific is called the Southern Oscillation (SO). The main centers of action of the SO are situated around Darwin (12.4 °S 130.9 °E) in the northern Australia and Tahiti (17.5 °S 149.6 °W) in the South Pacific (Fig. 20). Therefore, the difference in sea level pressures between the points has been long used as a standard measure of the SO (Troup, 1965). Since El Niño and the Southern Oscillation are related, the two terms are often combined into single phrase the El Niño-Southern Oscillation, or ENSO (Troup, 1965; Trenberth, 1984, 1997).

Several indices have been used to monitor ENSO. They have conventionally been calculated based only on sea level pressures at a combination of a few stations situated primarily near the main center of action of ENSO. These usually only involve those at Darwin and Tahiti (Troup, 1965; Trenberth, 1984, 1997; Ropelewski and Jones, 1987; Kiladis and van Loon, 1988). A drawback of this index is that it is based on the pressures at two points and therefore can easily be affected by local weather disturbances, making it somewhat “noisy” when viewed on a month-to-month basis. In recent decades, the indices based on SSTs have come into common usage because satellite and an observing network of buoys in the equatorial Pacific now allow for collection real time, high quality data. Indices based on SSTs (or, more often, its departure from long-term average) are those obtained by simply taking the average value over some specified region of the ocean (Wang, 1995; Trenberth and Hoar, 1996;

Trenberth, 1997). There are several regions of the tropical Pacific Ocean that have been highlighted as being important for monitoring and identifying El Niño and La Niña. The most common ones are illustrated in Fig. 21. For widespread global climate variability, NINO3.4 is generally preferred, because the SST variability in this region has the strongest effect on shifting rainfall in the western Pacific. This in turn leads to shift the location of rainfall from the western to central Pacific which modifies greatly where the location of the heating that drives the majority of the global atmospheric circulation. Newly generated version of index is the Multivariate ENSO Index (MEI) calculated as the first unrotated Principal Component of all six observed variables over the tropical Pacific (Wolter and Timlin, 1993, 1998). These six variables are: sea level pressure, zonal and meridional components of the surface wind, sea surface temperature, surface air temperature and total cloudiness fraction the sky. The MEI is computed separately for each of twelve sliding bi-monthly seasons (Dec/Jan, Jan/Fec , ..., Nov/Dec). Negative values of the MEI represent the cold ENSO phase (La Niña), while positive MEI values represent the warm ENSO phase (El Niño). Since the MEI integrates more information than other indices, it fully reflects the nature of the coupled ocean-atmosphere system, and thereby is better for monitoring ENSO phenomenon, including, for instance, world-wide correlations with surface temperatures and rainfall than the SOI or SST-based indices (Wolter and Timlin, 1993, 1998). To make the MEI comparable with the monthly coefficient time series of EOF1 mode of T_{mean} , T_{max} , T_{min} , T_{dew} , T_{amean} , T_{amax} and T_{amin} , the MEI values of month (i-1) and month (i) were averaged for the value of month (i), and the MEI series was then decomposed into interannual and decadal timescales.

3.2.2. Interannual variability of EOF1 coefficient series and its relationship with ENSO events

Residual EOF1 coefficient series of all seven temperature variables, after the fluctuations less than ten months were removed, exhibit a salient mode of interannual variability (Figs. 22, 23, 24, 25, 26, 27 and 28). All series show strong negative and positive signs, and the oscillations between maxima and minima with period of about 1-4 years stand out as reasonably clear signals above the otherwise noisy background of short term climatic fluctuations. The results from variance analysis reveal that variability on interannual timescale for all seven temperature variables ranges from 17.6 to 25.8 % of the total variance (Table 3). A closer examination of the data indicates that interannual variability of all but T_{min} accounts for the second source of the total variance (Table 3). A noteworthy feature emerged from Figs. 22-29 is that the interannual variability patterns of all seven temperature variables resemble that of MEI, and the anomalously positive/negative time-varying amplitudes of the EOF1 mode of them appear to be in phase with the warm/cold phase of ENSO (positive/negative MEI). There is a clear indication that T_{mean} , T_{max} , T_{min} , T_{dew} , T_{amean} , T_{amax} and T_{amin} in Thailand tend to warmer (colder) than normal during El Niño (La Niña) phase of ENSO. During the 6 strongest historic El Niño events, for example, all these variables were prominently higher than normal (Table 4), while they were anomalously lower than average during the 8 strongest historic La Niña events (Table 5). Moreover, the EOF1 coefficient series of all seven temperature variables underwent largest interannual variability during the recent extreme phase reversals of ENSO, when the 1997-98 El Niño, by some measures the strongest on record, was followed by the strong 1998 -2000 La Niña. A nonparametric Spearman rank correlation test provides further evidence that there were significant positive correlations between each smoothed EOF1 coefficient

series of surface temperature variables and the 10-term smoothed MEI series, for the 47-year period (Table 6). It is readily seen that the 10-term smoothed EOF1 coefficient series of T_{mean} , T_{max} , T_{amean} and T_{amax} have high correlations with that of the MEI, with correlation coefficients higher than 0.5 (Table 6). The similar but less pronounced

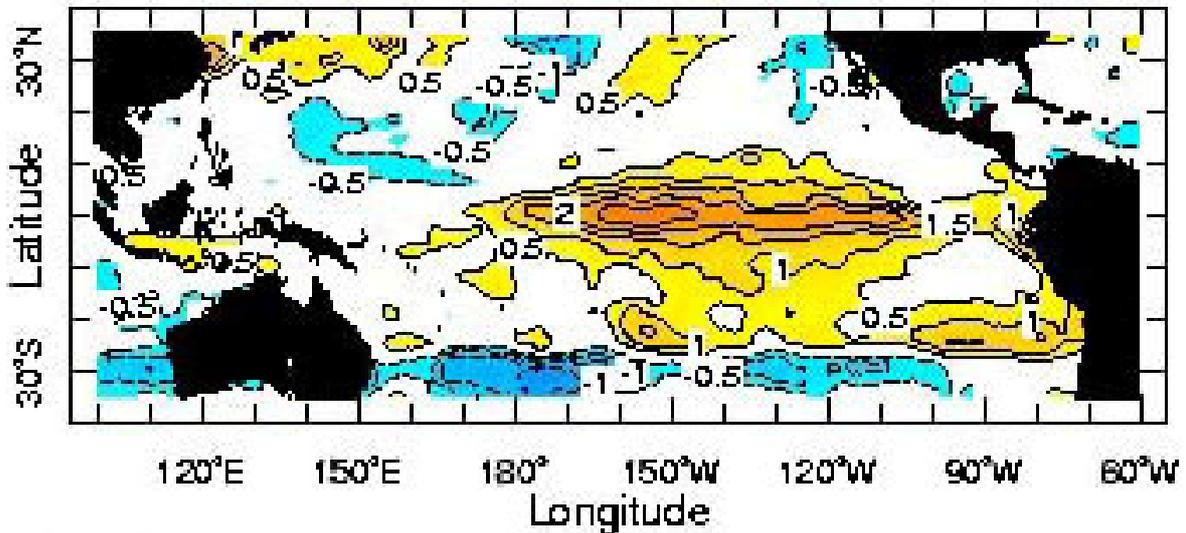


Fig. 17. An example of departure of sea surface temperature from the long-term average for an El Niño event during December 1991. Yellow shading indicates warmer than average temperatures. Units are °C and contours are drawn at 0.5 °C intervals. Note that this picture was obtained from website of International Research Institute for climate prediction (<http://iri.columbia.edu/climate/ENSO>).

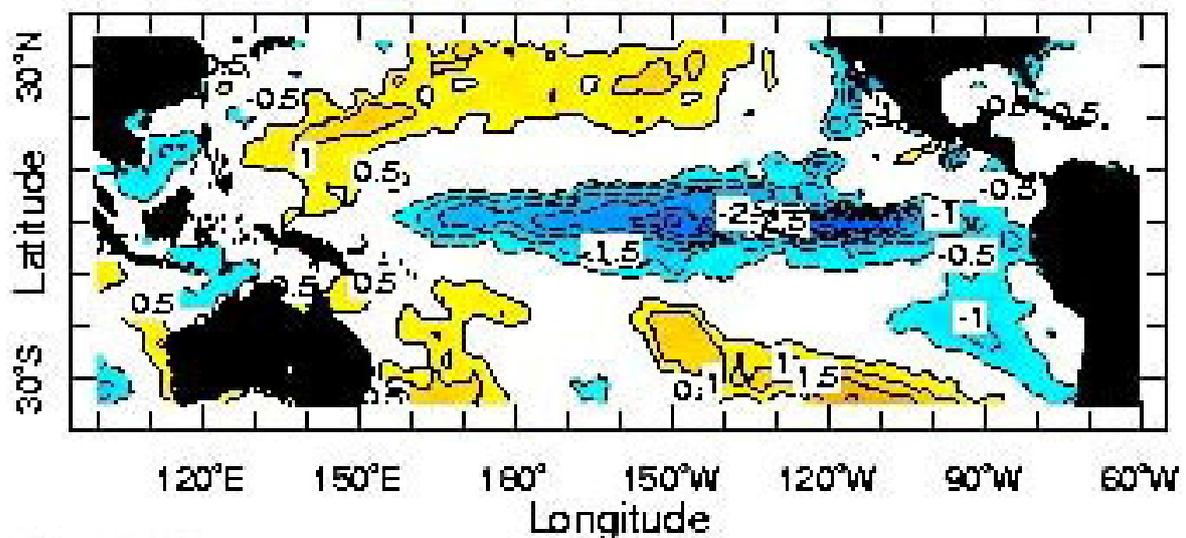
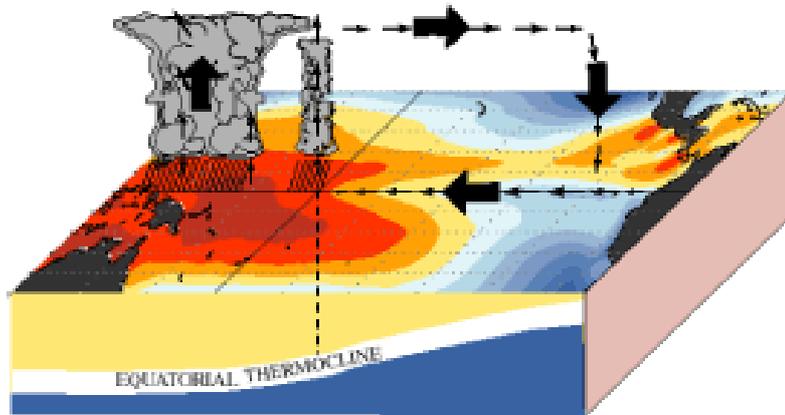


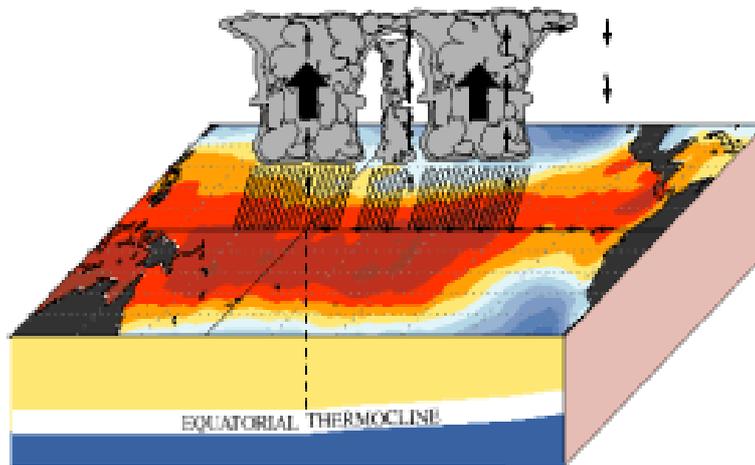
Fig. 18. An example of departure of sea surface temperature from the long-term average for a La Niña event during December 1998. Blue shading indicates colder than average

temperatures. Units are °C and contours are drawn at 0.5 °C intervals. Note that this picture was obtained from website of International Research Institute for climate prediction (<http://www.iri.columbia.edu/>) (TN100)

December - February Normal Conditions



December - February El Niño Conditions



December - February La Niña Conditions

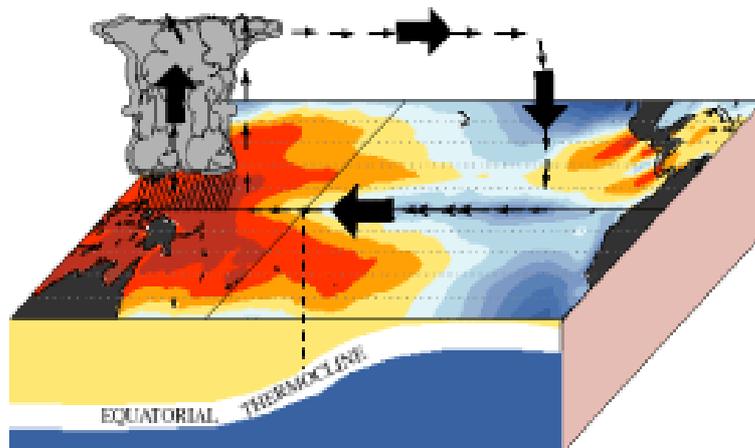


Fig. 19. Schematic views of the links between SSTs and tropical atmospheric variables in the equatorial Pacific ocean during normal (a), El Niño (b) and La Niña conditions (c). SSTs are shaded: blue-cold and orange-warm. The dark arrows indicate the direction of air movement in the atmosphere: upward arrows are associated with clouds and rainfall and downward-pointing arrows are associated with a general lack of rainfall. Note that this picture was obtained from website of International Research Institute for climate prediction (<http://iri.columbia.edu/climate/ENSO>).

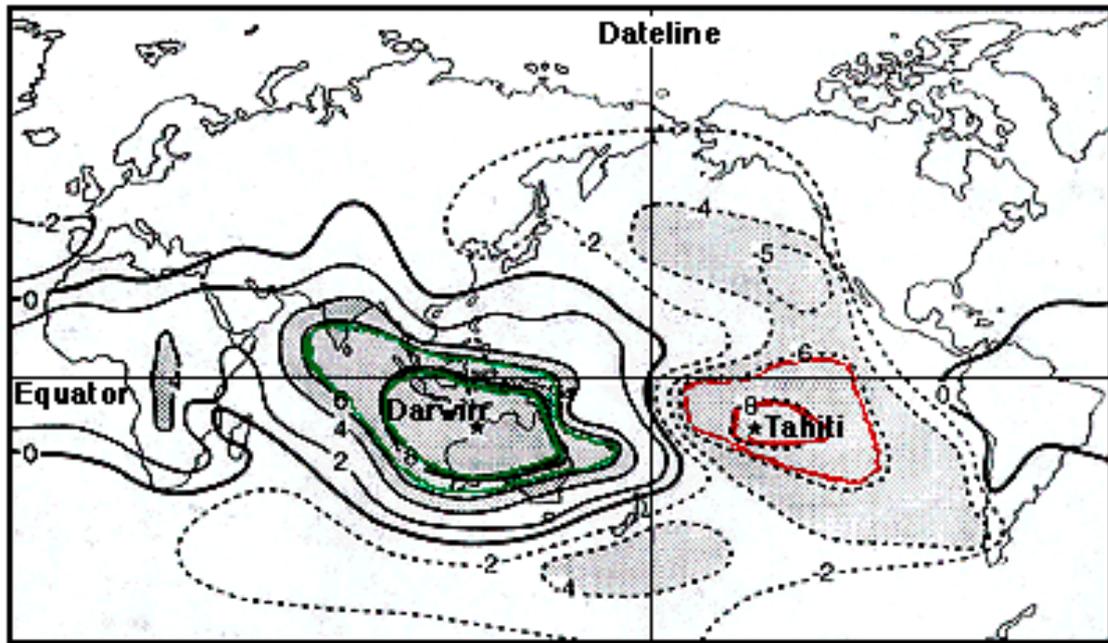


Fig. 20. The main centers of action of the Southern Oscillation. Tahiti and Darwin are at opposite ends of the Southern Oscillation's seesaw, and so the difference in pressure between them is used to measure the Southern Oscillation. The figure shows that pressure variation at Tahiti is as closely related to Darwin as are locations near to Darwin, but with the opposite sign. Note that this picture was obtained from website of International Research Institute for climate prediction (<http://iri.columbia.edu/climate/ENSO>).

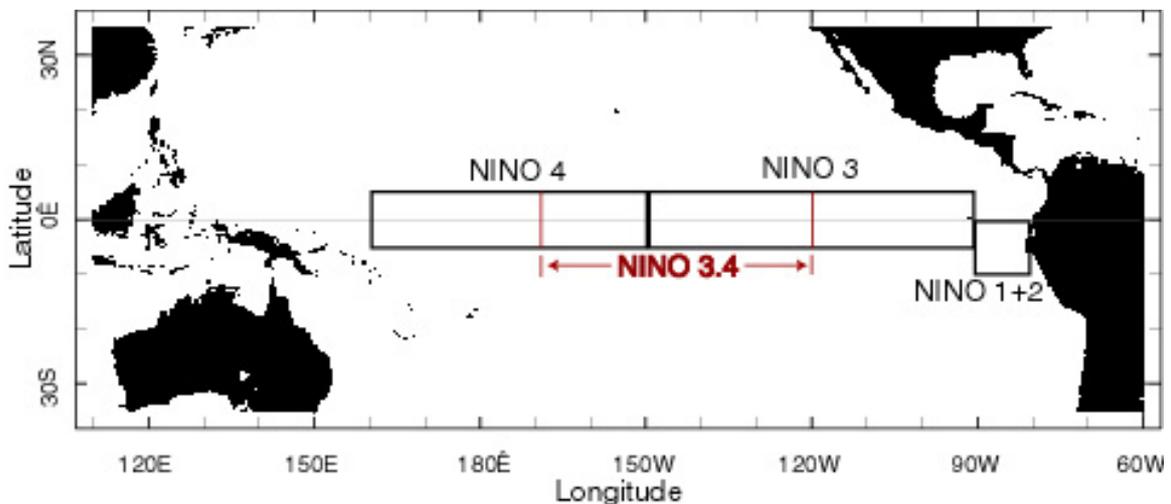


Fig. 21. The NINO regions. The thin grey line in the center is the equator. Note that this picture was obtained from website of International Research Institute for climate prediction (<http://iri.columbia.edu/climate/ENSO>).

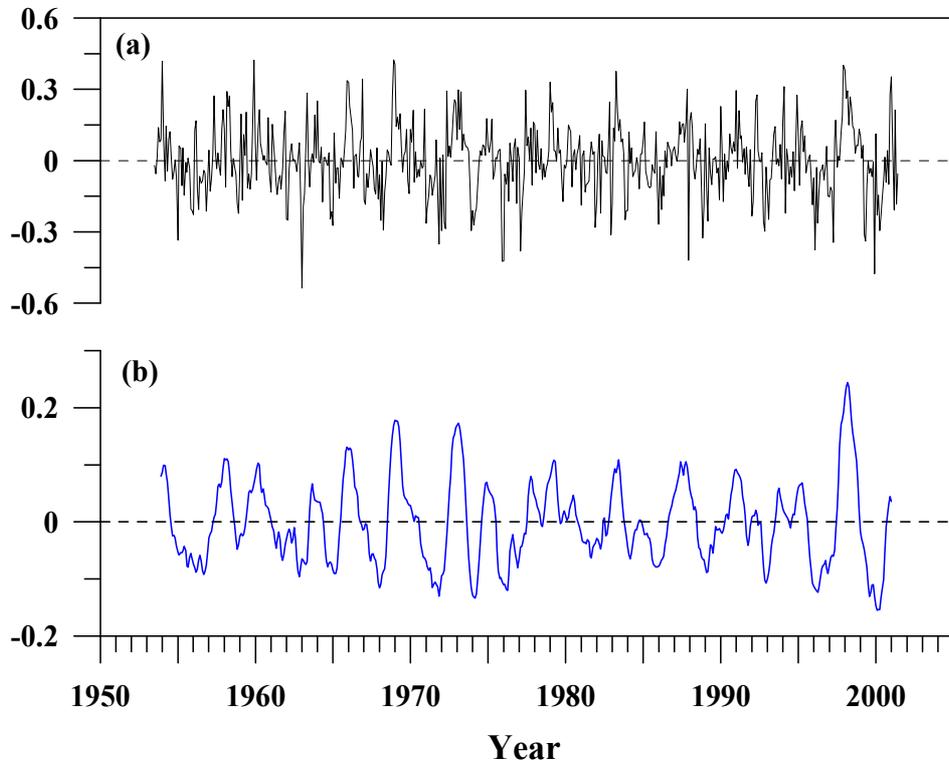


Fig. 22. The EOF1 coefficient series of T_{mean} residuals (original series minus 60-term smoothed series) (a) and 10-term smoothed T_{mean} residuals (b).

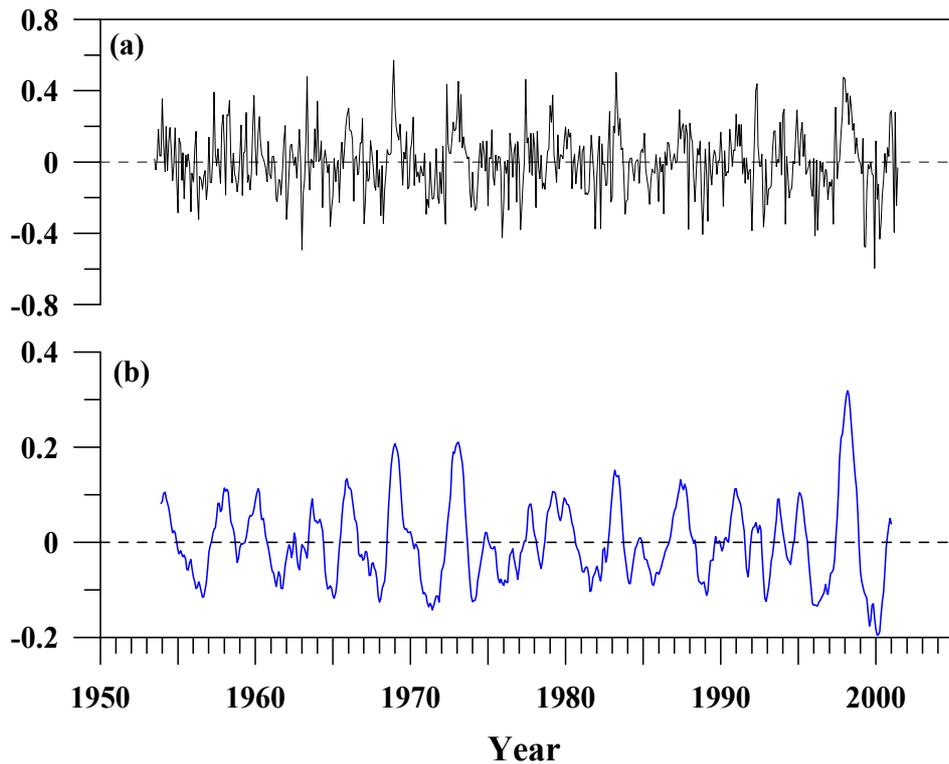
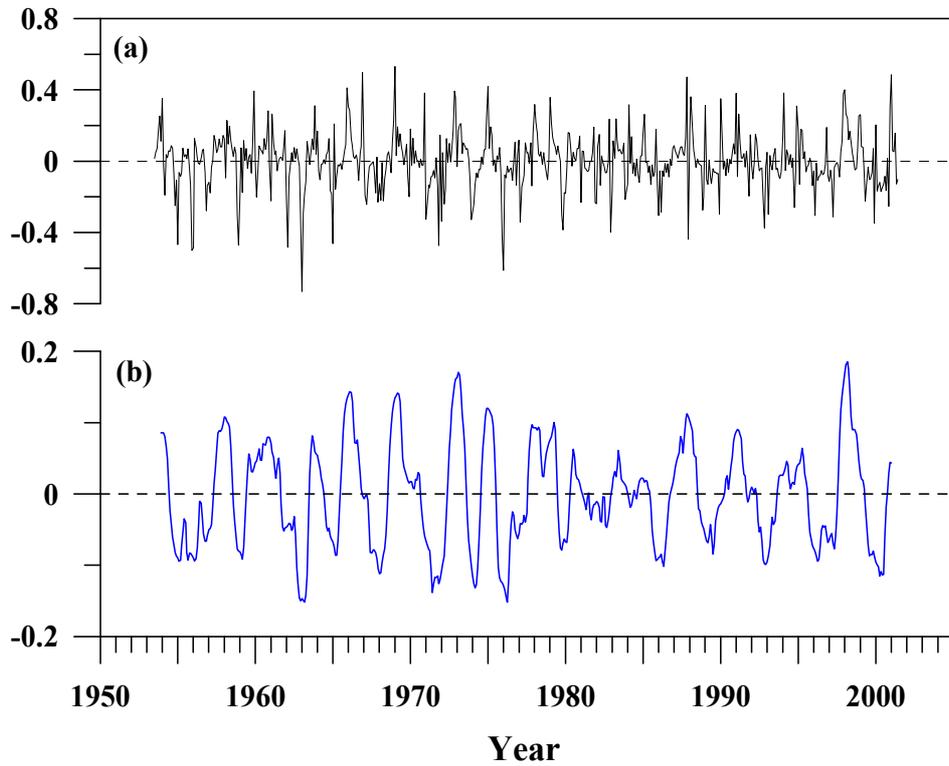


Fig. 23. The EOF1 coefficient series of T_{max} residuals (original series minus 60-term



smoothed series) (a) and 10-term smoothed T_{max} residuals (b).

Fig. 24. The EOF1 coefficient series of T_{min} residuals (original series minus 60-term smoothed series) (a) and 10-term smoothed T_{min} residuals (b).

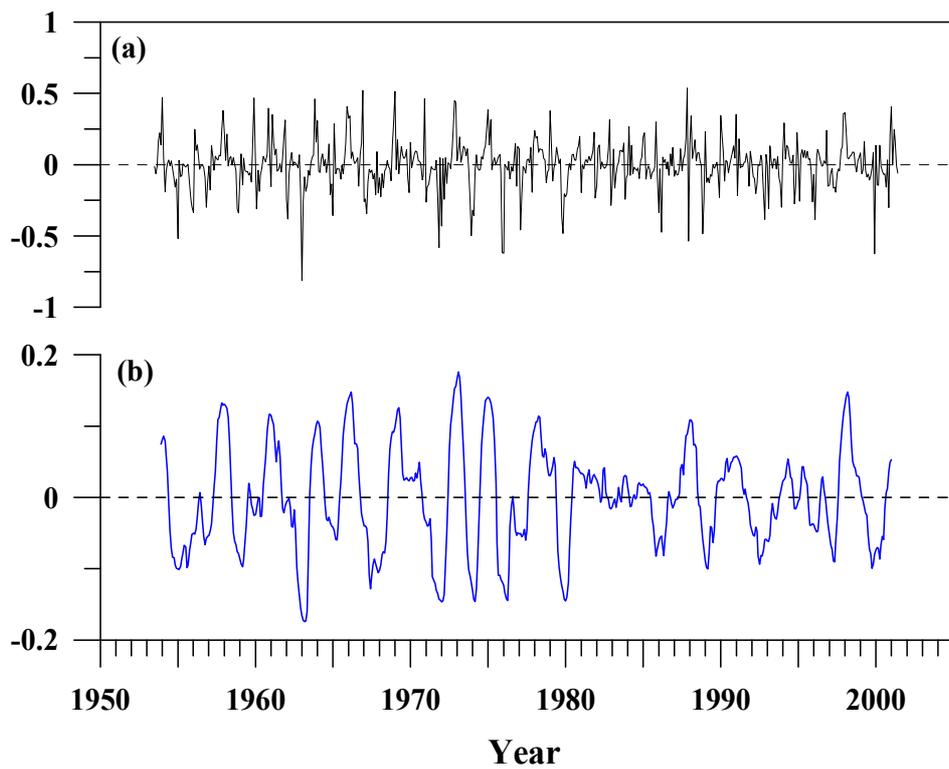
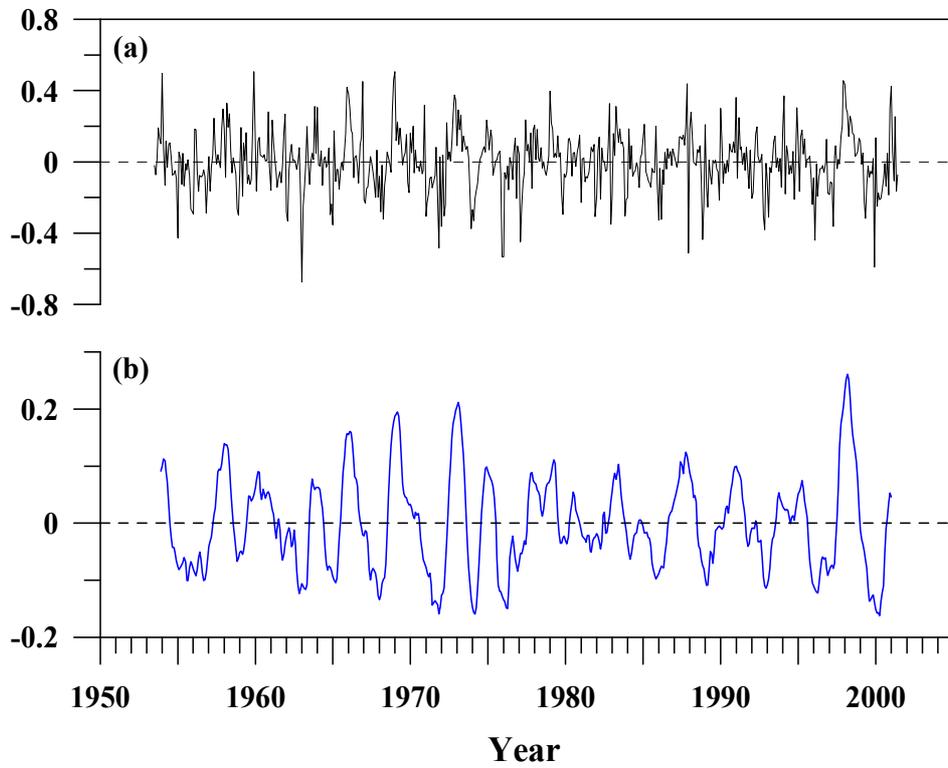


Fig. 25. The EOF1 coefficient series of T_{dew} residuals (original series minus 60-term



smoothed series) (a) and 10-term smoothed T_{dew} residuals (b).

Fig. 26. The EOF1 coefficient series of T_{amean} residuals (original series minus 60-term smoothed series) (a) and 10-term smoothed T_{amean} residuals (b).

