

계절내 예측자료를 이용한 홍수위험도 평가기술 개발

Development of Flood Risk Analysis Technique Using Seasonal to
Sub-Seasonal Data

이승수 예측기술팀

발간사

2주에서 2개월까지의 시간 규모를 가지는 계절내-계절(Subseasonal-to-Seasonal, S2S) 예측은 대기의 초기조건에 영향을 받기에는 시간 규모가 길고, 해양 경계조건에 영향을 받기에는 상대적으로 짧은 시간 규모이므로 수치모델을 이용해 정확도 높은 예보를 수행하기에는 기술적인 어려움이 존재하였습니다. 그러나 날씨예보와 기후예측을 이어주는 이음새 없는 예보에 대한 높은 관심과 요구에 힘입어 세계기상기구(World Meteorological Organization, WMO)의 세계기상연구프로그램(World Weather Research Programme, WWRP)과 세계기후연구프로그램(World Climate Research Program, WCRP)이 공동으로 추진하는 S2S 프로젝트가 2013년부터 시작되었으며, 현재 국제적으로 11개 기관에서 S2S 예측결과를 생산하고 있습니다.

S2S 프로젝트는 고영향(High-impact) 기상 이벤트를 특별히 강조하고 계절내에서 계절 규모의 시간 규모에 대한 이해를 바탕으로 모델의 예측력을 향상시키고자 하였습니다. 또한, 응용(적용)분야에서의 활용성 증진 및 운영 센터에 의한 이니셔티브 도입을 독려함과 동시에, 기상 및 기후 연구 커뮤니티의 전문성을 활용하여 기후 서비스를 위한 글로벌 프레임 체계의 중요성을 제기하기 위해 수립되었습니다.

S2S 프로젝트는 예측 성능을 증가시키기 위한 기회의 창을 정의하는 것을 포함하여 계절내 이벤트의 잠재적 예측성을 평가하고, 계절내에서 계절 예측 범위의 시스템적 에러와 편향(bias)에 대한 이해, 다중 모델 결합을 통한 계절내 예측 자료의 비교, 검증, 테스트와 불확실성의 정량화, 특정한 극한 이벤트의 연구를 최우선으로 하여 수행되고 있습니다. 현재 전 세계적으로 11개 현업기관이 참여하고 있

는 S2S 프로젝트의 예측자료는 유럽중기기상예보센터(European Centre for Medium-Range Weather Forecasts, ECMWF)와 중국기상청 (China Meteorological Administration, CMA) 데이터 포털을 통해 사용자에게 제공되고 있으나 일기예보나 중장기 예보대비 예측성이 낮은 것으로 인식되어 아직까지 활용성이 낮은 현실입니다.

이 연구에서는 S2S 자료의 활용성을 증진시키기 위한 노력의 일환으로 ECMWF에서 생산된 계절내 예측자료의 강수 정확도를 지점 관측자료와 비교하여 평가하고 최근 다양한 분야에서 활용성이 증대되고 있는 딥러닝 기법을 이용하여 하천에서의 홍수예측 분야의 적용성을 검토하는 연구를 수행하였습니다. 이 연구의 결과는 S2S 자료를 활용한 하천홍수 위험도 예측에 활용될 수 있을 것으로 기대합니다.

마지막으로 연구결과가 나오기까지 이 연구를 수행한 이승수 박사와 조원일 연구원의 노고에 감사드립니다.

2019년 3월
APEC 기후센터
원장 권 원 태

ABSTRACT

Over the last few decades, meteorological and climatological predictions using weather and climate models have been improving steadily. In contrast, sub-seasonal forecasts, which are between weather and climate models, have revealed a gap in the construction of seamless numerical forecasting systems. Climate data produced mainly by the APEC Climate Center (APCC) is seasonally forecasted monthly data with a lead-time of one to six months. It cannot be used directly in hydrological or other application fields because of its low spatial and temporal resolution. In the meteorological / climatic field, efforts are being made to increase the predictability of the weather and the availability climate data by extending seasonal forecast data to the sub-seasonal time scale, from two weeks to two months. As the result, the Subseasonal-to-Seasonal (S2S) project conducted jointly by the World Weather Research Program and the World Climate Research Program of the World Meteorological Organization was begun in 2013.

In this study, we evaluated the accuracy of S2S forecast data, which has increased in importance recently given the interest in seamless weather and climate forecast data, and evaluated its applicability to disaster areas, especially in river flood risk assessment. To evaluate the accuracy of the S2S forecast data, the Namgang dam basin was selected as the study area and the grid rainfall data corresponding to the eight rainfall stations in the area were extracted in 40 and 7 day intervals. The prediction accuracy of the S2S forecast data was evaluated by direct comparison with the rainfall data observed at the eight stations. Analysis using the RMSE and the coefficient of determination (R^2) were performed to evaluate the prediction

accuracy of the S2S rainfall forecast data. To test the possibility of improving accuracy of this data, a study was conducted using the S2S rainfall forecast data for the Korean peninsula to predict the precipitation at Namgang Dam Rainfall Observation Station using the machine learning technique known as multilayer perceptron.

In addition, time series data for fluctuations in river water elevation in the Nam River dam were predicted using the Long Short-Term model (LSTM) technique, which is effective for applying machine learning to time series data, to evaluate the river flood risk using S2S prediction data. To evaluate the feasibility of estimating fluctuations in river water elevation using S2S prediction data, three variables were estimated using the LSTM method: 1) the river water elevation using only water elevation; 2) river water elevation using only daily precipitation data; and 3) changes in river level using daily composite (river water and precipitation) data.

The result of the study shows that if the LSTM model is constructed using the S2S prediction data and river water elevation, the risk of flooding can be understood in terms of disaster preparedness. However, the R2 value was very low from the 2nd day due to limitations in the predictability of rainfall within the S2S forecast data itself. Therefore, it is necessary to develop methods to improve the accuracy of the S2S forecast data for extension to areas such as agriculture, water resources, and energy.

목 차

1. 서론	1
2. 연구자료 및 방법	5
2.1 계절내 예측자료	5
2.2 남강댐 유역 수문자료	6
2.3 인공신경망	9
2.3.1 다층 퍼셉트론	10
2.3.2 활성화 함수	11
2.3.3 손실 함수	13
2.3.4 오차역전파 알고리즘	13
2.3.5 LSTM	14
2.3.6 Keras	15
2.3.7 학습모델 구축	15
2.4 계절내 예측자료의 정확도 평가 방법	16
3. 연구내용	17
3.1 계절내 예측자료의 강우 예측능력 평가	17

3.2 다층 퍼셉트론을 이용한 계절내 예측정보의 예측정확도 항상 평가-----	18
3.3 홍수위험도 예측 활용성 평가-----	20
3.3.1 시간 단위 하천수위를 이용한 하천수위 예측 -----	20
3.3.2 일 단위 하천수위를 이용한 하천수위 예측 -----	22
3.3.3 일 단위 관측강수를 이용한 하천수위 예측 -----	24
3.3.4 일 단위 계절내 예측자료를 이용한 하천수위 예측 ---	27
3.3.5 일 단위 복합자료를 이용한 하천수위 예측 -----	29
 4. 결론-----	 35
 I REFERENCES-----	 38
 I Appendix A-----	 39
 I Appendix B-----	 61
 I Appendix C-----	 75
 I Appendix D-----	 131

그림 목차

Figure 1. Forecast skill among weather, sub-seasonal and seasonal forecasts (source: https://iri.columbia.edu/news/qa-subseasonal-prediction-project/) -----	2
Figure 2. Basin map of Namgang Dam -----	7
Figure 3. Simple Neural Network vs. Deep Neural Network -----	9
Figure 4. Sigmoid function -----	12
Figure 5. ReLU function -----	12
Figure 6. Long Short-Term Memory, LSTM -----	14
Figure 7. Variation of coefficient of determination (hourly water elevation case) -----	22
Figure 8. Variation of coefficient of determination (daily water elevation case) -	24
Figure 9. Variation of coefficient of determination (observed rainfall case) -----	26
Figure 10. Variation of coefficient of determination (S2S(40 day interval case)) ---	28
Figure 11. Variation of coefficient of determination (S2S(7 day interval case)) -	29
Figure 12. Variation of coefficient of determination (observed rainfall and water elevation data) -----	31
Figure 13. Variation of coefficient of determination (S2S(40day interval) and water elevation data) -----	33
Figure 14. Variation of coefficient of determination (S2S(7day interval) and water elevation data) -----	34

표 목차

Table 1. Characteristic of GPC data for sub-seasonal forecast	4
Table 2. Introduction of ECMWF S2S data	6
Table 3. Initialization date of hindcast for 2017 forecasting	6
Table 4. Attribute of water elevation observation in Nagang Dam basin	8
Table 5. Attribute of rainfall observation in Nagang Dam basin	8
Table 6. Type of machine learning	10
Table 7. Model summary	16
Table 8. Predictability comparison of observation vs. S2S (cont.)	17
Table 9. Predictability comparison of observation vs. machine learning result of S2S (cont.)	19
Table 10. Predictability of predicted water elevation using hourly water elevation data	21
Table 11. Predictability of predicted water elevation using daily water elevation data	23
Table 12. Predictability of predicted water elevation using daily observed rainfall data	25
Table 13. Predictability of predicted water elevation using S2S data (40day interval)	27
Table 14. Predictability of predicted water elevation using S2S data (7day interval)	29

Table 15. Predictability of predicted water elevation using observed rainfall and water elevation data -----	30
Table 16. Predictability of predicted water elevation using S2S(40day interval) and water elevation data -----	32
Table 17. Predictability of predicted water elevation using S2S(7day interval) and water elevation data -----	34

1. 서론

지난 수십 년간 기상 및 기후 모델을 활용한 기상·기후 예측성은 지속적으로 향상 되어 왔으나 기상 모델과 기후 모델 사이의 계절내(Sub-seasonal) 시간 규모의 예측은 초단기부터 계절·기후예측까지 이음새 없는(seamless) 수치예보 체계 구축에 있어 빈 공간을 차지하고 있었다. 이러한 문제점을 해결하기 위하여 세계 기상기구(World Meteorological Organization, WMO) 대기 과학위원회(Commission for Atmospheric Sciences, CAS)는 15차 회의(2009년 11월)에서 세계 기후연구 프로그램(World Climate Research Programme, WCRP), 세계 기상연구 프로그램(World Weather Research Programme, WWRP) 및 관측시스템 연구 및 예측가능성 실험(Observing System Research and Predictability Experiment, THORPEX)이 계절내 예측을 위한 적절한 협업 구조를 수립 할 것을 요청하였다. 이에 따라 2010년 12월 Exeter에서 WCRP / WWRP / THORPEX 워크샵이 개최되어 WCRP-WWRP-THORPEX 후원 하에 Sub-seasonal to Seasonal(S2S) 프로젝트의 기획 그룹이 구성되고, 2012년에 이행계획이 작성된 이후 2013년부터 5년 계획으로 계절내 예측 프로젝트(Sub-seasonal to Seasonal Project)가 진행되고 있다.

S2S 프로젝트는 고영향(High-impact) 기상 이벤트를 특별히 강조하고 계절내에서 계절 규모의 타임스케일에 대한 이해를 바탕으로 예측력을 향상시키고, 응용(적용)분야에 의한 활용성 증진 및 운영 센터에 의한 이니셔티브 도입을 독려함과 동시에, 기상 및 기후 연구 커뮤니티의 전문성을 활용하여 기후 서비스를 위한 글로벌 프레임 체계의 중요성을 제기하기 위한 목적으로 수립되었다. 이와 관련된 S2S 프로젝트의 연구 우선순위는 1) 예측 스킬을 증가시키기 위한 기회의 창을 정의하는 것을 포함하여 계절내 이벤트의 잠재적 예측성을 평가하고, 2) 계절내에서 계절 예측 범위의 시스템적 에러와 편향(bias)에 대한 이해, 3) 다중 모델 결합을 통한 계절내 예측 자료의 비교, 검증, 테스트와 불확실성의 정량화, 4) 특정한 극한 이벤트 케이스 연구 등이다(출처: <http://s2sprediction.net/>).

현재 계절내 예측을 정보를 생산하고 있는 기관은 China Meteorological Administration(CMA), European Centre for Medium-Range Weather Forecasts(ECMWF), United Kingdom Met Office(UKMO), Bureau of Meteorology(BoM), Environment

and Climate Change Canada(ECCC), Korea Meteorological Administration(KMA), Japan Meteorological Administration(JMA), National Centers for Environmental Prediction(NCEP) 등 총 8개 기관이 참여하고 있다. 각 기관별 예측 모델의 앙상블 개수는 4~50개의 분포를 가지며, 예측 주기는 매일에서 주 2회 등으로 다양하다. 또한 모형 결과의 기후적 경향을 파악하기 위한 hindcast 생산의 경우 고정된 hindcast를 사용하는 경우와 예측시마다 새로운 hindcast를 생산하는 경우도 있다. 이와 관련한 보다 자세한 사항은 Table 1에서 확인할 수 있다.

Figure 1에서는 기상예측(Weather forecast)과 계절예측(Seasonal forecast) 그리고 계절내 예측(Sub-seasonal forecast)의 예측 선행시간에 따른 예측스킬의 변화를 보여주고 있다. 그림에서 볼 수 있듯이 현재 계절내 예측 정보의 예측 스킬은 기상 모델과 계절예측에 비하여 상당히 낮은 수준으로 평가 받고 있으나 많은 기상·기후 연구자들에 의해 그 예측력을 높이기 위한 다양한 연구가 수행되고 있다(Brunet et al., 2010, Vitart et al., 2012, Vitart et al., 2017).




Figure 1. Forecast skill among weather, sub-seasonal and seasonal forecasts (source: <https://iri.columbia.edu/news/qa-subseasonal-prediction-project/>)

이러한 이음새 없는 기상·기후 예측정보는 다양한 분야에 활용되어 사회·경제적 부가 가치를 높일 수 있으며, 특히 재난관리 분야에 활용되어 인명과 재산상의 피해를 줄일 수 있을 것으로 기대되고 있다(Vitart et al., 2017). 그러나 Figure 1에서 살펴본 바와 같이 현재 계절내 예측자료의 정확도는 여타 기상·기후 예측자료에 비해 그 정확도가 매우 낮은 수준으로 인식되고 있으며 현재까지 명확히 계절내 예측자료의 정확도를 평가할 수 있는 기법이 개발되지 않은 실정이다. 따라서 본 연구에서는 국내 남강댐 유역을 연구 대상으로 하여 남강댐 유역 강우관측소에서 관측된 강수량자료와 계절내 예측자료의 비교를 통해 계절내 예측자료의 정확도를 평가한다. 또한 인공지능 기계학습 기법 중 하나인 다층 퍼셉트론 기법을 이용하여 계절내 예측자료의 정확도 향상 가능성에 대해 알아보고 홍수 위험도를 사전에 파악할 수 있도록 Long short-term Memory(LSTM) 기법을 활용하여 하천수위 예측의 활용성을 평가한 후 계절내 예측자료를 이용하여 홍수위험도 평가에 적용 가능한지를 알아본다.

Table 1. Characteristic of GPC data for sub-seasonal forecast

GPC name	Center	Time Range	Resolution	Forecast Ens. Size	Forecast Frequency	Hindcast	Hindcast Length	Hindcast Frequency	Hindcast Ens. Size
Beijing	CMA	d 0-60	T106L40	4	daily	fix	1994-2014	daily	4
ECMWF	ECMWF	d 0-46	T00639/319 L91	51	2/week (Sun, Thu)	on the fly	past 20 years	2/week (Mon, Thu)	11
Exeter	UKMO	d 0-60	N216L85	4	daily	on the fly	1993-2015	4/month (1, 9, 17, 25)	7
Melbourne	BoM	d 0-62	T47L17	33	2/week (Sun, Thu)	fix	1981-2013	6/month (1, 6, 11, 16, 21, 26)	33
Montreal	ECCC	d 0-32	0.45x0.45 L40	21	weekly (Thu)	on the fly	1995-2014	Weekly (Thu)	4
Seoul	KMA	d 0-60	N216L85	4	Daily	on the fly	1991-2010	4/month (1, 9, 17, 25)	3
Tokyo	JMA	d 0-33	T1479/319 L100	50	weekly (Wed)	fix	1981-2012	3/month (10, 20, last day)	5
Washington	NCEP /CPC	d 0-44	T126L64	16	daily	fix	1999-2010	Daily	4

2. 연구자료 및 방법

2.1 계절내 예측자료

현재 APEC기후센터(APEC Climate Center, 이하 APCC)에서 주로 생산되는 기후자료는 계절예측 자료로서 향후 1개월에서 6개월까지의 월별 자료로, 시·공간 해상도가 크기 때문에 수문 또는 수리 분야에서 바로 사용하기에는 한계가 있다. 기상/기후 분야에서 이러한 문제를 인지하여 계절 예측 정보를 2주~2개월의 계절내 시간 규모로 확장하여 위험 기상·기후 자료의 예측성 및 활용성을 향상시키려는 노력이 이루어지고 있다. 대표적으로 세계기상기구(World Meteorological Organization, WMO)의 세계기상연구프로그램(World Weather Research Programme, WWRP)과 세계기후연구프로그램(World Climate Research Program, WCRP)이 공동으로 추진하는 Subseasonal-to-Seasonal 프로젝트(이하 S2S 프로젝트)가 2013년부터 시작되었다(Vitart et al., 2017).

S2S 프로젝트의 일환으로 세계 여러 나라에서 고유 모델로 생산되어 유럽중기기상예보센터(European Centre for Medium-Range Weather Forecasts, ECMWF)와 중국기상청(China Meteorological Administration, CMA) 데이터 포털에서 제공되는 S2S 예측자료 중, 본 연구에서는 강수자료의 예측정확성과 활용도를 평가하기 위하여 ECMWF에서 생산된 자료를 수평해상도 $0.25^{\circ} \times 0.25^{\circ}$ 로 내삽하여 사용하였다. Table 2에서 볼 수 있듯이 ECMWF에서는 일주일에 두 번씩(월요일과 목요일) 향후 46일간의 S2S 예측자료를 매년 생산한다. 본 연구에서는 2017년 예측을 위해 생성된 1997-2016년 기간 동안의 hindcast 자료 중 매 주 월요일에 초기화 된 자료를 앙상블 평균하여 사용하였고, 자료의 초기장 날짜는 2017년의 월요일에 해당하는 날짜로 Table 3에 자세하게 기술하였다. 자료의 연속성과 활용성을 높이기 위해 예측자료를 두 가지로 구성하였다. 첫 번째는 매 주 생산된 향후 7일간의 자료를 연속하여 사용하였고, 윤년(2000, 2004, 2008, 2012, 2016년)의 경우에는 연속성을 위해 2월 27일 초기화 자료에 한해 8일간의 예측자료를 사용하였고 이를 7일 간격 자료로 명명하였다. 다른 하나는 하나의 초기장에서 생산된 자료를 최대한 이용하기 위해 6주(42일) 간격의 자료를 연속하여 사용했고, 이를 42일 간격 자료로 명명하였다.

Table 2. Introduction of ECMWF S2S data

Center	Forecast Frequency	Forecast Time range	Forecast Ens. Size	Hindcast Frequency	Hindcast Ens. Size	Hindcast length
ECMWF	2/week (Mon,Thu)	0-46 days	51	2/week (Mon, Thu)	11	past 20 years

Table 3. Initialization date of hindcast for 2017 forecasting

Month	Date
01	02, 09, 16, 23, 30
02	06, 13, 20, 27
03	06, 13, 20, 27
04	03, 10, 17, 24
05	01, 08, 15, 22, 29
06	05, 12, 19, 26
07	03, 10, 17, 24, 31
08	07, 14, 21, 28
09	04, 11, 18, 25
10	02, 09, 16, 23, 30
11	06, 13, 20, 27
12	04, 11, 18, 25

2.2 남강댐 유역 수문자료

남강은 낙동강의 제1지류로서 동경 127°29'~ 128°28', 북위 35°00'~35°46' 사이의 낙동강 남서쪽에 위치하고 있으며, 서쪽으로는 백두대간의 지리산 자락(소백산맥)이 섬진강 유역과 경계를 이루고 있다. 남서쪽으로는 섬진강 하류 중권역, 북쪽으로는 황강 유역과 남쪽으로는 남남정맥을 분수령으로 하여 낙동강 남해 대권역과 경계를 이루고 있다. 남강유역면적은 3,467.52km², 유로연장은 189.83km, 유역 평균폭은 18.27km, 형상계수는 0.10이며, 유역형상은 하천형태학적으로 수지상 형태로 유수가 하천에 일시에 집중되는 일은 없으나 홍수위가 오래 지속되는 경우가 발생하며, 유역의 평균고도는 EL. 319.96m 이고, 평균경사는 31.86%이다. 유역을 구성하고 있는 행정구역은 경상남도 함안군, 함양군, 산청군, 진주시, 합천군, 의령군, 하동군, 사천시, 고성군 및 전라남도 구례군, 전라북도 남원시 등 3도 3시 8군으로 이루어져 있다.

국가하천 구간인 남강에 직접 유입되거나 분기되는 하천현황을 살펴보면, 낙동강 제1지류인 남강의 국가하천 구간은 145.4km이며, 남강의 제1지류인 함안천과 덕천강의 국가하천 구간은 각각 9.32km, 2.90km이다. 또한 남강의 제1지류인 함양위천의 지방1급하천 구간은 9.60km이며, 지방2급하천은 의령천, 석교천, 반성천, 영천강, 나불천, 양천, 안봉천, 금서천 등 총 66개소에 총연장 492.60km로 구성되어 있으며, 남강댐 유역도는 Figure 2와 같다.

남강댐 유역에는 한국수자원공사에서 운영하고 있는 9개의 하천 수위 관측소와 2개의 댐 저수지 수위 관측소 그리고 20개의 강우관측소가 있으며 그 재원은 Table 4와 Table 5와 같다. 남강댐 유역에 위치하고 있는 수위관측소와 강우관측소에서 계측된 수문자료는 한국수자원공사의 협조를 받아 2013년 2월 5일 01시 부터 2018년 8월 27일 24시까지 시 단위 자료를 활용하였다. 또한 일 단위 자료는 시 단위 자료를 24시간 단위로 합산한 후 평균값을 이용하였다.

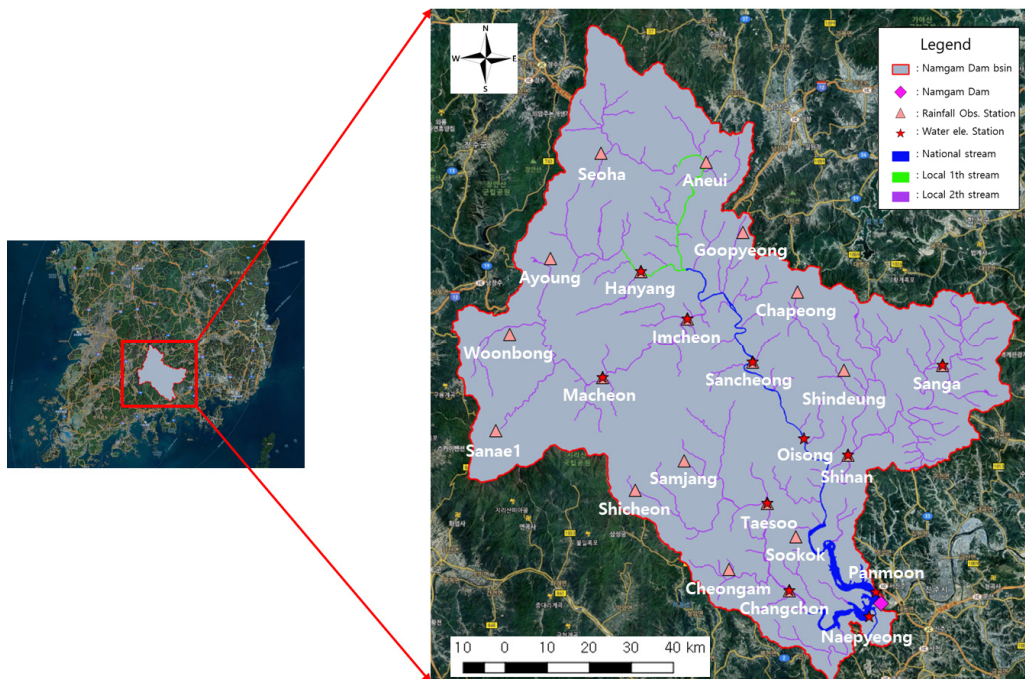


Figure 2. Basin map of Namgang Dam

Table 4. Attribute of water elevation observation in Nagang Dam basin

Station Name	Latitude	Longitude	Classification
Hamyang	35-30-49	127-43-53	Local 1th stream
Macheon	35-24-07	127-40-58	Local 2th stream
Imcheon	35-27-52	127-47-28	Local 2th stream
Sancheong	35-25-05	127-53-28	National stream
Oisong	35-20-15	127-56-24	National stream
Samga	35-24-50	128-07-03	Local 2th stream
Shinan	35-19-12	127-59-45	Local 2th stream
Changchon	35-10-43	127-55-13	Local 2th stream

Table 5. Attribute of rainfall observation in Nagang Dam basin

Station Name	Latitude	Longitude	Classification
Aneui	34-37-40	127-48-56	Local 1th stream
Ayoung	35-31-40	127-36-57	Local 1th stream
Chahwang	35-29-30	127-55-56	Local 1th stream
Changcheon	35-10-43	127-55-13	Local 1th stream
Cheongam	35-12-04	127-50-37	Local 1th stream
Goopyeong	35-33-16	127-51-44	Local 1th stream
Hamyang	35-30-49	127-43-53	Local 1th stream
Imcheon	35-27-52	127-47-28	Local 1th stream
Macheon	35-24-07	127-40-58	Local 1th stream
Samga	35-24-50	128-07-03	Local 1th stream
Samjang	35-18-53	127-47-11	Local 1th stream
Sanae1	35-20-49	127-32-46	Local 1th stream
Sancheong	35-25-05	127-53-28	National stream
Seoha	35-38-15	127-40-53	Local 1th stream
Shicheon	35-17-03	127-43-26	Local 1th stream
Shinan	35-19-12	127-59-45	Local 1th stream
Shindeung	35-24-32	127-59-28	Local 1th stream
Sookok	35-14-08	127-55-42	Local 1th stream
Taesoo	35-16-12	127-53-34	Local 1th stream
Woonbong	35-26-53	127-33-49	Local 1th stream

2.3 인공신경망

기계학습 또는 인공신경망은 기계에게 인간 뇌의 뉴런구조를 수학적으로 모델화한 정보처리 시스템으로 다층의 뉴런과 각 뉴런을 연결하는 가중치로 구성되어 있다 (Regueiro, 2006). 딥러닝은 Rosenblatt(1957)가 제안한 퍼셉트론(Perceptron) 이론에 기반하여 일반적인 기계학습 기법에 활용되는 학습층(Layer)을 깊게 한 기계학습 기법을 의미하며, 기계학습은 데이터 자체의 특징을 기반으로 학습하여 최적화하여 자가 발전을 하는 일련의 과정을 의미한다(Lee et al., 2016). 인공신경망은 기본적으로 입력층(Input layer)과 은닉층(Hidden layer) 그리고 출력층(Output layer)로 구성되어 있으며 각 층은 노드로 구성되어 있으며 모든 노드는 가중치와 편향으로 연결되어 있으며 학습을 시킨다는 의미는 각 노드간 연결되어 있는 가중치와 편향을 조절하여 원하는 값을 출력할 수 있도록 하는 것을 의미한다. Figure 3에서는 기본적인 인공신경망과 딥러닝의 차이점을 보여준다. 단순 신경망은 은닉층 노드의 개수와 상관없이 은닉층이 한 개 인 것을 의미하며 딥러닝은 두 개 이상의 은닉층을 가지는 인공신경망을 의미한다.




Figure 3. Simple Neural Network vs. Deep Neural Network

기계학습은 학습 데이터를 획득 하는 방법에 따라 지도학습(supervised Learning, SL), 반지도학습(Semi-Supervised Learning, SSL) 그리고 강화학습(Reinforcement Learning, RL)으로 구분될 수 있다. 지도 학습은 입력값과 출력값을 동시에 학습데이터로 주어 입력값이 출력값에 최대한 가깝게 학습되도록 하는 알고리즘이며, 반지도학습은 입력데이터만을 가지고 입력데이터 자체의 의미를 분석하는 알고리즘으로써 최초 지도학습과 동일하게 학습을 진행하다 출력값이 부족한 경우 입력값에 상응하는 가상의 출력값으로 보충하여 학습데이터를 구성하고 이를 학습하는 알고리즘이다. 강화학습은 입력데이터의 특징에 따라서 학습 방식을 결정한다. 각 학습 단계마다 학습을 평가하고 이에 따른 보상이 주어지며 보상이 극대화 되는 방향으로 학습이 진행된다. 지도학습 알고리즘의 예로는 인공신경망(Neural Network), Support Vector Machine(SVM), 커널 머신, Decision Tree, Naive Bayes, K-nn, Bayesian network, K-NN 등이 있으며, 반지도 학습 알고리즘에는 K-means, 계층적 군집화, SOM 등이 있으며, 강화학습에는 Q-Learning 등이 대표적이다. 기계학습을 적용하여 문제를 해결하는 경우 해결해야 하는 문제의 특징에 따라 적용되는 학습 알고리즘의 종류가 결정되며 그 종류는 Table 6과 같다.

Table 6. Type of machine learning

Type	Technique	
SL	<ul style="list-style-type: none"> • Perceptron • Classification • Diagnosis 	<ul style="list-style-type: none"> • Regression • Forecasting
UL	<ul style="list-style-type: none"> • Self Organizing Map(SOM) • Grouping • Density estimation 	<ul style="list-style-type: none"> • Dimension reduction • Feature extraction • K-means
SSL	<ul style="list-style-type: none"> • Classification • Regression 	<ul style="list-style-type: none"> • Forecasting
RL	<ul style="list-style-type: none"> • Trial&error • Reward function 	<ul style="list-style-type: none"> • Dynamic programming

2.3.1 다층 퍼셉트론

인공신경망 모형에는 여러 가지 구조가 있는데 그 중 퍼셉트론은 입력층, 출력층, 가중

치, 편향으로 구성되어 있다. 퍼셉트론의 특징은 은닉층의 활성화 함수가 -1에서 1사이의 값(ReLU 함수의 경우는 0에서 1사이)을 반환하기 때문에 비선형적 함수식을 표현하기 위해서는 입력 데이터를 정규화 해 줄 필요가 있다. 표준화된 입력 변수는 가중치를 곱하고 편향을 더한 후 활성화 함수로 보내지며 대표적인 활성화 함수는 계단함수(Hard limiter), 시그모이드(Sigmoid) 함수, ReLU 함수 등이 있다. 활성화 함수를 통과한 값은 그 다음 은닉층으로 보내지며 다시 가중치를 곱하고 편향을 더한 후 다시 활성화 함수를 통과 한 후 출력층으로 보내지게 된다. 이후 출력된 값과 대상값의 차이를 최소화 할 수 있는 방향으로 학습이 반복되며 이러한 과정을 오차역전파 알고리즘이라 한다.

2.3.2 활성화 함수

활성화 함수는 입력 신호의 총합을 출력 신호로 변화하는 함수로써 입력신호의 총합이 활성화를 일으킬지 말지를 결정한다. 대표적인 활성화 함수의 종류로는 Sigmoid 함수, ReLU함수, Softmax 함수 등이 있다.

2.3.2.1 Sigmoid 함수

Sigmoid 함수는 식 (1)를 통해 얻을 수 있다.

$$h(x) = \frac{1}{1 + \exp(-x)} \quad (1)$$

여기서, x 는 노드로부터 전달받은 값을 의미하며 Figure 4에서는 Sigmoid 함수의 형태를 나타내고 있다. Sigmoid함수는 노드로부터 입력값(x)을 전달받아 0과 1사이의 값을 출력하여 다음 층으로 전달하는 역할을 수행한다.




Figure 4. Sigmoid function

2.3.2.2 ReLU 함수

ReLU함수는 최근 인공지능망 학습에서 가장 많이 쓰이는 활성화 함수로써 매우 Figure 5와 같이 단순한 형태를 띠고 있지만 양 극단값이 포함되지 않으며 계산이 효율적이라는 장점을 가지고 있으며 수렴속도 또한 sigmoid 함수에 비해 빠른 것으로 알려져 있다. 그러나 중심값이 0이 아니며 입력값이 0보다 작은 경우 항상 0을 출력하여 학습이 되지 않는다는 단점을 가지고 있으며 다음 식 (2)를 통해 구할 수 있다.

$$f(x) = \max(0, x) \quad (2)$$




Figure 5. ReLU function

2.3.3 손실 함수

손실함수는 기계학습에서 최적 매개변수 탐색에 이용되는 지표로 사용된다. 손실 함수는 임의의 함수를 사용하는 경우도 있지만 일반적으로 평균제곱 오차(Mean Squared Error, MSE)와 교차 엔트로피 오차(Cross Entropy Error, CEE)를 사용하며 그 식은 각각 다음과 같다.

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (3)$$

$$CEE = -\frac{1}{N} \sum_n \sum_k t_{nk} \log y_{nk} \quad (4)$$

여기서 N 은 데이터의 총 개수, Y_i 는 실측값, \hat{Y}_i 는 실측값의 평균, n 은 t_{nk} 는 정답 레이블 중 n 번째 데이터의 k 번째 값, y_{nk} 는 신경망의 출력이다.

손실함수의 목적은 정확도 높은 매개변수를 찾는 것에 있다. 기계학습 과정에서 정확도 높은 매개변수를 찾는 방법으로 정확도 대신 손실함수를 이용하는 이유는 정확도를 매개변수 갱신의 지표로 사용하는 경우 매개변수의 미분값이 대부분의 경우 0이 되어 학습이 제대로 이루어지지 않는 문제를 해결하기 위함이다.

2.3.4 오차역전파 알고리즘

Rosenblatt(1957)에 의해 제안된 퍼셉트론은 기계학습 이론의 기초를 이루었으나 당시 연구되었던 신경망은 층을 깊게 하여도 복잡한 논리회로 연산이 힘들다는 단점으로 인하여 관련 연구의 침체기를 겪었으나 Rumelhart et al.(1986)에 의해 개발된 오차역전파(Back Propagation)알고리즘에 의해 관련 연구가 활성화 되었다. 오차역전파법은 출력값을 역으로 전파하여 오차의 경사를 줄여가는 기법으로써 입력값을 출력값으로 학습시키는 경우 미분을 활용하는 경우보다 계산시간을 획기적으로 줄일 수 있다는 장점을 가지고 있다.

2.3.5 LSTM

Deep-Learning(이하 딥러닝)은 기계학습의 하나로써 가려진 층(Hidden layer)을 깊게 만들어 입력값의 가중치를 조절하는 가려진 층의 가중치를 조절하여 원하는 값을 출력하는 기법을 의미한다. 따라서 범용적 의미에서는 딥러닝 보다는 인공신경망(Artificial Neural Network가, ANN)이라 칭하는 것이 더 적절하다. 인공신경망의 한 종류인 Recurrent Neural Network(이하 RNN)은 시계열 데이터처리에 특화된 알고리즘으로 알려져 있으며, 입력데이터와 전 단계에서 출력된 데이터를 동시에 이용하여 학습이 가능하다. 그러나 시계열적 특성을 나타내는 자료의 관계가 먼 경우 예측성이 나빠지는 경향을 보이며, Hochreiter and Schmidhuber(1997)는 이러한 RNN의 장기 의존성 문제를 해결하기 위해 LSTM 기법을 제안하였다. Figure 6에서는 LSTM 기법의 개념도를 보여주고 있다. LSTM은 여러 개의 게이트(gate)가 붙어있는 셀(cell)로 구성되며, 게이트는 셀 상태의 보호 및 제어를 위한 망각, 입력, 출력의 세 종류로 구분된다. LSTM은 각 셀간 정보를 유지시켜 주는 기능이 추가되어 주기성을 나타내는 자료구조의 간격이 넓어도 그 주기성을 잃지 않도록 해주어 일반적인 RNN의 고질적인 가중치 소실(vanishing gradient) 문제를 방지할 수 있어 시계열 자료 예측에 유리한 것으로 알려져 있다(Tran and Song, 2017).




Figure 6. Long Short-Term Memory, LSTM

2.3.6 Keras

Keras는 구글 엔지니어인 François Chollet가 개발한 딥러닝 라이브러리로서 파이썬으로 구현된 쉽고 간결한 딥러닝 라이브러리를 제공한다. 따라서 딥러닝 비전문가라 할지라도 각 분야에서 상대적으로 쉽게 딥러닝 모델을 구축하여 활용할 수 있도록 직관적인 API를 제공한다. 또한 Keras 내부에는 TensorFlow와 Theano, CNTK 등의 딥러닝 전용 엔진이 구동되어 다양한 모델을 구축하고 실무적 활용이 가능하다. 이와 관련한 Keras는 아래 4가지의 주요 특성을 가진다.

- 1) 모듈화(Modularity)
- 2) 최소주의(Minimalism)
- 3) 쉬운 확장성
- 4) 파이썬 기반

Keras와 관련된 보다 자세한 사항은 <https://keras.io>에서 확인할 수 있다.

2.3.7 학습모델 구축

본 연구에서는 계절내 예측자료를 이용한 남강댐 유역 강우 관측값을 예측하는 다층 퍼셉트론 모델과 관측 수위, 관측강수, 계절내 예측자료 등을 이용하여 하천수위를 예측하는 LSTM 모형을 구축하여 계절내 예측자료의 정확도를 평가하고 기계학습 기반 계절내 예측자료의 정확도 향상 기법 그리고 하천 홍수 예측을 위한 계절내 예측자료의 활용성 평가에 관한 연구를 수행한다. 이에 따른 입력값과 예측값 그리고 기계학습 기법은 Table 7에 정리하였다.

Table 7. Model summary

Index	Prediction Target	Input data	Method
1	Observed rainfall	S2S	Multilayer Perceptron
2	Observed water elevation	Observed water elevation	LSTM
3		Observed rainfall	
4		S2S	
5		Observed water elevation & rainfall	
6		Observed water elevation & S2S	

2.4 계절내 예측자료의 정확도 평가 방법

본 연구에서는 계절내 예측자료의 수문분야 활용성을 평가하기 위하여 42일 예측정보와 7일 예측정보 두 가지를 이용하였다. 한반도 영역에 대해서 추출된 계절내 예측자료와 남강댐 유역에 위치하고 있는 20개 강우관측소의 관측데이터(2013년 2월 5일~2016년 12월 31일)가 겹치는 기간에 대해서 강우관측소가 포함된 계절내 예측자료의 해당 격자값과 강우관측소의 관측값을 직접 비교하여 분석하였다. 계절내 예측자료의 정확도를 평가하기 위하여 평균제곱근오차(Root Mean Square Error, RMSE)와 결정계수(R^2) 분석을 수행하였으며 그 식은 아래의 식 (3)과 (4)와 같다.

$$\text{평균제곱근 오차: } RMSE = \sqrt{\frac{\sum_{n=1}^N (\hat{y}_n - y_n)^2}{N}} \quad (5)$$

$$\text{결정계수: } R^2 = 1 - \frac{\sum_{n=1}^N (y_n - \hat{y}_n)^2}{\sum_{n=1}^N (\hat{y}_n - \bar{y}_n)^2} \quad (6)$$

여기서, N 은 데이터의 개수, \hat{y}_n 은 예측값, y_n 은 실측값, \bar{y}_n 은 실측값의 평균이다.

3. 연구내용

3.1 계절내 예측자료의 강우 예측능력 평가

계절내 예측자료의 예측정확도 분석은 42일 단위 예측정보와 7일 단위 예측정보 두 가지에 대해 강우 관측소를 포함하는 격자에 대해 강우값을 추출한 후 식 (3)과 식 (4)를 이용하여 RMSE와 결정계수 R^2 을 계산하여 수행되었다.

42일 단위 예측정보의 RMSE 분석결과 최소 11.02(안의 강우관측소)에서 최대 21.55(신천 강우관측소)로 나타났으며 R^2 값은 최소 -0.1041(안의 강우관측소)에서 최대 0.0403(창천 강우관측소) 수준으로 매우 낮은 수준의 예측정확도를 가지는 것으로 분석되었다. 7일 단위 계절내 예측정보의 RMSE는 최소 10.06(구평 강우관측소)에서 최대 20.29(시천 강우관측소)로 나타났으며 R^2 는 최소 0.053(안의 강우관측소)에서 최대 0.2417(서하 강우관측소)로 42일 단위 계절내 예측정보 보다는 우수한 결과를 보여주었으나 대체적으로 낮은 수준의 예측 재현성을 보여주는 것으로 분석되었다. 42일 주기 예측정보와 7일주기의 예측정보의 RMSE와 R^2 값은 Table 8에 나타내었으며 시계열 비교 자료는 Appendix A-1과 A-2에 표시하였다.

Table 8. Predictability comparison of observation vs. S2S (cont.)

Rainfall obs. station	40day interval		7day interval	
	RMSE	R^2	RMSE	R^2
Aneui	11.02	-0.104	10.21	0.0532
Ayoung	12.95	0.0137	11.66	0.1995
Chahwang	12.28	0.0232	11.11	0.1998
Changcheon	13.69	0.0403	12.50	0.1993
Cheongam	17.31	0.0379	15.98	0.1806
Goopyeong	11.32	0.0031	10.06	0.2122
Hamyang	11.43	0.0055	10.16	0.2149
Imcheon	12.50	0.0261	11.39	0.1906
Macheon	14.34	0.0313	13.22	0.1768
Samga	12.12	0.0119	10.84	0.2101
Samjang	20.30	0.0263	19.06	0.1414

Table 8. Predictability comparison of observation vs. S2S

Rainfall obs. station	40day interval		7day interval	
	RMSE	R ²	RMSE	R ²
Sanae1	15.95	0.0209	14.72	0.1659
Sancheong	15.11	0.0266	14.06	0.1575
Seoha	11.80	0.0139	10.35	0.2417
Shicheon	21.55	0.0189	20.29	0.1305
Shinan	12.90	0.0327	11.63	0.2129
Shindeung	12.83	0.0310	11.62	0.2043
Sookok	14.01	0.0377	12.75	0.2037
Taesoo	15.58	0.0318	14.29	0.1852
Woonbong	12.31	-0.0011	11.05	0.1930

3.2 다층 퍼셉트론을 이용한 계절내 예측정보의 예측정확도 향상 평가

본 연구에서는 Keras를 이용하여 다층 퍼셉트론을 구성하였다. 입력값으로는 계절내 예측자료 중 한반도 영역을 전부 포함하는 962개의 격자값을 이용하여 남강댐 유역 강우 관측소의 강수량을 학습하도록 하였다. 은닉층은 512개의 노드를 가지는 두 개의 층으로 구성하였으며 활성화 함수는 최근 가장 많이 사용되고 있는 ReLU 함수를, Loss 함수는 MSE를 사용하며 optimize는 adam을 이용하여 학습 모델을 구성하였다. 반복학습은 10회, 50회, 100회, 1,000회, 5,000회 그리고 10,000회로 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 본 연구에서 사용한 계절내 예측자료의 전체 기간이 상대적으로 짧은 것을 감안하여 2013년 2월 15일부터 2015년 12월 31일까지의 자료를 이용하여 95%는 학습에 이용하였으며 5%는 검증에 활용하였다. 또한 2016년 1월 1일부터 2016년 12월 31일 까지의 데이터에 대해서 학습된 모델의 성능을 위에서 언급한 RMSE와 R²값을 이용하여 평가하였다.

Table 9에는 42일 주기의 계절내 예측정보와 7일 주기의 계절내 예측정보를 입력자료로 활용하여 남강댐 유역 20개 강우관측소의 강우값을 예측한 결과에 대해 RMSE와 R² 값을 분석한 결과를 나타내고 있다. 먼저 RMSE 분석 결과를 살펴보면 42일 주기 계절내 예측정보를 활용한 지점 강우 예측의 경우 RMSE는 최대 20.20(삼장 강우관측소)에

서 최소 10.56(안의 강우관측소)의 분포를 나타내고 있으며 7일 주기 계절내 예측정보를 활용한 지점 강우 예측의 경우에는 RMSE가 최대 22.08(시천 강우관측소)에서 최소 10.24(구평 강우관측소)의 분포를 보여주고 있다. 이는 실제 기계학습을 시키지 않은 순수 예측정보의 범위를 크게 벗어나는 않는 값으로써 다층 퍼셉트론을 이용한 예측 결과가 실제 계절내 예측정보 값보다 RMSE 오차가 크지 않음을 의미하나 그 저감폭은 매우 저조한 것으로 나타났다.

결정계수 R^2 값을 살펴보면 42일 주기 계절내 예측 정보를 이용한 결과값은 최소 -0.1294(청암 강우관측소)에서 최대 0.0103(서하 강우관측소)의 분포를 보이며, 7일 주기 예측정보는 최소 -0.2260(시천 강우관측소)에서 최대 0.2377(삼가 강우관측소) 범위를 보여주는 것으로 분석되었다. 그러나 R^2 가 0보다 작은 음수를 내는 경우에는 편차의 제공보다 오차의 제공이 더 크다는 것을 의미 하므로 이는 계절내 예측정보의 값이 강우관측소의 평균 강수량 값 보다 더 낮은 재현성을 가지는 것을 의미한다. 즉, 기계학습을 활용한 예측정보가 해당기간의 평균값으로 예측한 것보다 정확도가 더 낮음을 의미한다. 따라서 다층 퍼셉트론 기법을 기반으로 계절내 예측 정보를 이용한 지점 강우의 예측력을 향상 시키는 것은 좋은 효과를 얻지 못하였다. 42일 주기 계절내 예측 결과와 관측값의 시계열 비교 그래프는 Appendix A-3에 7일 주기 계절내 예측 결과와 관측값의 시계열 비교 그래프는 Appendix A-4에 각각 추가하였다.

Table 9. Predictability comparison of observation vs. machine learning result of S2S (cont.)

Rainfall obs. station	40day interval		7day interval	
	RMSE	R^2	RMSE	R^2
Aneui	10.56	0.0063	11.62	-0.2034
Ayoung	12.62	-0.0236	11.44	0.1581
Chahwang	11.92	-0.0343	12.26	-0.0937
Changcheon	15.29	-0.0014	13.44	0.2270
Cheongam	19.73	-0.1294	16.68	0.1924
Goopyeong	11.38	-0.0364	10.24	0.1615
Hamyang	12.01	-0.0494	11.08	0.1071
Imcheon	12.13	-0.0299	11.36	0.0975
Macheon	15.74	-0.0580	14.07	0.1545

Table 9. Predictability comparison of observation vs. machine learning result of S2S

Rainfall obs. station	40day interval		7day interval	
	RMSE	R ²	RMSE	R ²
Samga	13.76	-0.0114	11.95	0.2377
Samjang	20.20	-0.0415	19.53	0.0352
Sanae1	15.25	-0.0646	15.09	-0.0382
Sancheong	14.28	-0.1148	14.29	-0.1162
Seoha	11.52	0.0103	10.87	0.1195
Shicheon	20.15	-0.0204	22.08	-0.2260
Shinan	14.51	-0.0411	12.53	0.2230
Shindeung	15.18	-0.0388	13.53	0.1743
Sookok	16.11	-0.0147	14.63	0.1630
Taesoo	17.99	-0.0569	15.65	0.1993
Woonbong	12.58	-0.0565	11.65	0.0958

3.3 홍수위험도 예측 활용성 평가

본 장에서는 하천 홍수위험도 평가를 위해 LSTM 기법을 활용하여 남강댐 유역 하천 수위 변동을 예측하고 정확도 분석을 통해 홍수위험도 예측 분야 적용성을 평가한다. 먼저 시계열 자료 예측에 대한 LSTM의 활용성을 평가하기 위하여 1) LSTM 기법을 활용하여 시간 단위 하천수위 자료만을 이용한 하천수위 변동 예측, 2) LSTM 기법 기반 일 단위 강수량(지점 관측자료, 계절내 예측자료)를 이용한 하천수위 변동 예측, 3) LSTM 기법 기반 일 단위 복합자료(관측 하천수위, 지점 강수량 자료, 계절내 예측자료)를 이용한 하천수위 변동 예측을 수행하여 계절내 예측자료의 홍수 위험도 예측에의 활용성에 대해 알아본다.

3.3.1 시간단위 하천수위를 이용한 하천수위 예측

LSTM을 이용한 하천수위 예측성능을 평가하기 위하여 남강댐 유역내에 위치하고 있는 8개 하천수위 지점(함양, 마천, 임천, 산청, 외송, 삼가, 신안 창촌)에 대해서 예측 선행 시간(lead-time), 1시간, 2시간, 3시간, 4시간, 5시간, 6시간, 12시간 별로 하천 수위 예측을 수행하였다.

Table 10. Predictability of predicted water elevation using hourly water elevation data

Water Gauge Station	R ²						
	1 hour	2 hour	3 hour	4 hour	5 hour	6 hour	12 hour
Hamyang	0.9860	0.9655	0.9434	0.9077	0.8715	0.8313	0.6950
Macheon	0.9901	0.9618	0.9295	0.8937	0.7917	0.8063	0.6258
Imcheon	0.9756	0.9339	0.8944	0.9498	0.7913	0.7747	0.5614
Sancheong	0.9823	0.9395	0.9129	0.8811	0.8245	0.7872	0.3735
Oisong	0.9762	0.9478	0.9093	0.8474	0.7807	0.8315	0.6472
Samga	0.9841	0.9656	0.9360	0.9061	0.8810	0.8495	0.6900
Shinan	0.9895	0.9726	0.9415	0.9171	0.8849	0.8170	0.6889
Changchon	0.9640	0.9686	0.9272	0.8962	0.8662	0.8213	0.6296

입력값으로는 개별 하천 수위 관측소의 시간 단위 수위 관측자료만을 이용하였으며 과거 12시간 동안 관측된 자료를 이용하여 선행 시간별 수위를 예측하도록 모델을 구성하고 학습하도록 하였다. 은닉층의 노드 개수는 최초 2개부터 2의 제곱수로 늘려 테스트를 수행하였으며 계산시간과 정확도(RMSE), 재현계수(R²)의 값을 고려하여 최종적으로 128개의 노드를 가지는 한 개의 층으로 구성하였으며 활성화 함수는 최근 가장 많이 사용되고 있는 ReLU 함수를 이용하였다. 반복학습은 50회에서 10,000회 까지 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 수위 자료는 2013년 2월 15일부터 2018년 8월 27일까지의 자료 중 순차적으로 72%는 학습에 이용하였으며 8%는 검증에 활용하였다. 또한 나머지 20%의 데이터에 대해서 학습된 모델의 성능을 평가하였다.

Table 10에서는 선행 시간에 따른 학습모델 예측결과와 관측값을 이용하여 구한 개별 수위관측소의 R² 값을 표시하였다. 하천 수위만을 이용한 하천 수위 예측결과 1시간 후의 하천수위 예측이 R² 0.99에서 0.96의 범위를 보여주어 가장 우수한 결과를 나타냈다. 예측 선행시간이 길어질수록 예측성능은 점진적으로 줄어드는 것으로 나타났으나 12시간 이후의 수위예측정보도 산청 수위 관측소 0.37을 제외하면 모든 강우관측소에서 R² 값 0.63 이상으로 유의미한 예측성능을 보여주었다.




Figure 7. Variation of coefficient of determination (hourly water elevation case)

Figure 7에서 볼 수 있듯이 선행시간 6시간 이후의 예측정확도 역시 모든 수위 관측소에 걸쳐서 선행시간 8시간 까지는 R^2 값이 0.7이상으로 예상된다. 따라서 향후 LSTM을 이용한 수위 변동 예측 모형 구축시 추가적인 정보의 입력 없이 7~8시간 이후까지는 신뢰도 높은 수위 변동 예측값을 획득할 수 있을 것으로 판단된다. 특히 이러한 정보는 돌발 호우나 태풍과 같이 단기간에 하천의 수위를 급격하게 상승시키는 재난 현상을 사전에 예측하여 대비하는데 활용이 가능할 것으로 기대된다. 추가적으로 학습된 모델을 이용한 예측값과 관측값의 시계열 비교는 Appendix B-1~B-7에 산포도 그래프는 Appendix B-8~B-14에 첨부하였다.

3.3.2 일 단위 하천수위를 이용한 하천수위 예측

LSTM 기법을 이용한 일 단위 하천수위 예측성능을 평가하기 위하여 남강댐 유역내에 위치하고 있는 8개 하천수위 지점(함양, 마천, 임천, 산청, 외송, 삼가, 신안 창촌)에 대해서 예측 선행시간(lead-time), 1일에서 7일까지의 하천 수위 변화 예측을 수행하였다. 개별 하천 수위관측소의 일 단위 수위 값을 생성하기 위하여 앞장에서 설명한바와 같이 1시에서 24시까지의 시간단위 수위 관측값의 평균값을 일 단위 대표 수위로 변환하여

입력자료를 구축하였다.

입력값으로는 개별 하천 수위 관측소의 일 단위 수위 관측자료만을 이용하였으며 과거 3일에서 14일 동안 관측된 자료를 이용하여 선행 시간별 수위를 예측하도록 모델을 구성하고 학습하도록 하였으며 그 중 가장 높은 정확도를 보여주는 선행시간을 이용하여 학습 모델을 완성하였다. 은닉층은 128개의 노드를 가지는 한 개의 층으로 구성하였으며 활성화 함수는 최근 가장 많이 사용되고 있는 ReLU 함수를 이용하였다. 반복학습은 50회에서 2,000회 까지 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 수위 자료는 2013년 2월 15일부터 2016년 12월 31일까지의 자료 중 시간 순으로 72%는 학습에 이용하였으며 8%는 검증에 활용하였다. 또한 나머지 20%의 데이터에 대해서 학습된 모델의 성능을 평가하였다.

Table 11. Predictability of predicted water elevation using daily water elevation data

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	0.5780	0.4058	0.3103	0.2119	0.1369	0.067	0.0070
Macheon	0.5359	0.3523	0.2596	0.1845	0.1351	0.0274	0.0736
Imcheon	0.5852	0.3274	0.2296	0.1358	0.1465	0.0592	0.1037
Sancheong	0.5482	0.2490	0.2037	0.0780	0.0350	-0.1374	-0.1969
Oisong	0.6068	0.3831	0.2627	0.1754	0.1075	0.0492	0.0792
Samga	0.4500	0.1972	0.1881	0.1540	0.1175	0.0915	0.0519
Shinan	0.5436	0.1800	0.1763	0.0989	0.0432	-0.0340	0.0071
Changchon	0.6023	0.3301	0.1920	0.1229	0.1463	0.1219	0.0502

Table 11에서 볼 수 있듯이 일 단위 하천 수위만을 이용한 하천 수위 예측결과는 시간 단위 수위 변화를 이용하여 예측한 하천 수위자료 예측에 비하여 상대적으로 낮은 수준의 예측정확도를 보여주었다. 1일 후의 하천수위 예측이 R² 0.6(창춘 수위관측소)에서 0.45(외송 수위관측소)의 범위를 보여주었으며 예측 선행시간이 길어질수록 예측성능은 점진적으로 감소하는 것으로 나타났으며 선행시간 6일 이상부터는 산청 수위관측소와 신안 수위관측소에서 R² 값이 음의 값을 나타내었다.




Figure 8. Variation of coefficient of determination (daily water elevation case)

Figure 8에서는 선행 시간에 따른 개별 수위관측소의 R^2 값을 표시하였다. 그림에서 볼 수 있듯이 선행시간 1일 부터 R^2 값 0.5에서 0.6 수준으로 나타났으며 3일 이후 급격히 예측성이 떨어져 0.2 이하의 값을 보여주었다. 시계열 자료 예측에 특화된 LSTM을 이용한 일 단위 하천수위 예측에서 시간 단위 하천수위 예측과 달리 저조한 예측성을 나타내는 이유는 시간단위로 예측된 하천 수위를 일 단위 평균값으로 변환하면서 하천수위의 주기성이 사라진 것으로 판단된다. 즉, 하천 수위의 증감이 하루(24 시간) 내에 발생하게 되는 경우 일 단위 자료에서는 그 증감을 파악할 수 없으므로 단 시간 내에 발생할 수위자료의 증감을 파악할 수 없어 정확도 높은 예측이 불가능한 것으로 판단된다. 따라서 추후에는 일 단위 평균 수심이 아닌 일 최대 수심 혹은 일 최저 수심에 대한 자료에 대해서 예측모형을 구축하여 재난분야의 활용성에 대한 평가가 필요할 것으로 판단된다. 추가적으로 학습된 모델을 이용한 예측값과 관측값의 시계열 비교는 Appendix C-1-1~C-1-7에 산포도 그래프는 Appendix C-1-8~C-1-14에 첨부하였다.

3.3.3 일 단위 관측강수를 이용한 하천수위 예측

LSTM 기반 일 단위 관측강수 자료를 이용한 일 단위 하천수위 예측성능을 평가하기

위하여 남강댐 유역내에 위치하고 있는 20개 강우관측소(안의, 아영, 차황, 창천, 청남, 구평, 함양, 임천, 마천, 삼가, 삼장, 산내1, 산청, 서하, 신천, 신안, 신등, 수곡, 태수, 우봉 강우관측소)의 강수 관측자료를 이용하여 8개 하천수위 지점(함양, 마천, 임천, 산청, 외송, 삼가, 신안 창촌)에 대해서 예측 선행시간(lead-time), 1일에서 7일까지의 하천 수위 변화 예측을 수행하였다. 개별 강우관측소의 일 단위 강수량을 생성하기 위하여 앞에서 설명한바와 같이 1시에서 24시까지의 시간 단위 강수 관측값을 합하여 일 단위 대표 강수로 변환하여 입력자료를 구축하였다.

입력값으로는 개별 강우 관측소의 일 단위 강수 관측자료만을 이용하였으며 과거 3일에서 14일 동안 관측된 자료를 이용하여 선행 시간별 수위를 예측하도록 모델을 구성하고 학습하도록 하였으며 그 중 가장 높은 정확도를 보여주는 선행시간을 이용하여 학습모델을 완성하였다. 은닉층은 수위 자료만을 이용한 수위 예측 모형과 동일하게 128개의 노드를 가지는 한 개의 층으로 구성하였으며 활성화 함수는 ReLU 함수를 이용하였다. 반복학습은 100회에서 2,000회 까지 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 입력자료는 2013년 2월 15일부터 2016년 12월 31일까지의 자료 중 72%는 학습에 이용하였으며 8%는 검증에 활용하였다. 또한 나머지 20%의 데이터에 대해서 학습된 모델의 성능을 평가하였다.

Table 12. Predictability of predicted water elevation using daily observed rainfall data

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	0.1935	0.0396	-0.2637	-0.3740	-0.3332	-0.6895	-0.3623
Macheon	0.2398	-0.0003	-0.0658	-0.1969	-0.3990	-0.1525	-0.2824
Imcheon	0.4991	0.2077	-0.0591	-0.1290	-0.1676	-0.0477	-0.1162
Sancheong	0.2554	-0.0520	-0.5167	-0.3641	-0.5567	-0.6452	-0.9909
Oisong	0.6088	0.2422	0.0593	-0.0831	-0.1678	-0.0822	-0.3873
Samga	0.5327	0.0675	-0.0738	-0.3101	-0.1738	-0.2742	-0.2071
Shinan	0.5225	-0.0132	-0.1598	-0.2841	-0.1412	-0.1713	-0.1350
Changchon	0.6298	0.2125	0.0177	-0.1125	-0.1927	-0.2656	-0.1118

Table 12에서 볼 수 있듯이 일 단위 관측 강수량자료를 이용한 하천 수위 예측결과 시

간단위 수위 변화를 이용하여 예측한 하천 수위자료 예측에 비하여 상대적으로 낮은 수준의 예측정확도를 보여주었다. 1일 후의 하천수위 예측이 R^2 0.6(외송 수위관측소)에서 0.24(마천 수위관측소)의 범위를 보여주었으며 예측 선행시간이 길어질수록 예측성능은 점진적으로 줄어드는 것으로 나타났으며 2일 이후부터는 마천, 산청, 신안 수위관측소에서 R^2 값이 음의 값을 나타내었으며 선행시간 4일 부터는 모든 수위관측소에서 R^2 값이 음의 값을 나타내었다.

Figure 9에서는 선행 시간에 따른 개별 수위관측소의 R^2 값을 표시하였다. 그림에서 볼 수 있듯이 선행시간 1일 부터 임천, 외송, 삼가, 신안, 창춘 수위 관측소의 R^2 값 0.5에서 0.6 수준으로 나타났으며 함양, 마천, 산청 수위 관측소의 R^2 값은 0.2에서 0.25수준을 보여주었다. 또한 2일 이후 급격히 예측성이 떨어져 0 이하의 값을 보여주는 수위관측소도 발생하였다. 예측값의 정확도가 떨어지는 이유는 강수자료의 시계열 변화와 하천수위 사이의 상관관계가 매우 낮기 때문인 것으로 판단된다. 즉, 남강댐 유역의 수위 변화에 영향을 미치는 직접 도달시간이 하루 이하이기 때문에 일 단위 강수와 일단위 수위변화 사이의 관계를 유추하기가 어려운 것으로 판단된다.

추가적으로 학습된 모델을 이용한 예측값과 관측값의 시계열 비교는 Appendix C-2-1~C-2-7에 산포도 그래프는 Appendix C-2-8~C-2-14에 첨부하였다.




Figure 9. Variation of coefficient of determination (observed rainfall case)

3.3.4 일 단위 계절내 예측자료를 이용한 하천수위 예측

계절내 예측자료를 이용하여 LSTM 기법을 활용한 일 단위 하천수위 예측성능 및 활용성을 평가하기 위하여 남강댐 유역을 포함하는 계절내 예측자료 13개 격자자료를 이용하여 8개 하천수위 지점(함양, 마천, 임천, 산청, 외송, 삼가, 신안 창촌)에 대해서 예측 선형시간(lead-time) 1일에서 7일까지의 하천 수위 변화 예측을 수행하였다.

입력값으로는 과거 3일에서 14일 동안의 계절내 예측 자료의 격자값을 이용하여 선형 시간별 수위를 예측하도록 모델을 구성하고 학습하도록 하였으며 그 중 가장 높은 정확도를 보여주는 선형시간을 이용하여 학습모델을 완성하였다. 은닉층은 수위 자료만을 이용한 수위 예측 모형과 동일하게 128개의 노드를 가지는 한 개의 층으로 구성하였으며 활성화 함수는 ReLU 함수를 이용하였다. 반복학습은 100회에서 2,000회 까지 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 입력자료는 2013년 2월 15일부터 2016년 12월 31일까지의 자료 중 72%는 학습에 이용하였으며 8%는 검증에 활용하였다. 또한 나머지 20%의 데이터에 대해서 학습된 모델의 성능을 평가하였다.

Table 13. Predictability of predicted water elevation using S2S data (40day interval)

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	-0.3294	-0.3185	-0.7979	-0.6580	-0.7874	-0.6527	-1.1009
Macheon	-0.1703	-0.2101	0.2933	-0.2594	-0.1083	-0.2944	-0.5576
Imcheon	-0.1471	-0.1898	-0.3803	-0.3128	-0.4143	-0.4550	-0.6003
Sancheong	-0.8124	-0.7209	-0.7791	-0.9292	-0.7918	-0.9978	-0.6660
Oisong	-0.1957	-0.3513	-0.2487	-0.0285	-0.3449	-0.6527	-0.3281
Samga	-0.1682	-0.2031	-0.2352	-0.3710	-0.3284	-0.2944	-0.2441
Shinan	-0.5541	-0.3670	-0.6099	-0.3692	-0.7918	-0.5643	-0.6480
Changchon	-0.1958	-0.7127	-0.4140	-0.2303	-0.5970	-0.4534	-0.3851

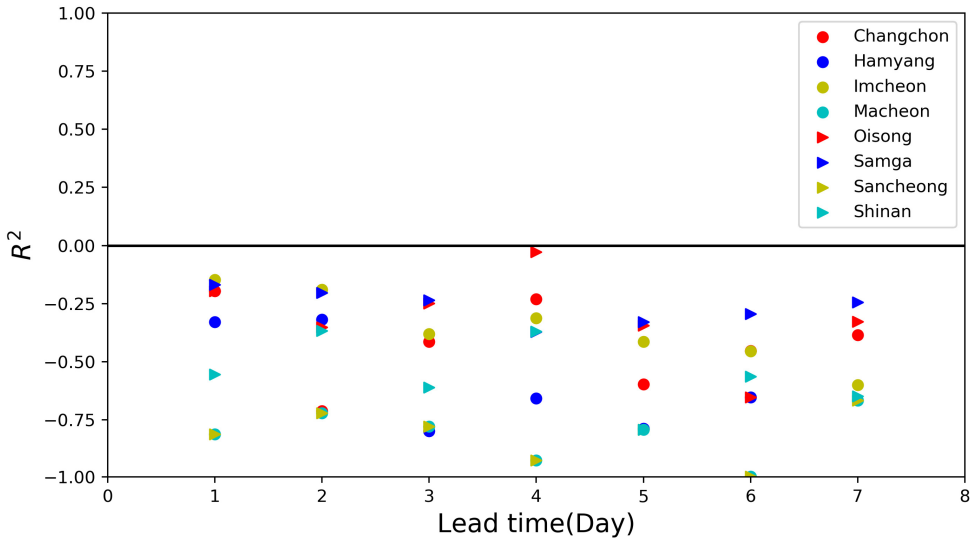


Figure 10. Variation of coefficient of determination (S2S(40 day interval case))

계절내 예측 강수자료를 이용한 하천 수위 예측은 42일 단위와 7일 단위로 구성된 입력자료 두 가지 경우에 대해서 모델 학습을 실시하였으며 그 결과는 Table 13과 14에 나타내었다. Figure 10과 11에서 볼 수 있듯이 계절내 예측 강수자료를 이용한 하천 수위 예측 결과는 42일 간격 자료와 7일 간격 자료 모두에서 1일 후 예측 자료에서부터 R^2 값이 음의 값을 나타내었다. 이는 해당 기간에 있어서 평균치로 예측한 경우($R^2=0$)보다 낮은 수준의 예측값을 나타냄을 의미하므로 기계학습을 이용한 계절내 예측자료 기반 하천 수위 예측은 활용성이 매우 낮은 것으로 판단된다. 이는 계절내 예측자료의 강수 예측 능력이 낮아 하천수위 변동에 영향을 미치는 인자를 기계학습으로 도출해 내는 것이 사실상 불가능에 가깝기 때문인 것으로 추정된다. 따라서 계절내 예측자료를 홍수위험도 평가에 활용하기 위해서는 계절내 예측자료의 정확도 향상이 우선되어야 할 것으로 판단된다.

추가적으로 학습된 모델을 이용한 42일 단위 계절내 예측자료를 이용한 예측값과 관측값의 시계열 비교는 Appendix C-3-1~C-3-7에 산포도 그래프는 Appendix C-3-8~C-3-14에 첨부 하였으며 7일 단위 계절내 예측자료를 이용한 예측값과 관측값의 시계열 비교는 Appendix C-4-1~C-4-7에 산포도 그래프는 Appendix C-4-8~C-4-14에 첨부하였다.

Table 14. Predictability of predicted water elevation using S2S data (7day interval)

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	-0.9324	-0.6786	-0.5479	-0.3774	-0.5720	-0.6989	-0.6749
Macheon	-0.2966	-0.2567	-0.3557	-0.1650	-0.1416	-0.4048	-0.6705
Imcheon	-0.0029	0.0528	-0.0702	0.0198	-0.0697	-0.0894	-0.2519
Sancheong	-0.3713	-0.3075	-0.5385	-0.3638	-0.1964	-0.4764	-0.4090
Oisong	-0.0384	-0.0187	-0.0310	-0.0195	0.0641	-0.1082	-0.1669
Samga	0.0486	0.0123	0.0049	-0.0553	-0.0398	-0.1708	-0.1081
Shinan	0.0278	0.0666	-0.0660	0.0453	0.0313	-0.0996	-0.1375
Changchon	-0.5149	0.0031	-0.0155	0.0387	0.0439	-0.0158	-0.3239




Figure 11. Variation of coefficient of determination (S2S(7 day interval case))

3.3.5 일 단위 복합자료를 이용한 하천수위 예측

본 장에서는 LSTM 기반 일 단위 강수량자료와 수위 자료(이하 복합자료)를 이용하여 일 단위 하천수위 예측성능을 평가하였다. 본 장에서 이용된 강수량자료는 남강댐 유역 20 개 강우관측소에서 관측된 자료, 42일 주기 계절내 예측자료와 7일 주기 계절내 예측자료이다. 입력 자료로 활용된 하천 수위는 예측 대상 하천 수위 관측소에서 관측된 하천 수위만을 이용하였다. 예측 선행시간(lead-time)은 앞선 연구와 마찬가지로 1일에서 7일

까지의 하천 수위 변화 예측을 수행하였다.

입력값은 과거 3일에서 14일 동안의 강수량자료와 하천수위자료를 활용하여 선행 시간 별 수위를 예측하도록 모델을 구성하고 학습하도록 하였으며 그 중 가장 높은 정확도를 보여주는 선행시간을 이용하여 학습모델을 완성하였다. 은닉층은 수위 자료만을 이용한 수위 예측 모형과 동일하게 128개의 노드를 가지는 한 개의 층으로 구성하였으며 활성화 함수는 ReLU 함수를 이용하였다. 반복학습은 100회에서 5,000회 까지 설정하여 그 중 가장 정확도가 높은 값을 취하도록 하였다. 입력자료는 2013년 2월 15일부터 2016년 12월 31일까지의 자료 중 72%는 학습에 이용하였으며 8%는 검증에 활용하였다. 또한 나머지 20%의 데이터에 대해서 학습된 모델의 성능을 평가하였다.

Table 15. Predictability of predicted water elevation using observed rainfall and water elevation data

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	0.5789	0.0825	-0.0139	-0.3543	0.0002	-0.2810	-0.5264
Macheon	0.6074	0.1730	-0.1136	-0.8971	-0.3684	-0.1112	-0.4034
Imcheon	0.6330	0.2386	0.1112	-0.0799	-0.1324	-0.0340	-0.1326
Sancheong	0.4240	0.2254	0.0367	-0.4281	-0.3500	-0.2979	-0.6610
Oisong	0.5278	0.2383	0.1831	0.0954	-0.1610	-0.1764	-0.1058
Samga	0.5612	0.1814	0.0813	-0.0055	-0.6428	-0.1496	-0.1469
Shinan	0.6724	0.0570	-0.0809	-0.1128	-0.1651	-0.3904	-0.3151
Changchon	0.5558	0.2398	-0.2463	0.0769	0.1544	0.02227	-0.1434

Table 15에서는 관측강수와 하천수위를 입력자료로 활용하여 학습된 모형의 선행 시간에 따른 개별 수위관측소의 R² 값을 표시하였다. 그림에서 볼 수 있듯이 선행시간 1일의 R²값은 최소 0.42(산청 강우관측소)에서 최대 0.67(신안 강우관측소)을 보여주었으며 선행시간 2일까지는 낮은 수준이나 양의 값을 보여주고 있다. 일 단위 관측강수와 하천수위 복합자료를 이용한 하천 수위 예측결과는 강수량자료만을 이용한 예측결과보다는 향상된 결과를 보였다. 관측강수와 하천수위를 입력자료로 활용하여 구축한 예측모형의 경우 선행시간 1일에 대한 예측결과는 R² 최소 0.42(산청 수위관측소)에서 0.67(신안 수위관측소)까지의 값을 보여 관측강수만을 이용한 예측모형의 선행시간 1일 R² 값(0.24~0.6)

보다 향상된 결과를 보여주었다. 이는 해당 지점의 수위변화에 영향을 미치는 수문인자 중 주기성을 포함하고 있는 과거 하천 수위 변동이 입력값으로 추가되어 예측성능을 향상시킨 것으로 판단된다.




Figure 12. Variation of coefficient of determination (observed rainfall and water elevation data)

그러나 Figure 12에서 볼 수 있듯이 예측 3일 이후부터는 함양, 마천, 신안, 창춘 수위 관측소에서 결정계수 R^2 값이 음의 값을 나타내며 예측값으로서 의미 있는 값을 도출해 내지 못하는 것을 확인할 수 있다. 이는 앞서 언급한 바와 같이 일 단위 관측자료가 자료 자체의 시계열적 특성을 상실한 것과 강수자료와 하천 수위 사이의 인과관계가 명확하지 않아 발생하는 것으로 판단된다.

추가적으로 관측 강수자료와 수위 자료를 입력자료로 하여 학습된 모델을 이용한 예측 값과 관측값의 시계열 비교는 Appendix D-1-1~D-1-7에 산포도 그래프는 Appendix D-1-8~D-1-14에 첨부하였다.

Table 16와 Figure 13에서는 42일 단위 계절내 예측자료와 하천 수위를 이용한 개별 수위관측소의 예측 선행 시간에 따른 R^2 값을 표시하였다. 그림에서 볼 수 있듯이 선행시간 1일의 R^2 값은 최소 0.42(산청 강우관측소)에서 최대 0.67(신안 강우관측소)을 보여주

었으며 선행시간 2일 이후부터는 산청과 삼가 수위 관측소를 제외하고는 모두 음의 값을 나타내었다. 비록 선행시간 2일 이후부터는 예측자료로 활용하기 어려운 수준의 예측성을 나타내고 있으나 관측강수와 하천수위를 입력자료로 활용하여 구축한 예측모형의 경우 선행시간 1일(R^2 0.67~0.42)에 대해서는 관측강수만을 이용한 예측모형의 선행시간 1일 R^2 값(0.24~0.6) 보다 향상된 결과를 보여주었다. 이는 해당 지점의 수위변화에 영향을 미치는 수문인자 중 주기성을 포함하고 있는 과거 하천 수위 변동이 입력값으로 추가되어 예측성능을 향상 시킨 것으로 판단된다.

추가적으로 42일 주기 계절내 예측 강수자료와 수위 자료를 입력자료로 하여 학습된 모델을 이용한 예측값과 관측값의 시계열 비교는 Appendix D-2-1~D-2-7에 산포도 그래프는 Appendix D-2-8~D-2-14에 첨부하였다.

Table 16. Predictability of predicted water elevation using S2S (40day interval) and water elevation data

Water Gauge Station	R^2						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	0.3603	-0.0022	-0.2535	-0.1435	-0.9714	-0.4349	-0.2362
Macheon	0.2854	-0.2962	0.0344	-0.1032	-0.3177	-0.5304	0.0067
Imcheon	0.4242	-0.0258	-0.1023	-0.1961	-0.3935	-0.3639	0.0099
Sancheong	0.3017	0.0968	0.0680	-0.4731	-0.2106	-0.3805	-0.3650
Oisong	0.3918	-0.1383	-0.5830	-0.0084	-0.3117	-0.3951	-0.1983
Samga	0.1685	0.0714	-0.2184	-0.0707	-0.1583	-0.3804	-0.1216
Shinan	0.1180	-0.0843	-0.1705	0.1979	-0.3821	-0.7788	-0.2499
Changchon	0.2067	-0.6767	-0.0400	-0.1813	-0.8851	-0.3017	-0.4041

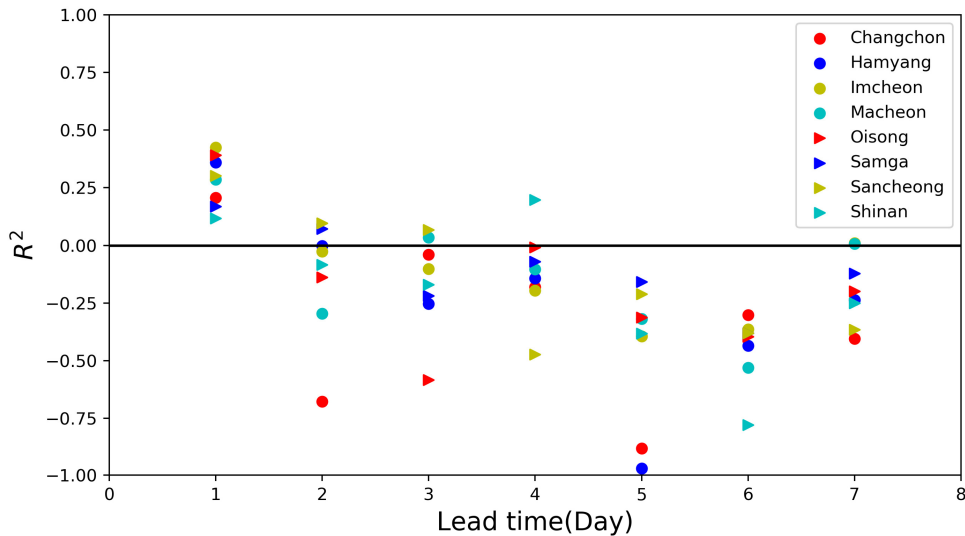


Figure 13. Variation of coefficient of determination (S2S(40day interval) and water elevation data)

Table 17과 Figure 14에서는 7일 단위 계절내 예측자료와 하천 수위를 이용한 개별 수위관측소의 예측 선행 시간에 따른 R^2 값을 표시하였다. 그림에서 볼 수 있듯이 선행시간 1일의 R^2 값은 최소 0.12(창춘 강우관측소)에서 최대 0.45(함양 강우관측소)을 보여주었으며 선행시간 2일 역시 R^2 값이 최소 0.11(신안 강우관측소)에서 최대 0.24(임천 강우관측소)의 값을 보여주고 있다. 이는 역시 계절내 예측자료만을 단독으로 이용하여 하천 수위를 예측한 결과(R^2 -0.93~0.05)보다 예측 정확도가 상당히 향상된 것을 확인할 수 있다. 이는 해당 지점의 수위변화에 영향을 미치는 수문인자 중 주기성을 포함하고 있는 과거 하천 수위 변동이 입력값으로 추가되어 예측성능을 향상 시킨 것으로 판단되며 선행시간 1일까지는 계절내 예측자료를 이용한 하천수위 변동 모형의 활용성이 일정 부분 존재하는 것으로 판단된다.

Table 17. Predictability of predicted water elevation using S2S (7day interval) and water elevation data

Water Gauge Station	R ²						
	1 day	2 day	3 day	4 day	5 day	6 day	7 day
Hamyang	0.4455	0.0783	-0.3240	-0.2877	-0.1644	-0.8657	-0.1165
Macheon	0.3656	0.2338	-0.1823	-0.4313	0.0864	-0.5045	-0.4193
Imcheon	0.3765	0.2422	0.0982	-0.1075	0.1522	0.0102	-0.0810
Sancheong	0.2961	0.1176	0.0088	0.0014	0.0436	-0.3386	-0.2936
Oisong	0.4065	0.1678	0.0333	-0.1493	0.0921	0.0752	-0.0425
Samga	0.3610	0.2245	0.0101	0.2401	0.1530	-0.1192	-0.1800
Shinan	0.2399	0.1098	-0.0621	0.1990	0.0501	-0.1041	-0.0823
Changchon	0.1198	0.1868	0.017	0.1303	0.1620	0.0428	-0.0881

추가적으로 7일 주기 계절내 예측 강수량자료와 수위 자료를 입력자료로 하여 학습된 모델을 이용한 예측값과 관측값의 시계열 비교는 Appendix D-3-1~D-3-7에 산포도 그래프는 Appendix D-3-8~D-3-14에 첨부하였다.




Figure 14. Variation of coefficient of determination (S2S(7day interval) and water elevation data)

4. 결론

본 연구에서는 이음새 없는 기상·기후 예측정보 중 최근 중요성과 관심도가 증가하고 있는 계절내 예측자료의 정확도를 평가하고 재난분야, 특히 하천 홍수위험도 평가에 대한 활용성을 평가하였다.

계절내 예측자료의 정확도를 평가하기 위하여 연구대상 지역을 남강댐 유역으로 선정하였으며 42일 단위, 7일 단위 계절내 예측자료에 대해서 연구 대상 유역 남강댐 8개 강우관측소에 해당하는 격자 강수값을 추출하여 관측 강수값과 직접 비교를 통해 계절내 예측자료의 예측정확도를 평가하였다. 계절내 예측자료의 예측정확도 평가를 위해 RMSE 분석과 결정계수(R^2)값을 이용한 분석을 수행하였다. 대상기간은 계절내 예측자료와 강우관측소의 관측기간이 겹치는 2013년 2월 5일~2016년 12월 31일 기간에 대해 수행되었다. 42일 단위 예측정보의 RMSE 분석결과 최저 11.02(안의 강우관측소)에서 최대 21.55(신천 강우관측소)로 나타났으며 R^2 값은 -0.1041(안의 강우관측소)에서 0.0403(창천 강우관측소) 수준으로 상당히 낮은 수준의 예측정확도를 가지는 것으로 분석되었다. 7일 단위 계절내 예측정보의 RMSE는 최소 10.06(구평 강우관측소)에서 최대 20.29(시천 강우관측소)로 나타났으며 R^2 는 0.053(안의 강우관측소)에서 0.2417(서하 강우관측소)로 42일 단위 계절내 예측정보 보다는 우수한 결과를 보여주었으나 대체적으로 낮은 수준의 예측정확도를 보여주었다.

계절내 예측자료의 정확도 향상을 위해 기계학습 기법 중 하나인 다층 퍼셉트론을 이용하여 한반도 영역에 대한 계절내 예측자료를 입력자료로 하여 남강댐 강우관측소의 강수량을 학습시키는 연구가 수행되었다. 입력자료로는 계절내 예측자료 중 한반도 영역을 포함하는 962개의 격자값이 이용되었으며 2013년 2월 15일부터 2015년 12월 31일까지의 자료로 학습을 시키고 2016년 1월 1일부터 동년 12월 31일까지의 자료에 대해 학습된 모델의 성능을 평가하였다. 평가 결과 42일 주기와 7일 주기 계절내 예측자료를 이용한 계절내 예측자료 정확도 향상 모델은 R^2 값이 학습이전보다 예측 성능이 좋다고 판단할 만한 값을 얻지 못하였으며 특히, 결정계수 값이 음의 값을 나타내며 예측력이 오히려 저하되는 경우도 발생하는 것을 확인할 수 있었다. 결정계수 R^2 값이 0보다 작은

음수를 나타내는 경우에는 편차의 제곱보다 오차의 제곱이 더 크다는 것을 의미하므로 이는 계절내 예측정보 정확도 향상 모델의 결과값이 강우관측소의 평균 강수량 값을 이용한 예측값보다 성능이 떨어짐을 의미하므로 다층 퍼셉트론을 이용한 계절내 예측정보의 향상 기법은 효과적인 성능 향상을 기대하기 어려운 수준으로 판단된다.

또한 추가적으로 계절내 예측자료를 활용한 하천 홍수위험도 평가를 위해 시계열 자료 기계학습에 효과적인 LSTM 기법을 활용하여 남강댐 유역 하천수위 변동을 예측하였다. 먼저 계절내 예측자료를 활용한 하천수위 변동 예측 활용성을 평가하기 위하여 1) LSTM 기법을 활용하여 시간 단위 하천수위 자료만을 이용한 하천수위 변동 예측, 2) LSTM 기법 기반 일 단위 강수량(관측, 계절내 예측)를 이용한 하천수위 변동 예측, 3) LSTM 기법 기반 일 단위 복합자료(하천수위와 강수량)를 이용한 하천수위 변동 예측을 수행하였다.

먼저 하천 수위만을 이용하여 LSTM 모형을 구축하여 선행시간 1시간, 2시간, 3시간, 4시간, 5시간, 6시간, 12시간 별로 하천 수위 예측을 수행하였다. 수행결과 선행시간 1시간에 대한 하천수위 예측은 R^2 값 0.99에서 0.96수준으로 매우 우수한 예측 성능을 보여 주었으며 선행시간 6시간에 대해서도 R^2 값이 최소 0.77에서 최대 0.85까지 나타나 향후 LSTM을 이용한 수위 변동 예측 모형 구축시 추가적인 정보의 입력 없이 7~8시간 이후까지는 신뢰도 높은 수위 변동 예측값을 획득할 수 있을 것으로 판단된다. 특히 이러한 정보는 돌발 호우나 태풍과 같이 단기간에 하천의 수위를 급격하게 상승시키는 재난 현상 하에서도 활용이 가능할 것으로 기대된다.

일 단위 강수량(관측, 계절내 예측)를 이용한 LSTM 기법 기반 하천수위 변동 예측 모형을 구축하기 위하여 남강댐 유역 20개 강우관측소의 관측자료와 42일 주기 그리고 7일 주기의 계절내 예측자료를 이용하여 남강댐 유역 8개 하천수위 관측소의 수위값을 선행시간 1일에서 7일까지 예측하였다. 예측결과 일 단위 관측 강수량을 이용한 하천 수위 예측 결과는 시간 단위 수위 변화를 이용하여 예측한 하천 수위 자료 예측에 비하여 상대적으로 낮은 수준의 예측정확도를 보여주었다. 특히 1일 후의 하천 수위 예측은 R^2 값이 0.6에서 0.24 수준을 보여주었으며 선행시간 2일 부터는 음의 값을 보여주어 예측 자료로서의 활용도가 거의 없는 것으로 나타났다. 42일 주기와 7일 주기 계절내 예측자

료를 이용한 하천수위 예측은 선행시간 1일부터 R^2 값이 음의 값을 나타내어 예측성 및 활용성이 거의 전문한 것으로 나타났다.


일 단위 복합자료(강수량자료와 하천수위)를 이용한 LSTM 기법 기반 하천수위 변동 예측모형을 구축하여 관측강수와 하천수위, 42일 주기 계절내 예측자료와 하천수위 그리고 7일 주기 계절내 예측자료와 하천수위를 입력자료를 이용하여 하천수위 예측을 수행하였다. 예측결과 지상 강수 관측소 자료와 하천수위를 입력자료로 학습한 모형의 예측결과 선행시간 1일의 R^2 값은 최소 0.42(산청 강수관측소)에서 최대 0.67(신안 강수관측소)을 보여주었으며 선행시간 2일까지 낮은 수준이나 양의 값을 보여주었다. 이는 선행 시간 1일에 대한 예측자료에 대해서 지상강수관측소 자료와 하천수위 자료를 단독으로 활용한 경우보다 높은 수준의 예측성을 나타내는 결과로써 해당 수위 관측소의 지점의 수위변화에 영향을 미치는 수문인자 두 개(강수, 수위)가 모두 입력값으로 추가되어 예측력 상승효과가 나타난 것으로 판단된다. 42일 단위 계절내 예측자료와 하천 수위를 이용한 수위관측소의 예측 선행 시간에 따른 R^2 값 역시 선행시간 1일에 대해서 최소 0.42(산청 강수관측소)에서 최대 0.67(신안 강수관측소)을 보여주어 42일 단위 계절내 예측자료만을 단독으로 활용하여 예측모형을 구축한 경우보다 매우 높은 수준의 예측성 향상이 나타났다. 7일 주기 계절내 예측자료와 하천수위를 이용한 하천수위 예측 모형의 결과 역시 선행시간 1일의 R^2 값이 최소 0.12(창촌 강수관측소)에서 최대 0.45(함양 강수관측소)로 나타나 7일 주기 계절내 예측자료만을 이용하여 구축한 하천 수위 예측모형 보다 매우 높은 예측 성능을 보여주었다. 따라서 계절내 예측자료와 하천수위를 함께 이용하여 LSTM 모형을 구축하는 경우 재난 대비 측면에서 하천 홍수 위험도를 파악 할 수 있을 것으로 판단된다. 그러나 계절내 예측자료 자체의 강수 예측성의 한계로 인하여 선행 시간 2일 이후부터는 R^2 값이 매우 낮은 수준을 보여주므로 향후 앙상블 기법기반의 계절내 예측자료의 정확도 향상에 관한 연구와 향상된 정확도의 계절내 예측자료의 활용성 및 적용성 평가에 대한 연구가 보다 다양한 분야에 대해서 수행되어야 할 것으로 판단된다.

REFERENCES


- Lee, H. H., Jung, S. H. & Choi, E. J. (2016). "A Case Study on Improving Performance of Machine Learning Application and Learning Algorithm." *Digital fusion research* 14, no. 2 (2016): 245-258. (In Korean)
- Regueiro, C. V., Domenech, J. E., Iglesias, R., & Correa, J. L. (2006). Acquiring contour following behaviour in robotics through q-learning and image-based states. *International Journal of Applied Mathematics and Computer Sciences*, 1(2).
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., Déqué, M., Ferranti, L., Fucile, E., Fuentes, M. and Hendon, H., 2017. The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1), pp.163-173.
- Brunet, G., Shapiro, M., Hoskins, B., Moncrieff, M., Dole, R., Kiladis, G.N., Kirtman, B., Lorenc, A., Mills, B., Morss, R. and Polavarapu, S., 2010. Collaboration of the weather and climate communities to advance subseasonal-to-seasonal prediction. *Bulletin of the American Meteorological Society*, 91(10), pp.1397-1406.
- Vitart, F., Ardilouze, C., Bonet, A., Brookshaw, A., Chen, M., Codorean, C., Déqué, M., Ferranti, L., Fucile, E., Fuentes, M. and Hendon, H., 2017. The subseasonal to seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1), pp.163-173.
- Rosenblatt, F., 1957. *The perceptron, a perceiving and recognizing automaton* Project Para. Cornell Aeronautical Laboratory.
- Rhee, J., Im, J. and Park, S., 2016. *Drought Forecasting Based on Machine Learning of Remote Sensing and Long-range Forecast Data*. APEC Climate Center, Republic of Korea.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1986. Learning representations by back-propagating errors. *nature*, 323(6088), p.533.
- Hochreiter, S. and Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), pp.1735-1780.
- Saputra, A., Talebi, H., Tran, D., Birk, C. and Song, C., 2017. Automatic image-based stress analysis by the scaled boundary finite element method. *International Journal for Numerical Methods in Engineering*, 109(5), pp.697-738.

Appendix A

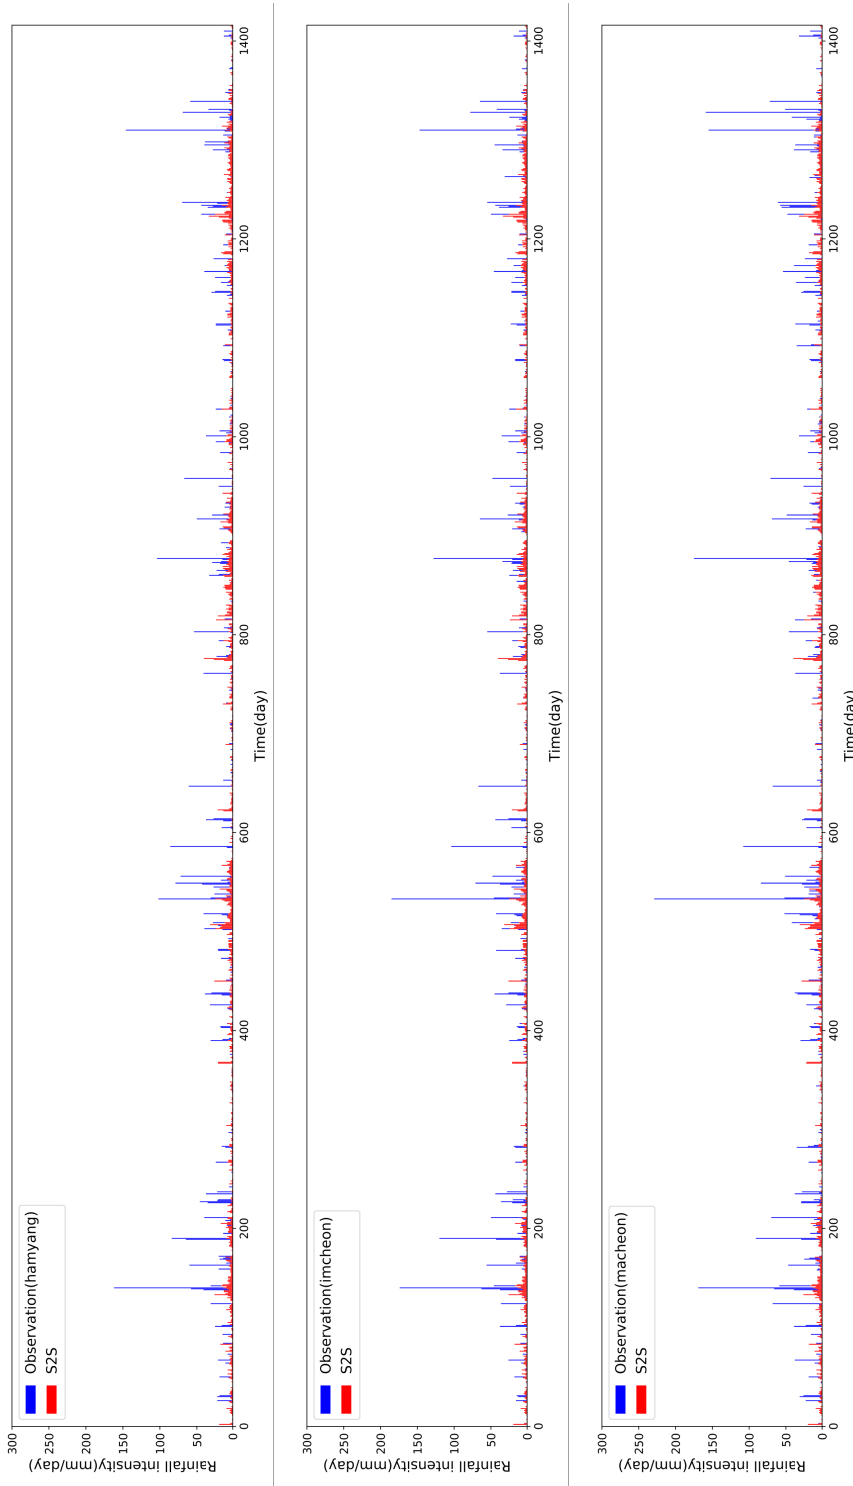
A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)




A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)




A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)




A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)





A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)




A-1. Comparison of S2 (40 day interval) vs. measured station rainfall (cont.)




A-1. Comparison of S2 (40 day interval) vs. measured station rainfall




A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)




A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)




A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)






A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)




A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)



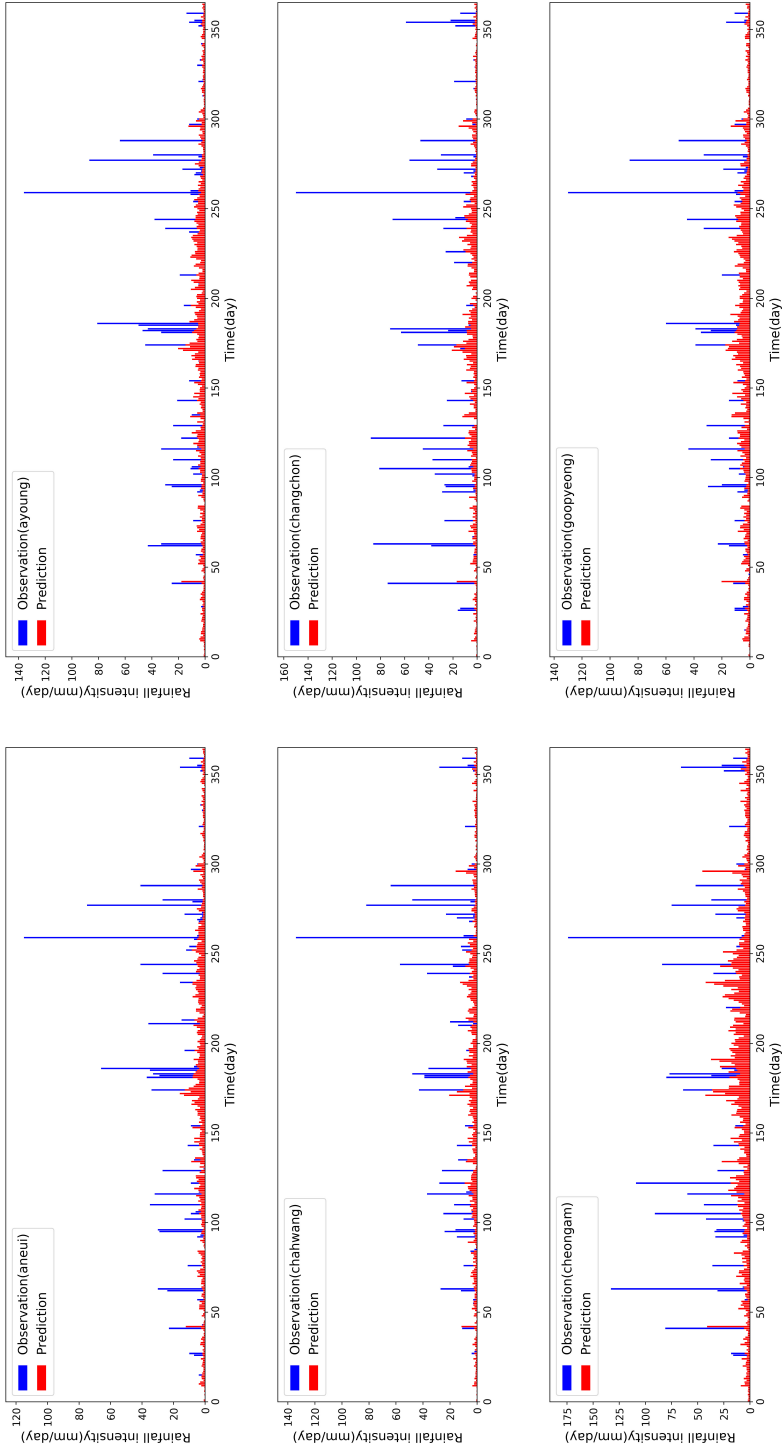
A-2. Comparison of S2S (7 day interval) vs. measured station rainfall (cont.)



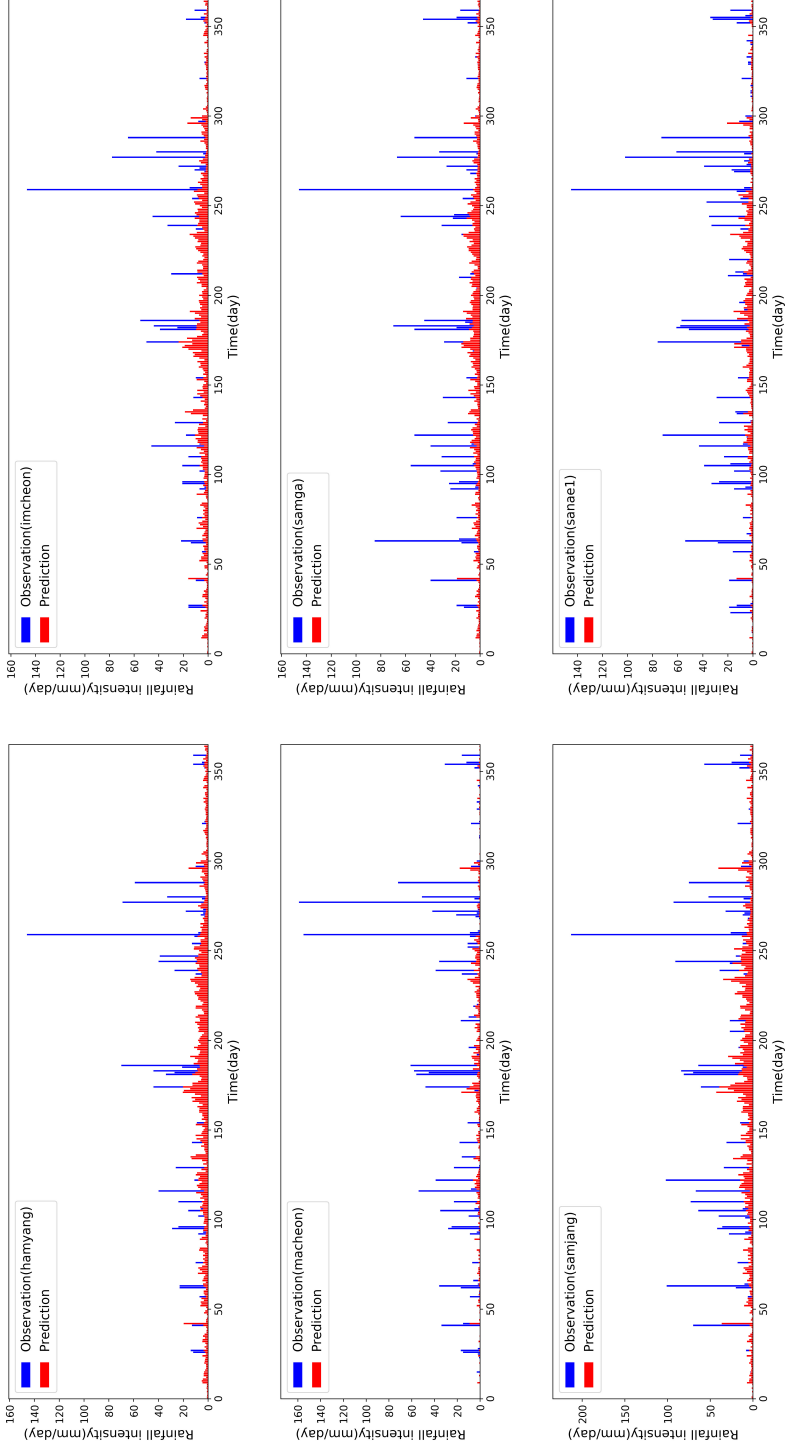
A-2. Comparison of S2S (7 day interval) vs. measured station rainfall



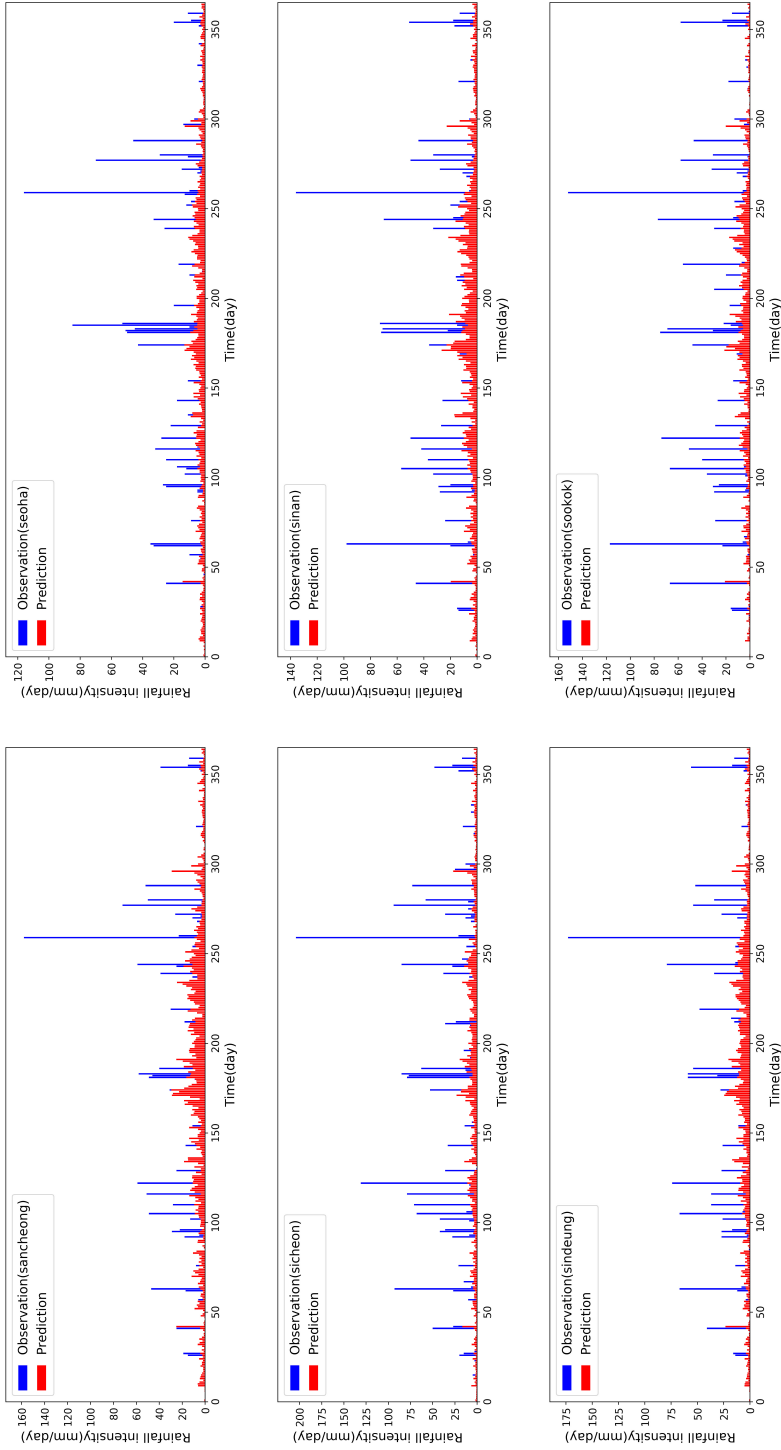
A-3. Comparison of Multilayer Perceptron result using S2S (40 day interval) vs. measured station rainfall (cont.)





A-3. Comparison of Multilayer Perceptron result using S2S (40 day interval) vs. measured station rainfall (cont.)



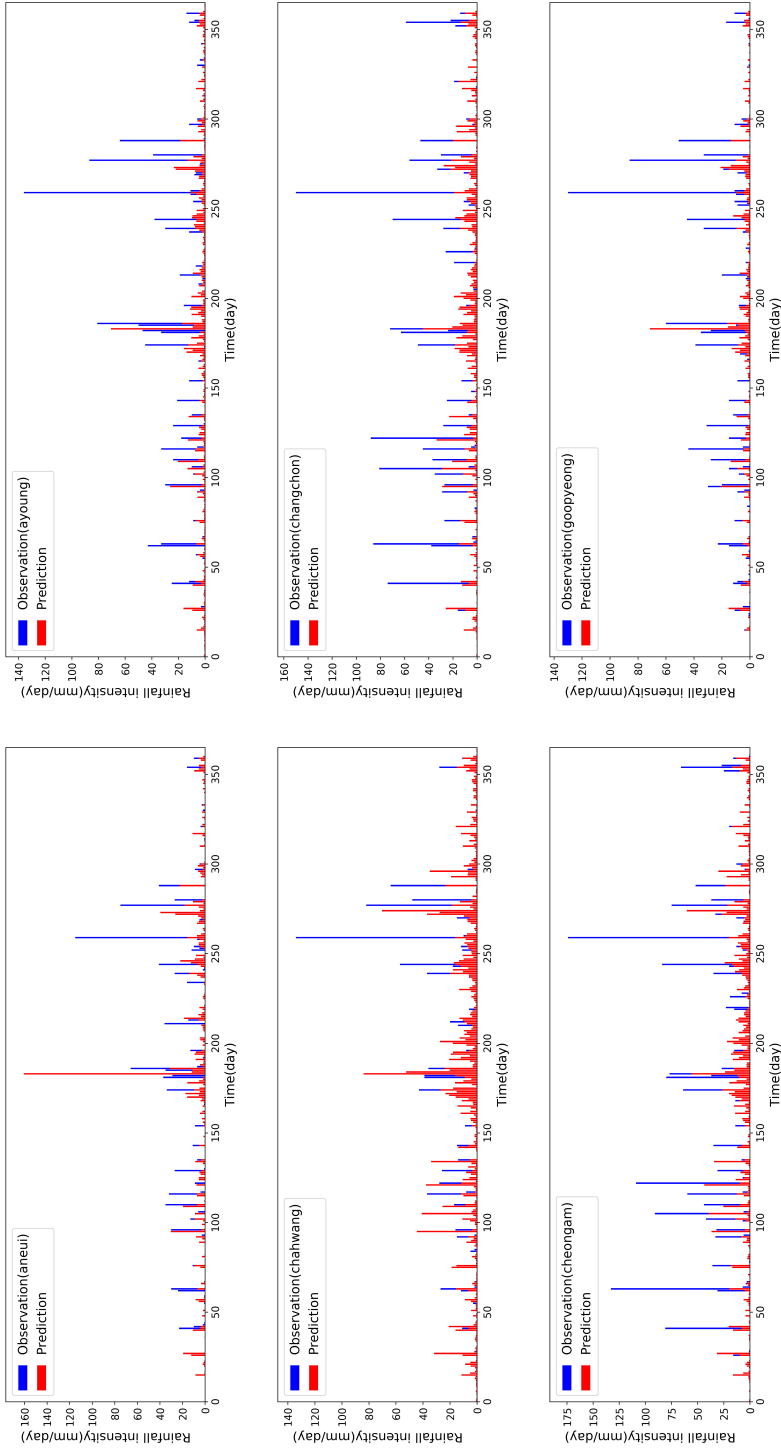
A-3. Comparison of Multilayer Perceptron result using S2S (40 day interval) vs. measured station rainfall (cont.)



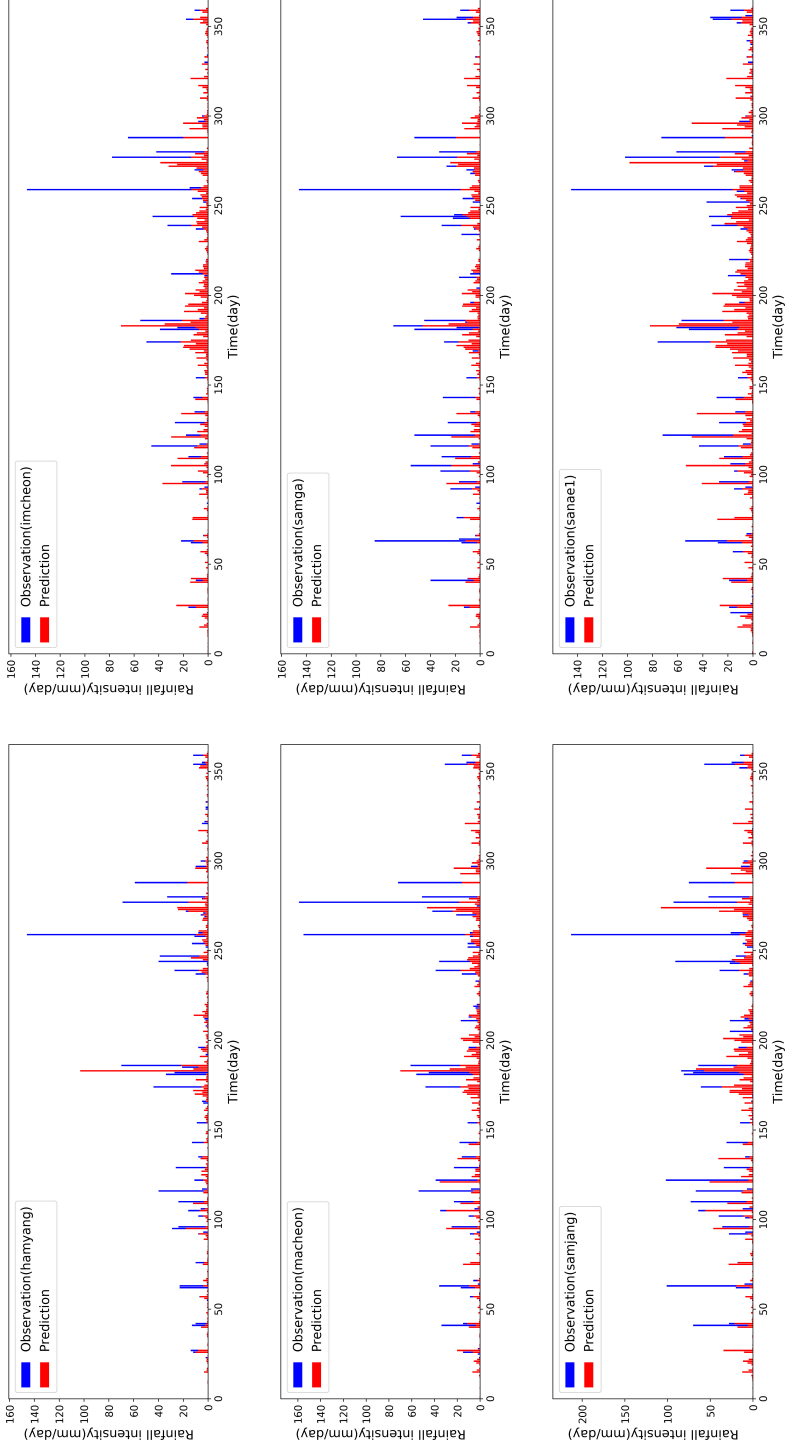
A-3. Comparison of Multilayer Perceptron result using S2S (40 day interval) vs. measured station rainfall



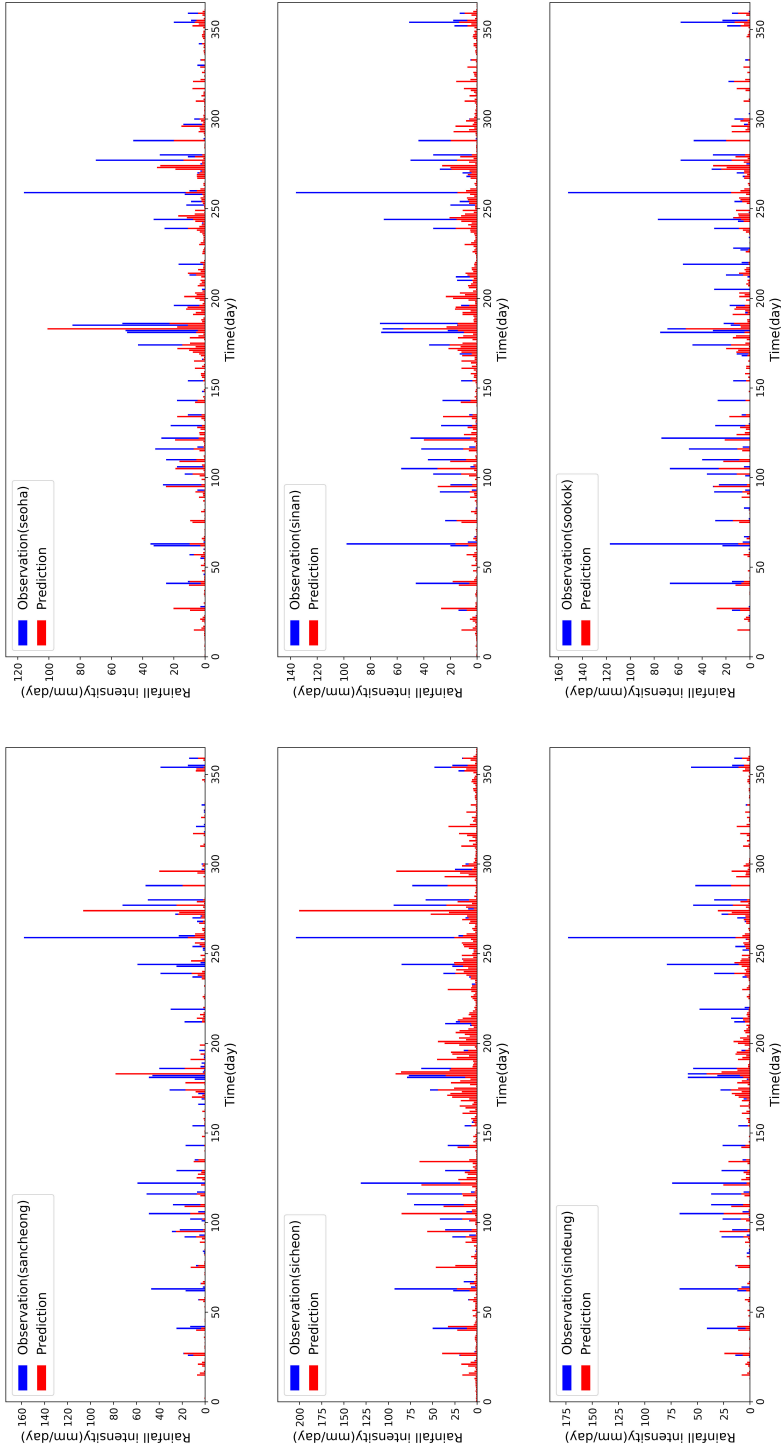
A-4. Comparison of Multilayer Perceptron result using S2S (7 day interval) vs. measured station rainfall (cont.)





A-4. Comparison of Multilayer Perceptron result using S2S (7 day interval) vs. measured station rainfall (cont.)



A-4. Comparison of Multilayer Perceptron result using S2S (7 day interval) vs. measured station rainfall (cont.)

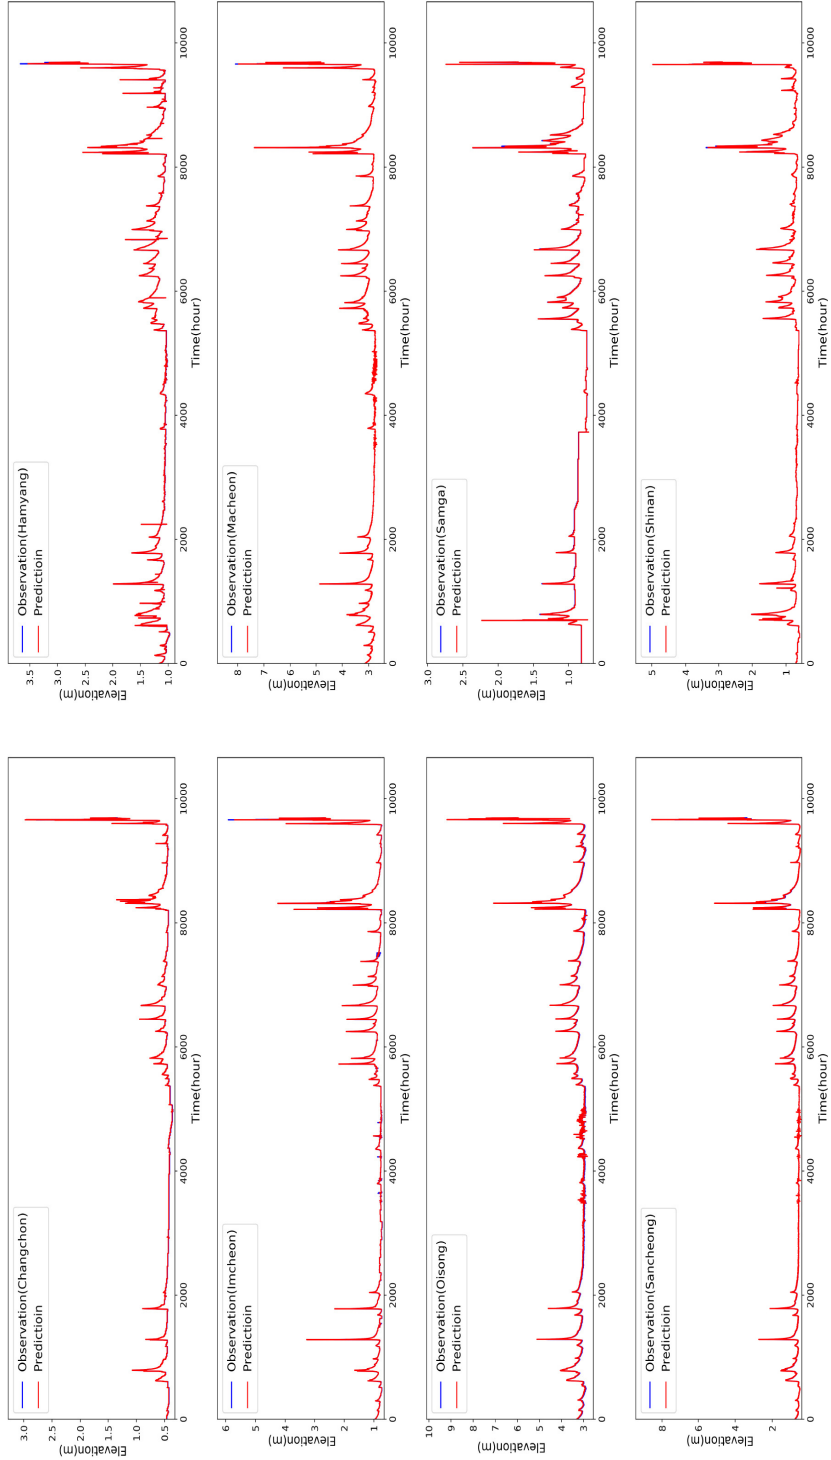


A-4. Comparison of Multilayer Perceptron result using S2S (7 day interval) vs. measured station rainfall

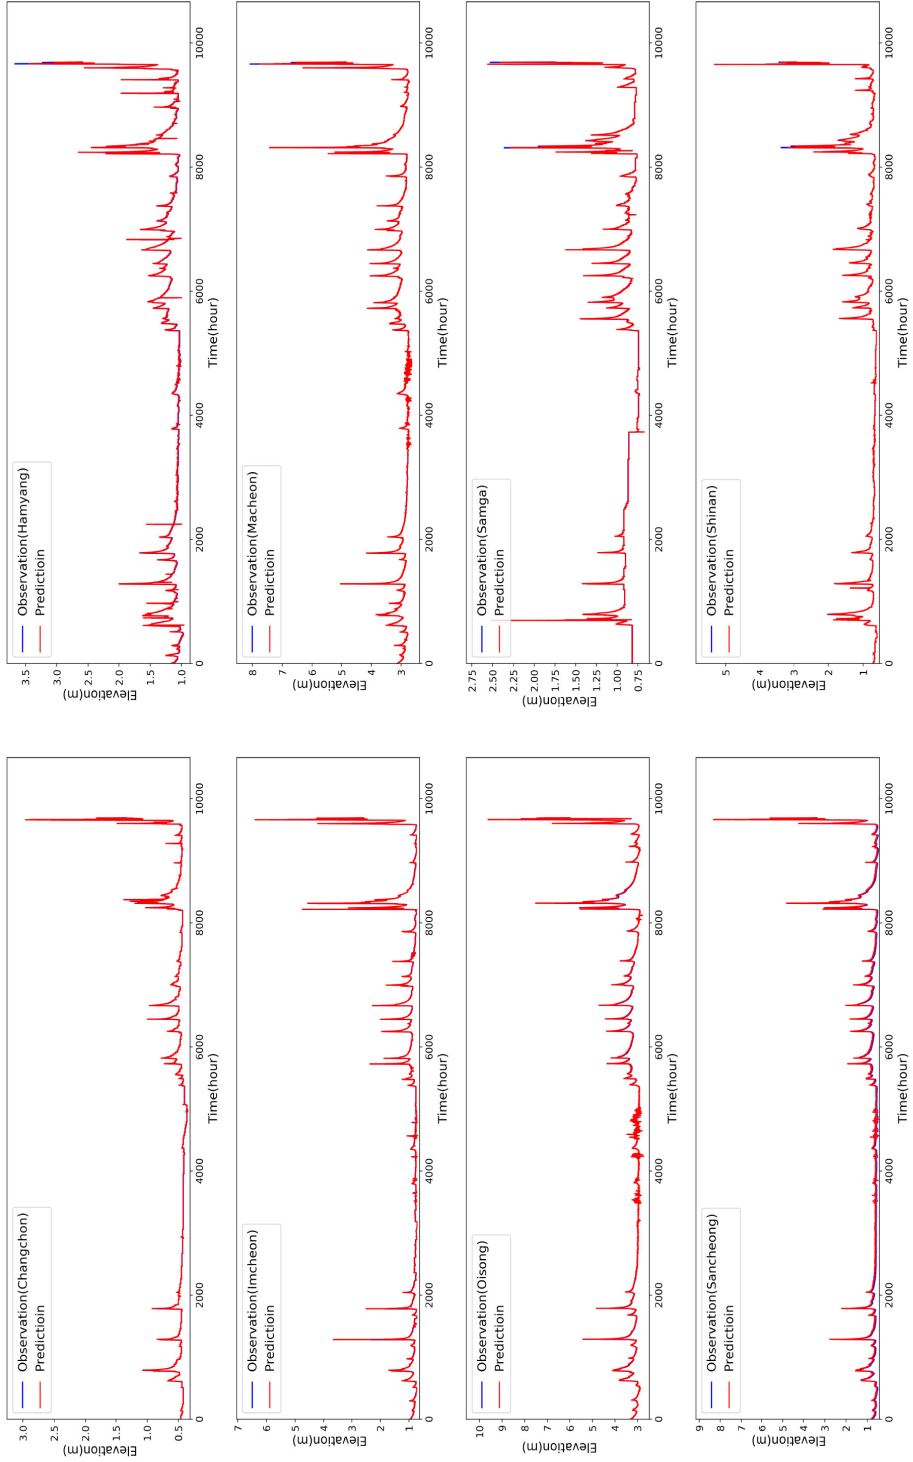


Appendix B

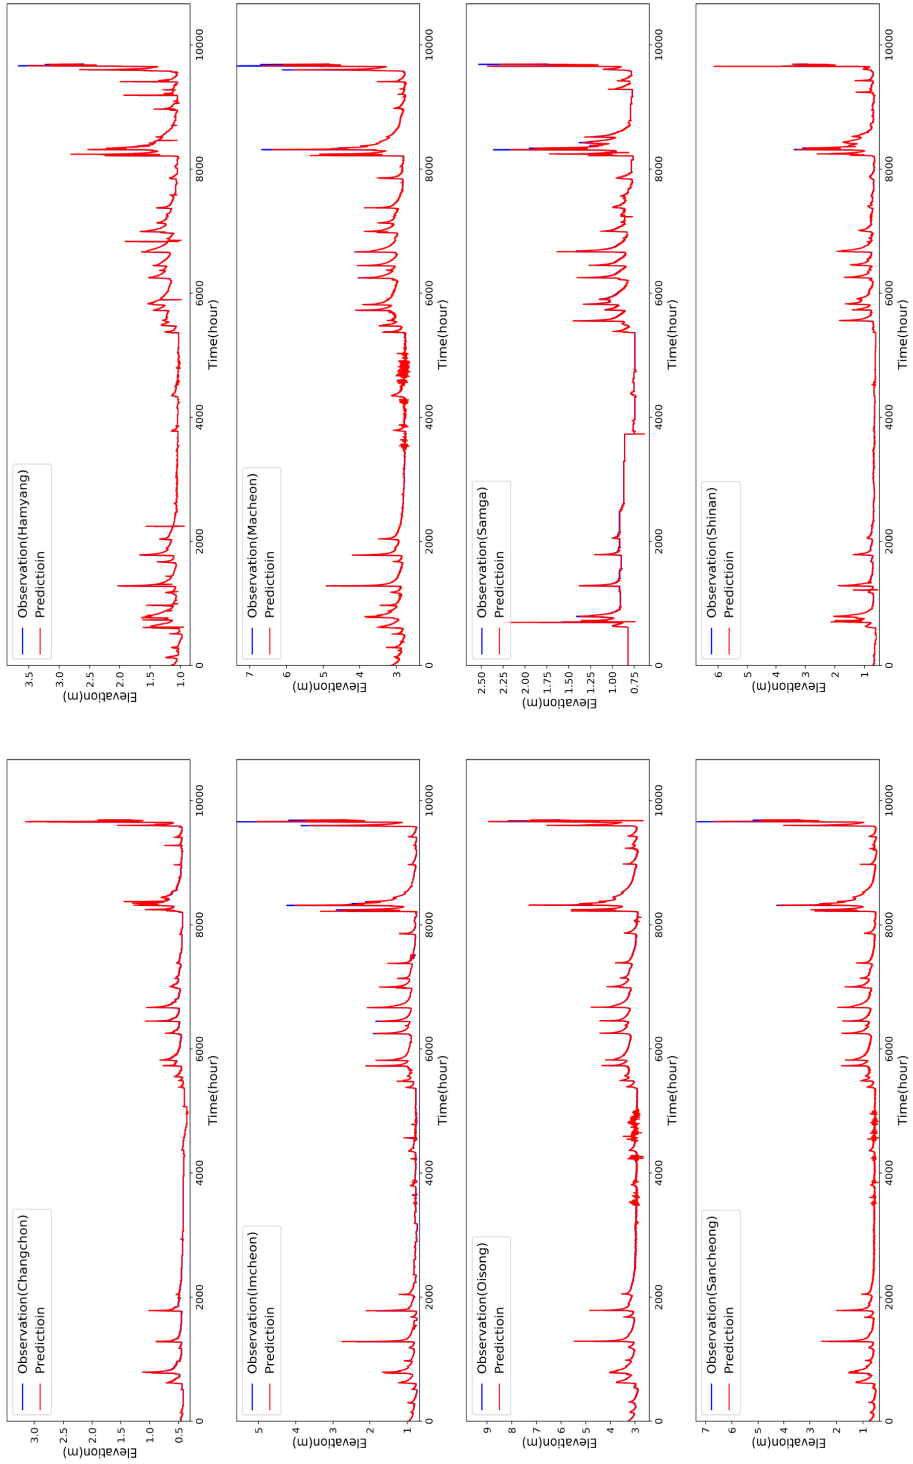
B-1. Comparison of LSTM prediction (1h) vs. measured water elevation data



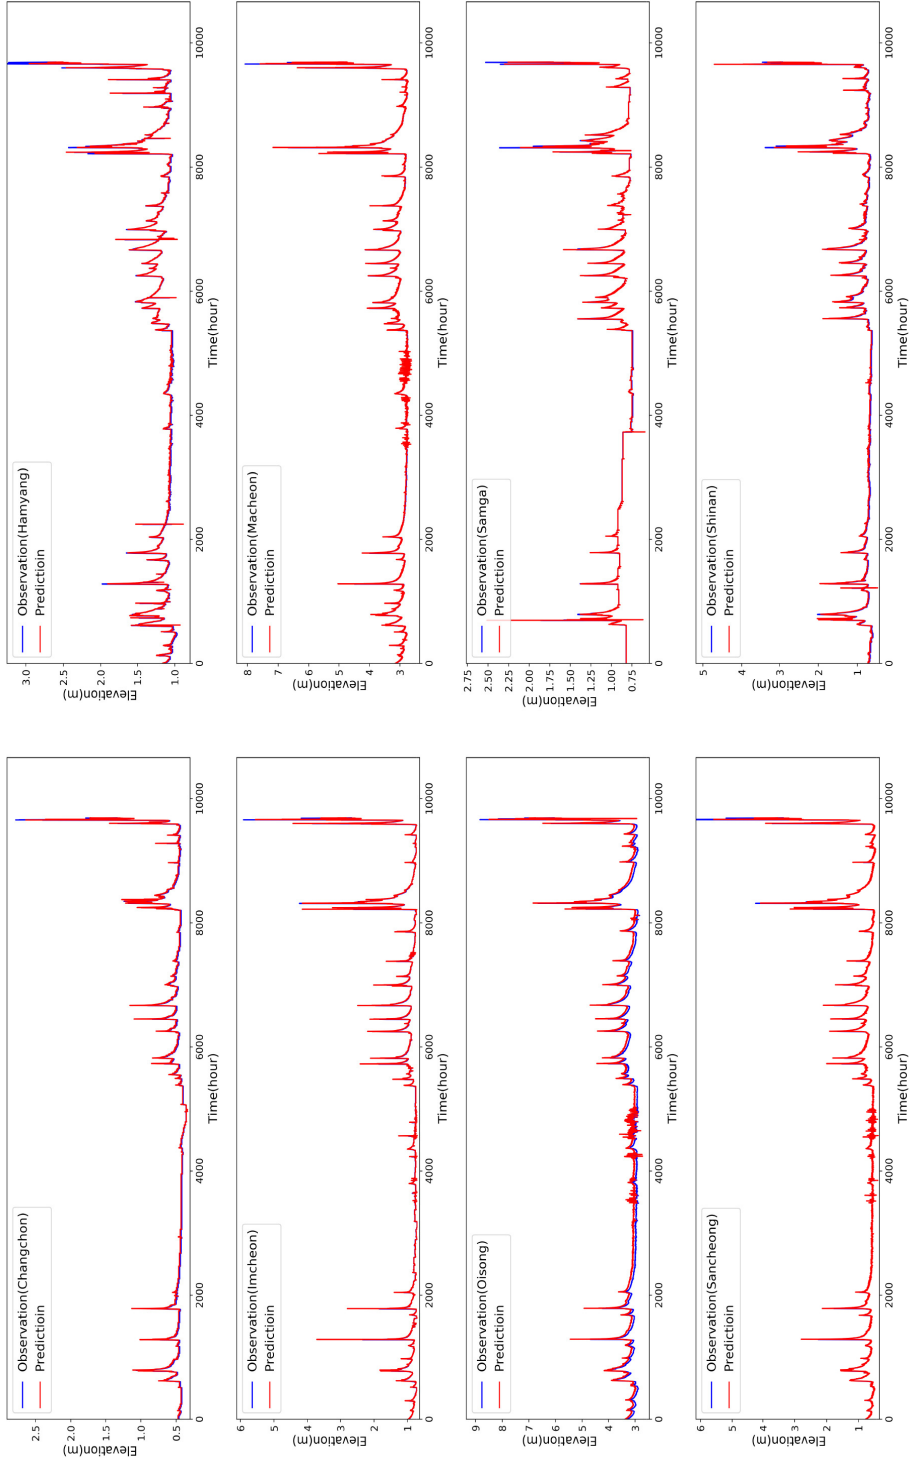
B-2. Comparison of LSTM prediction (2h) vs. measured water elevation data



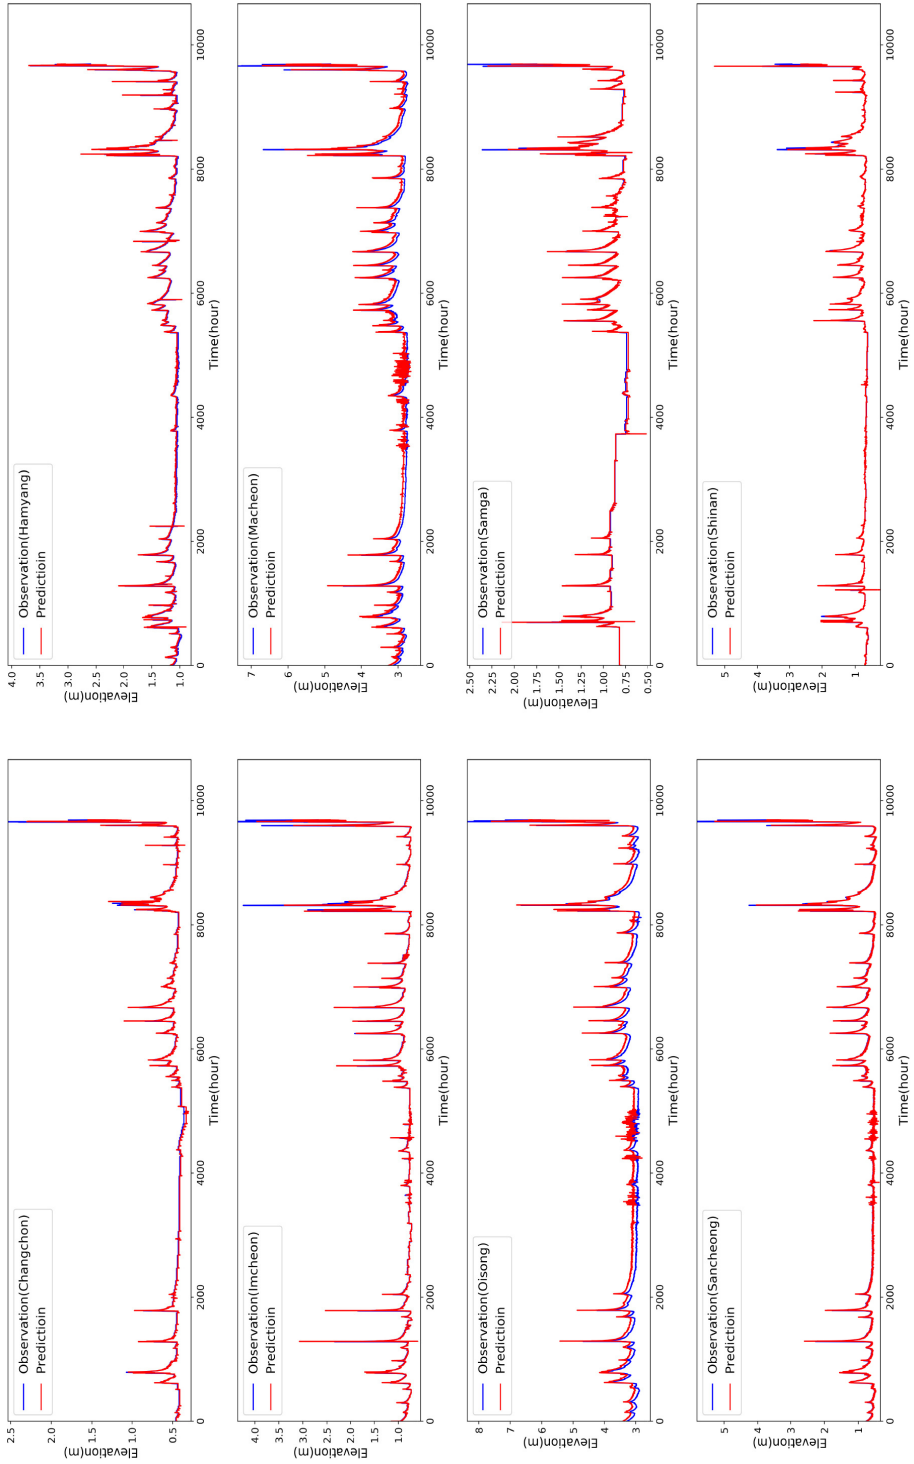
B-3. Comparison of LSTM prediction (3h) vs. measured water elevation data



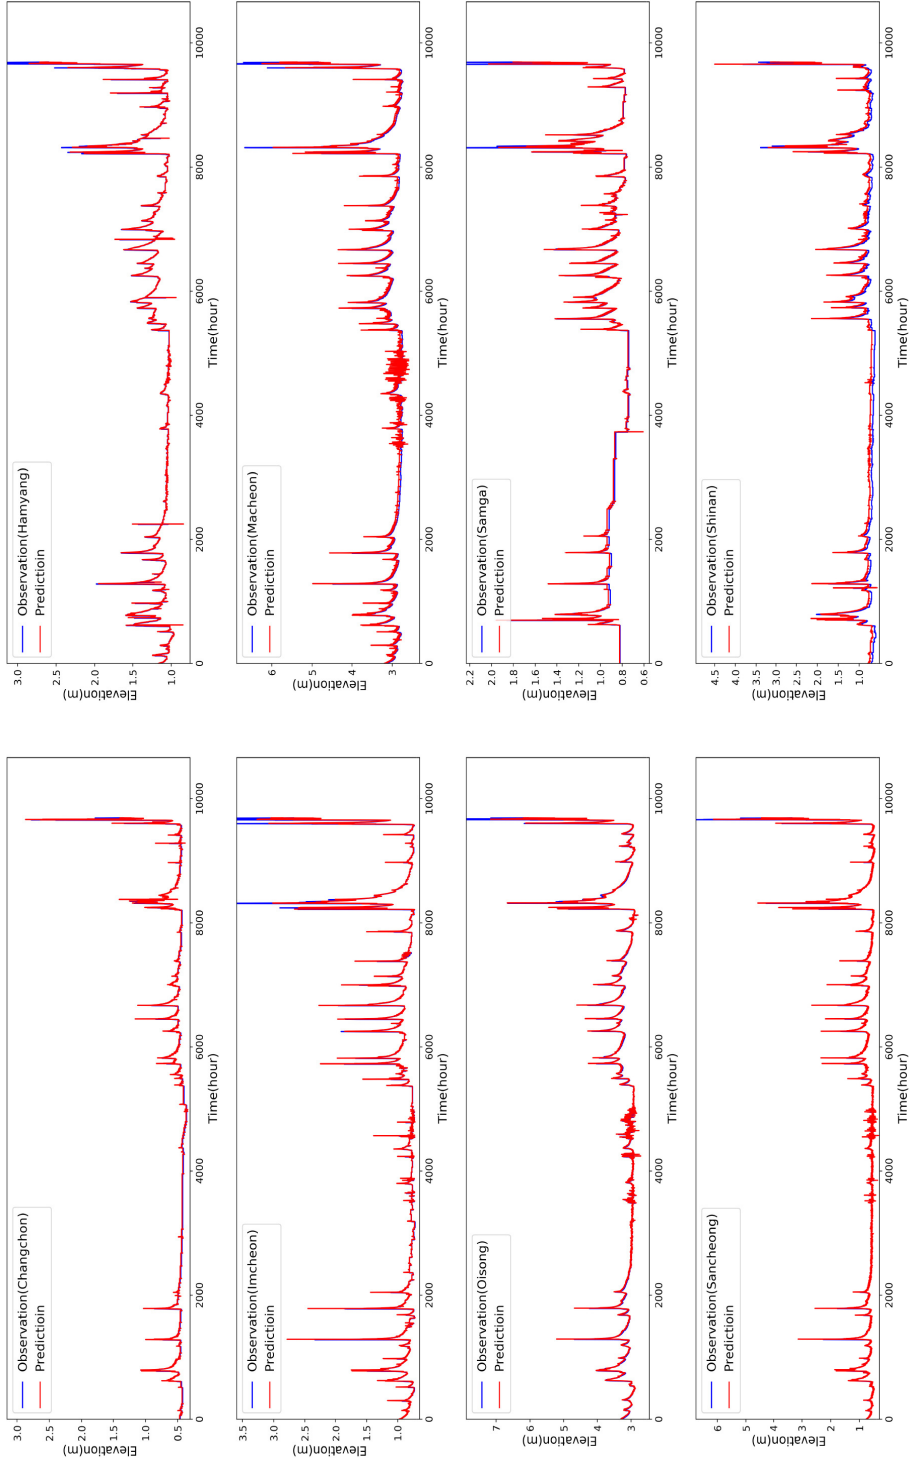
B-4. Comparison of LSTM prediction (4h) vs. measured water elevation data



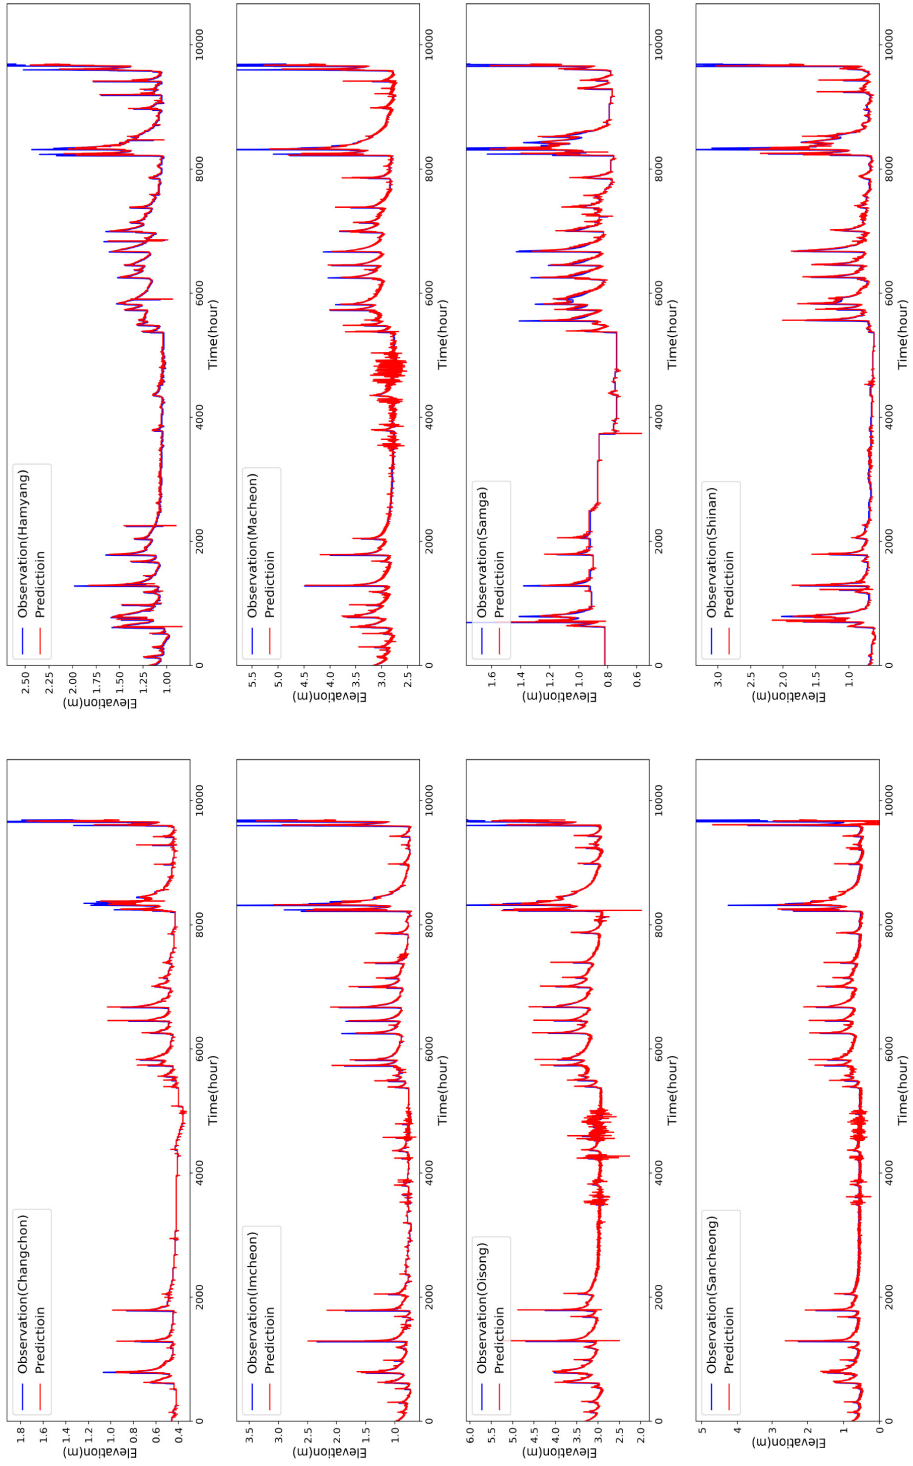
B-5. Comparison of LSTM prediction (5h) vs. measured water elevation data



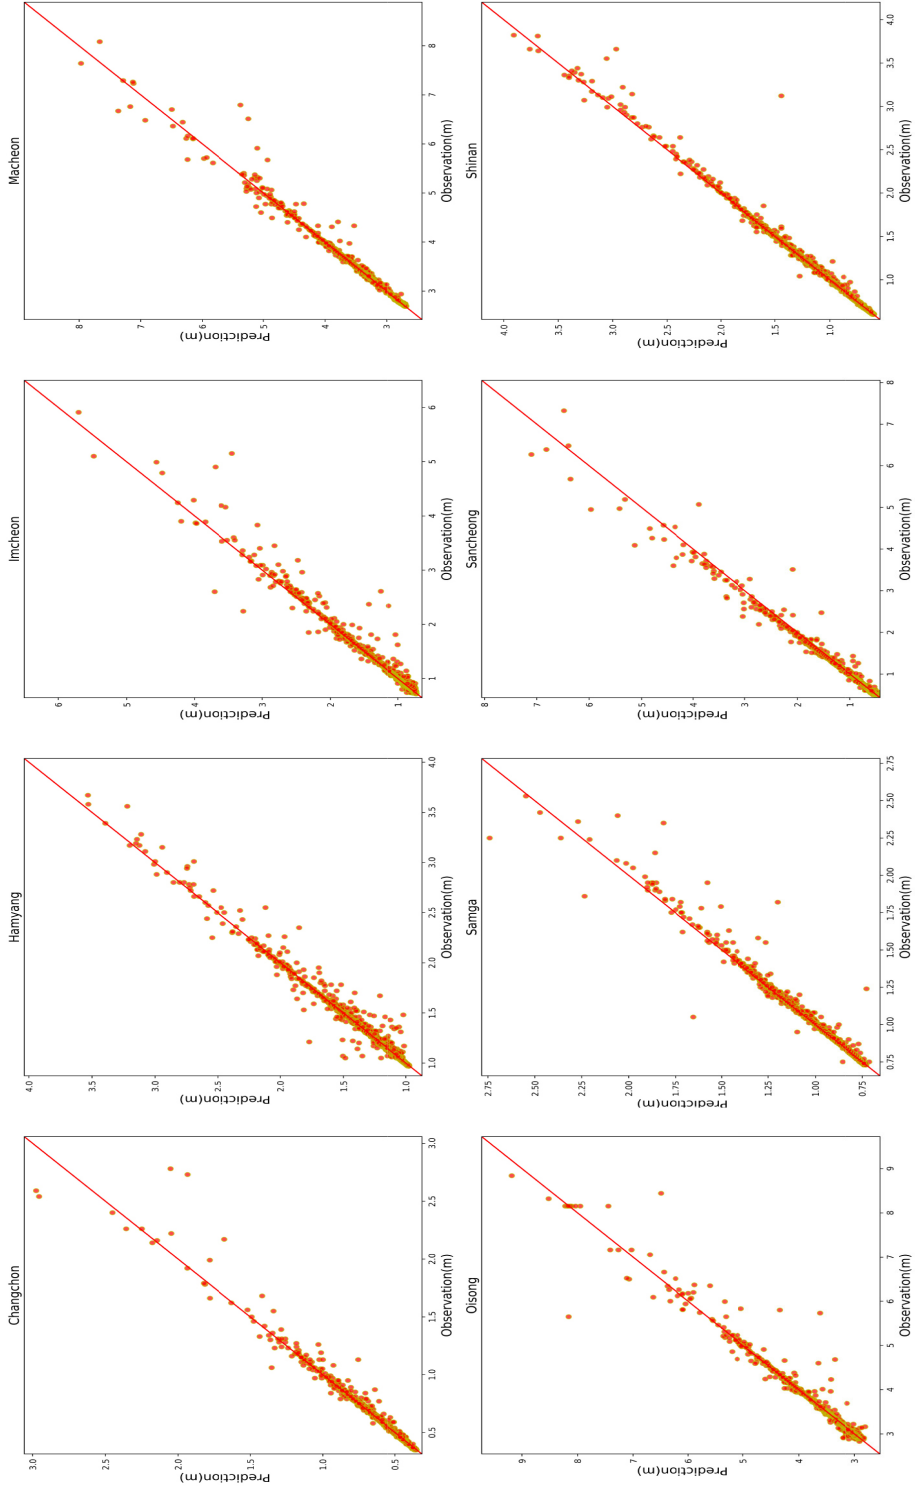
B-6. Comparison of LSTM prediction (6h) vs. measured water elevation data



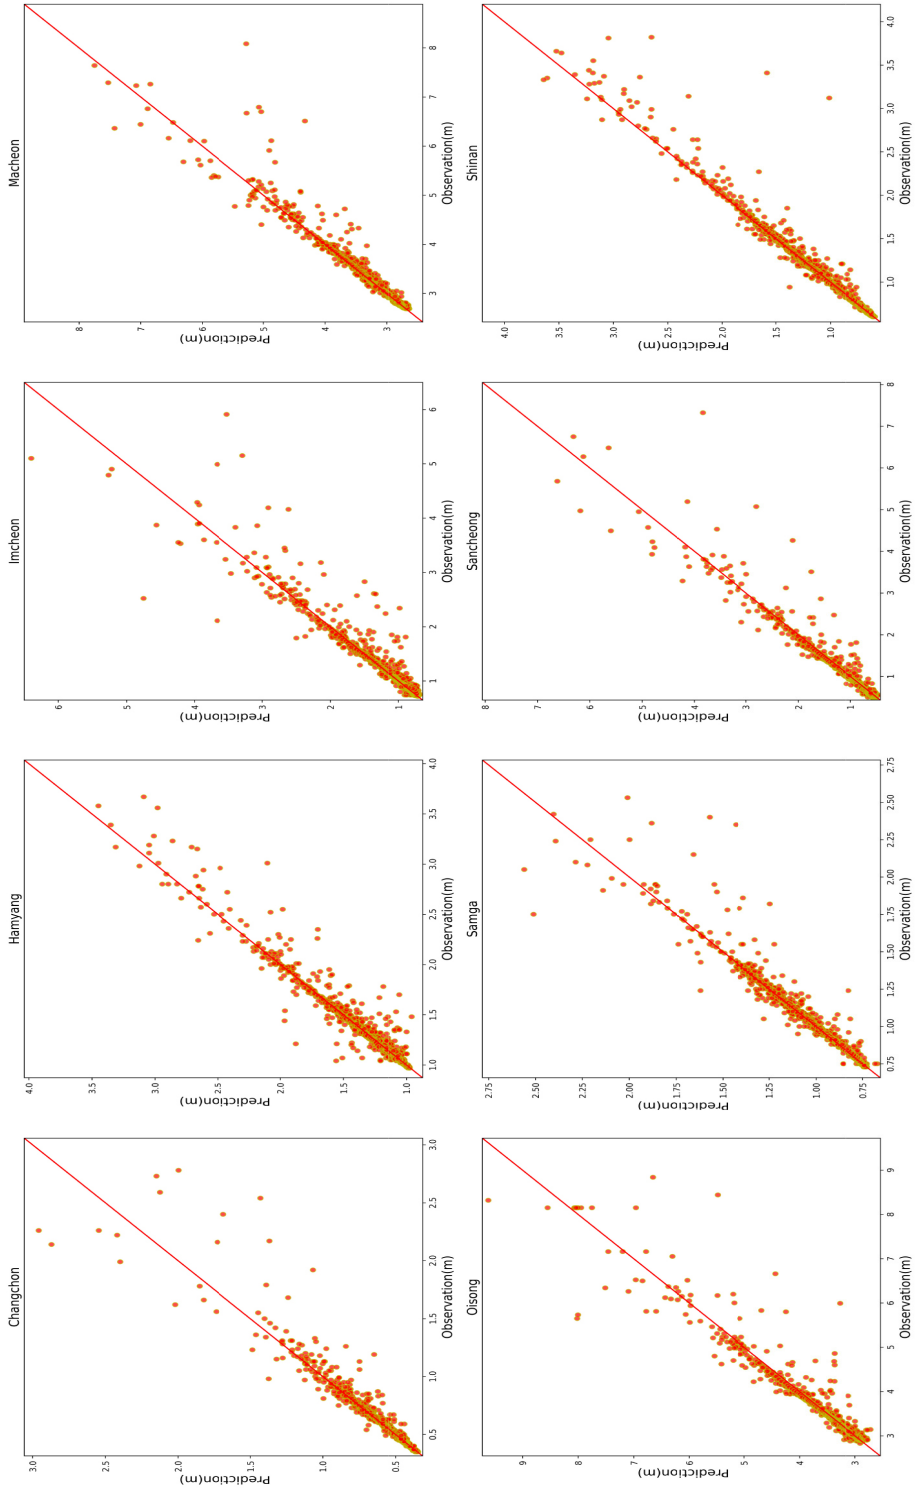
B-7. Comparison of LSTM prediction (12h) vs. measured water elevation data



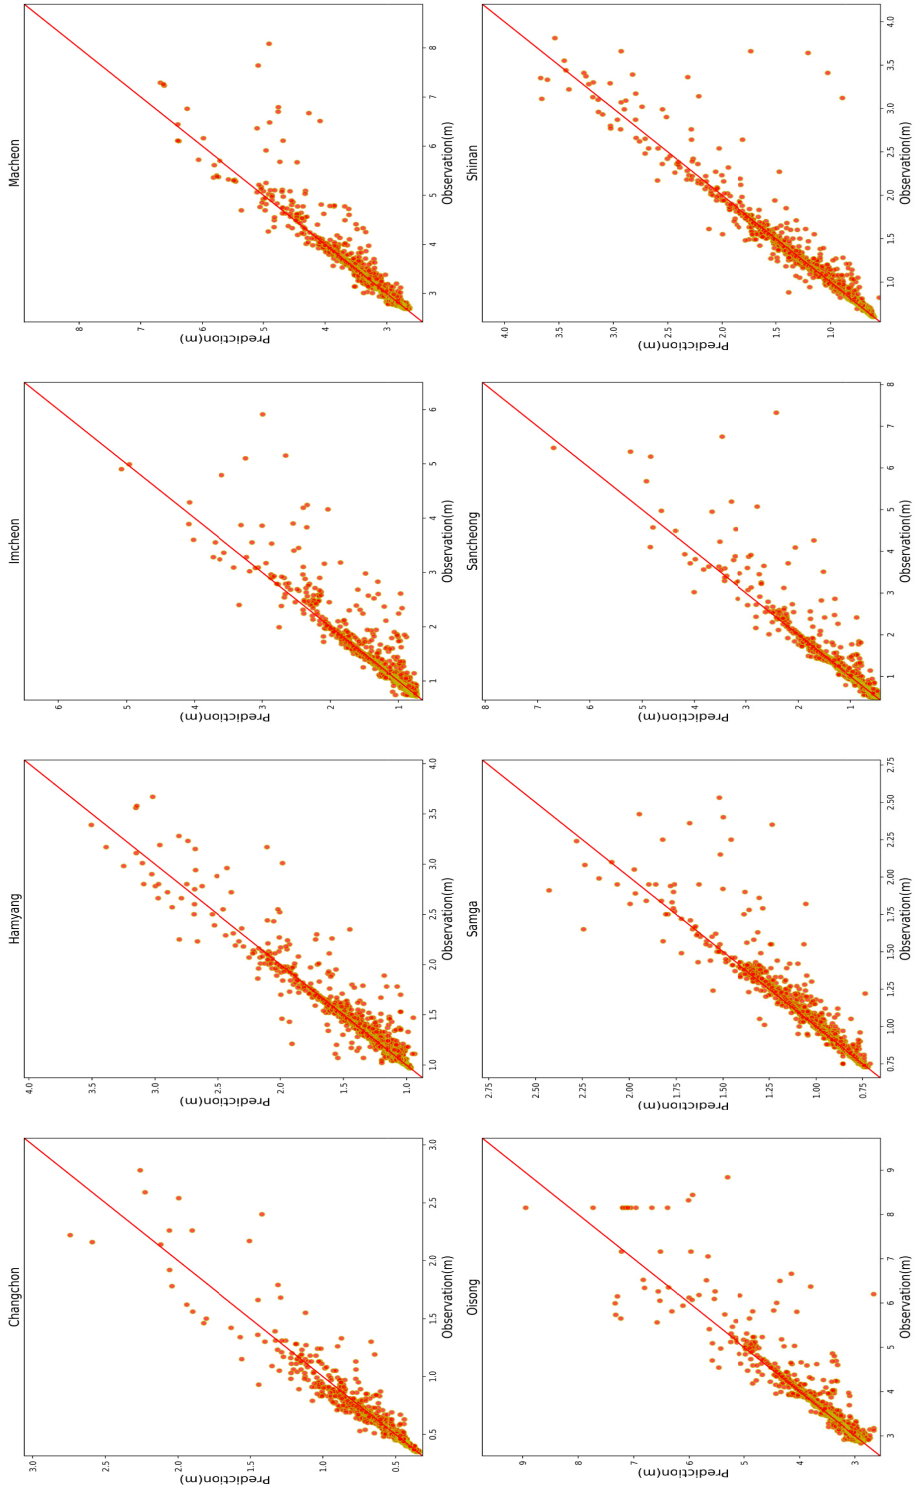
B-8. Comparison of scatter plot of LSTM prediction (1h) vs. measured water elevation data



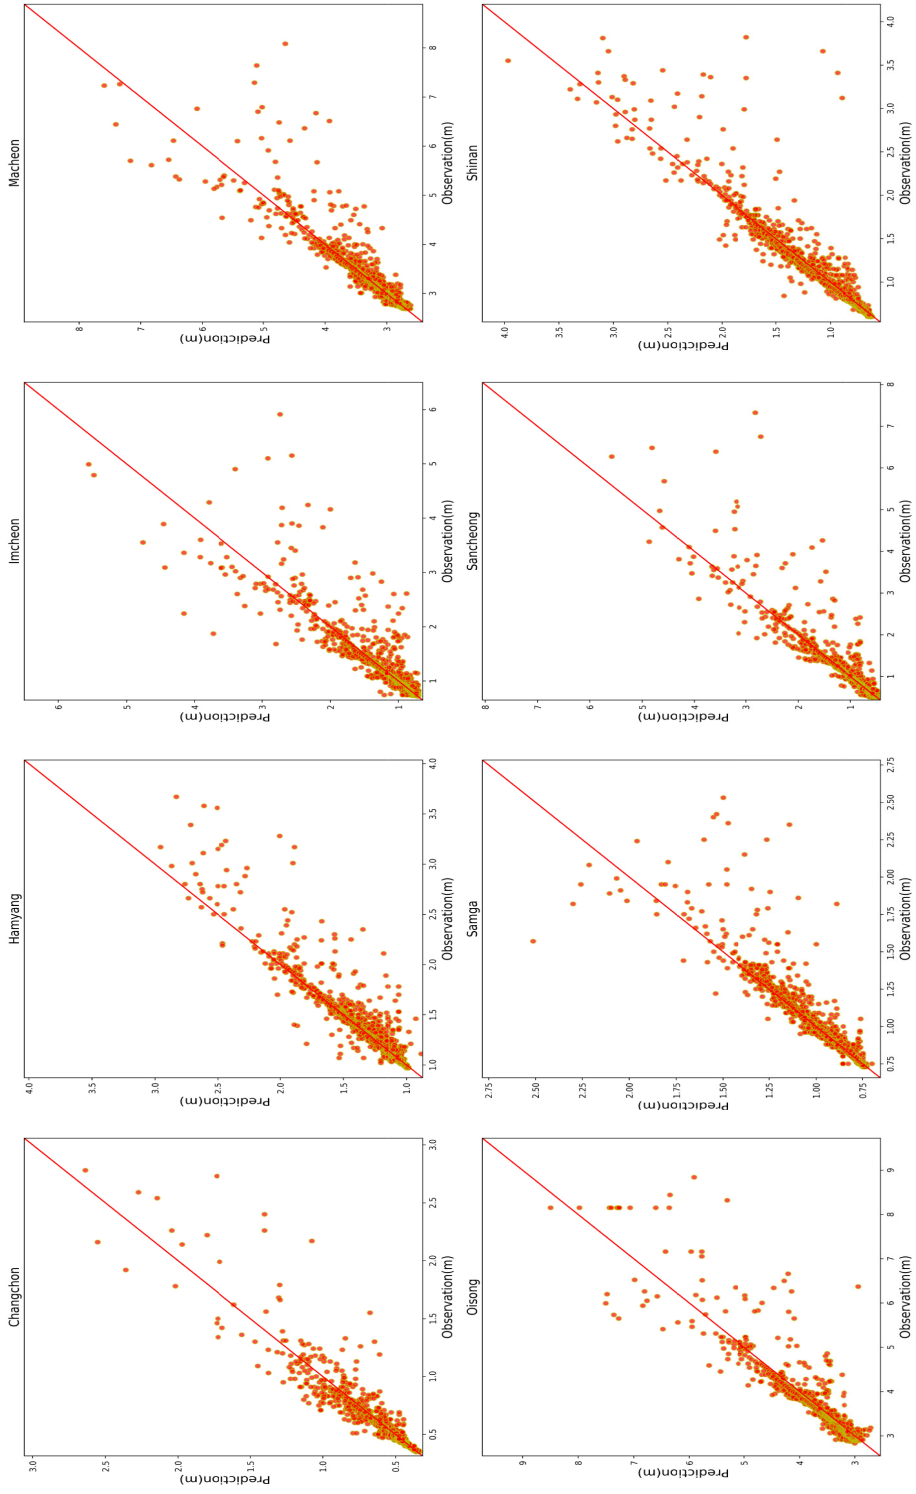
B-9. Comparison of scatter plot of LSTM prediction (2h) vs. measured water elevation data



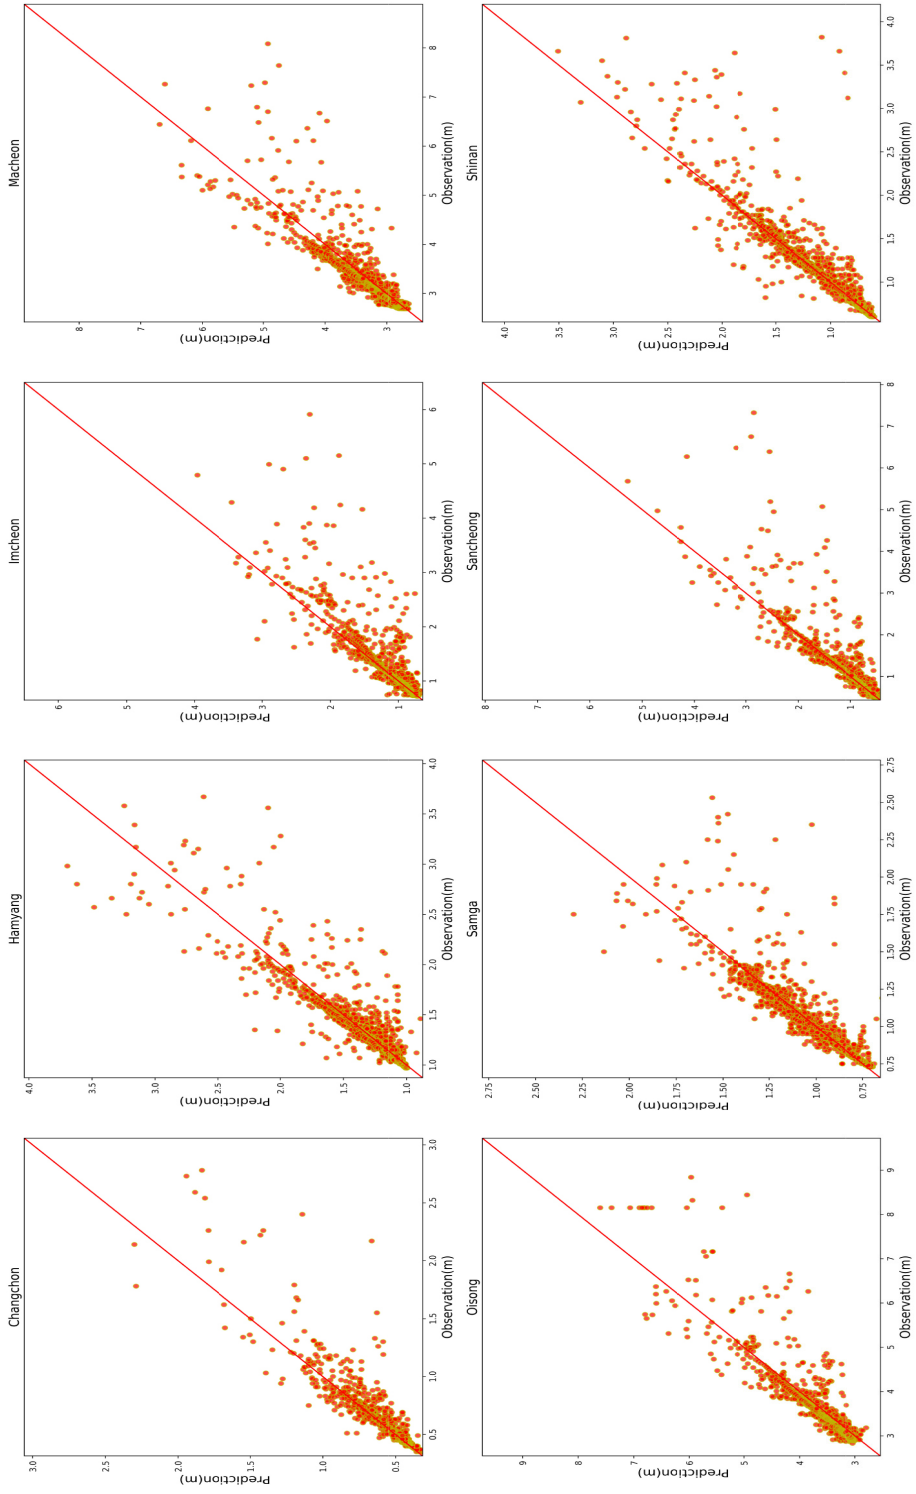
B-10. Comparison of scatter plot of LSTM prediction (3h) vs. measured water elevation data



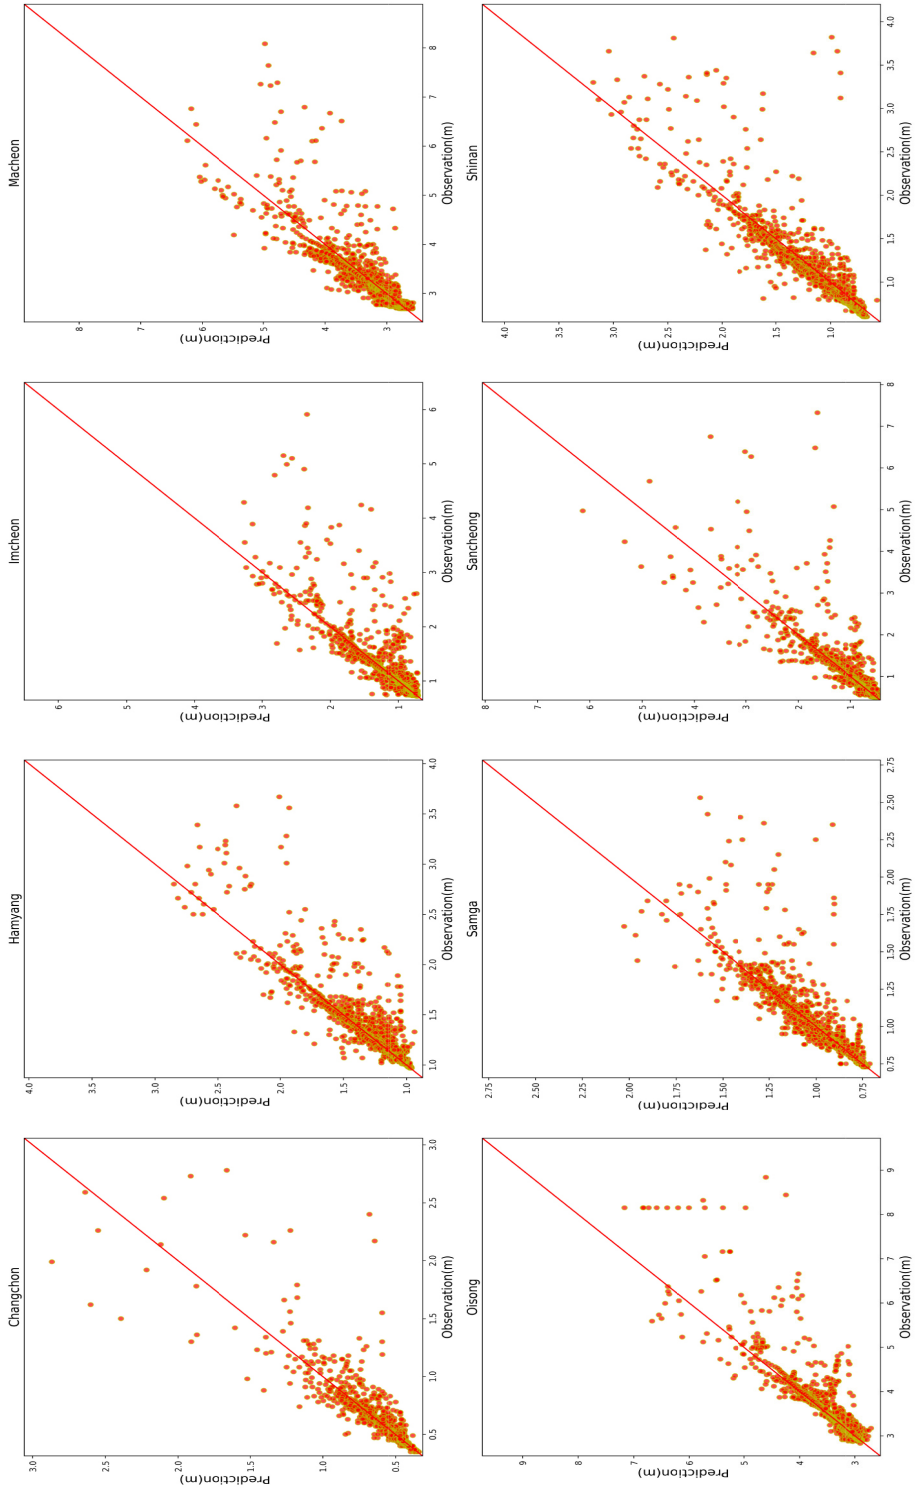
B-11. Comparison of scatter plot of LSTM prediction (4h) vs. measured water elevation data



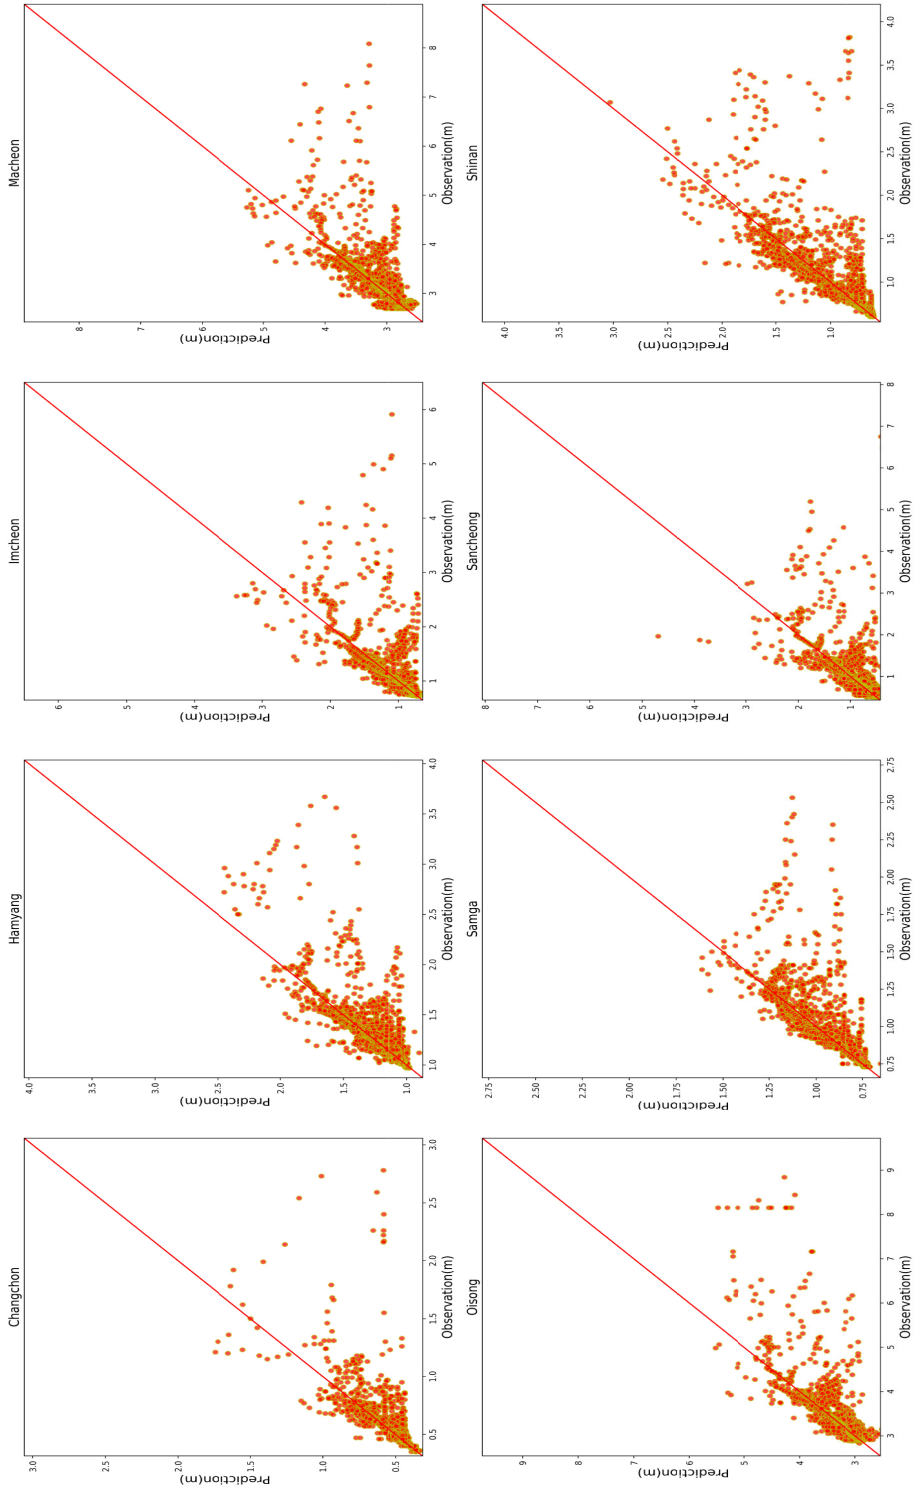
B-12. Comparison of scatter plot of LSTM prediction (5h) vs. measured water elevation data



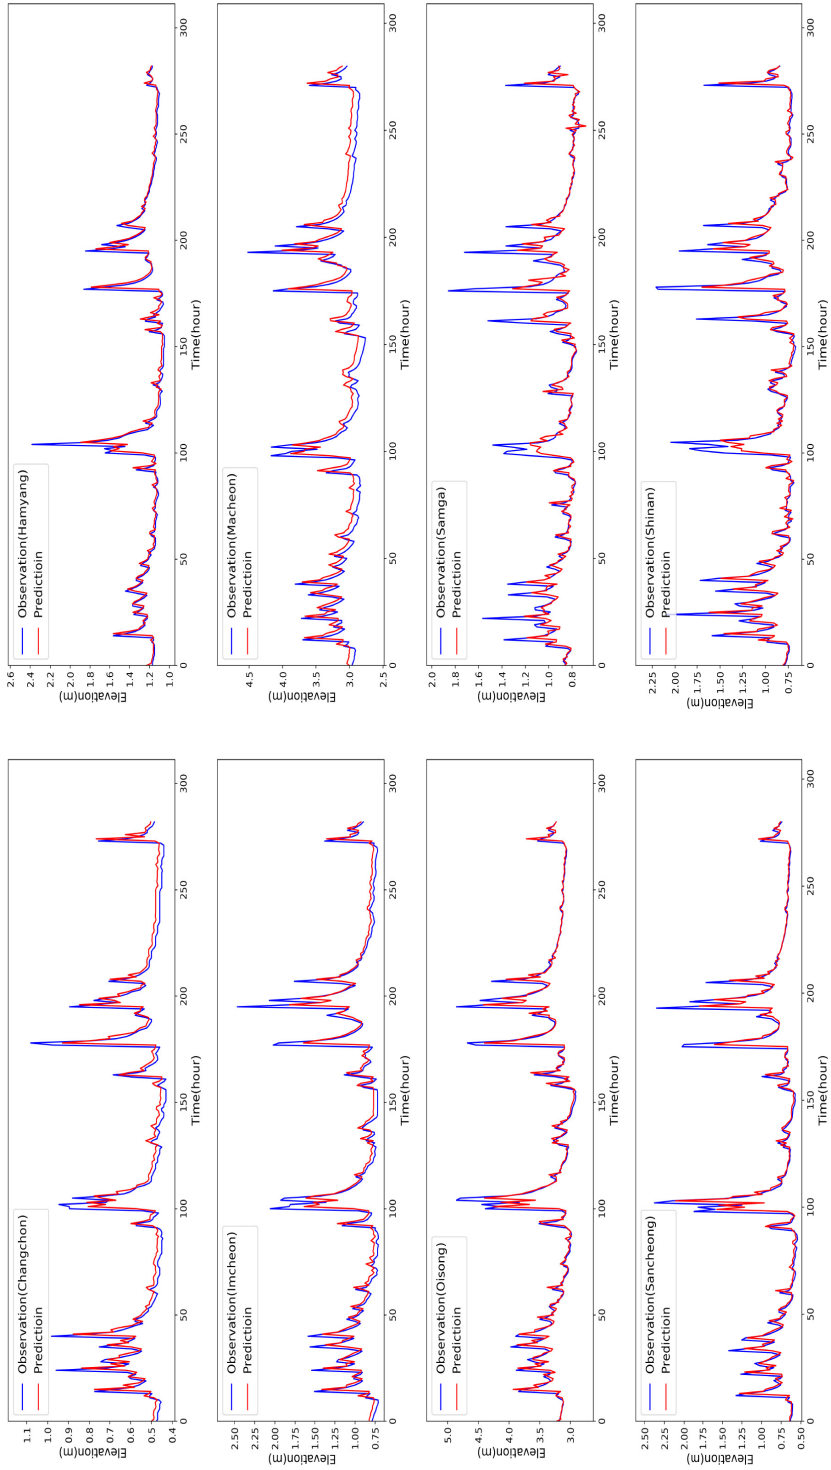
B-13. Comparison of scatter plot of LSTM prediction (6h) vs. measured water elevation data



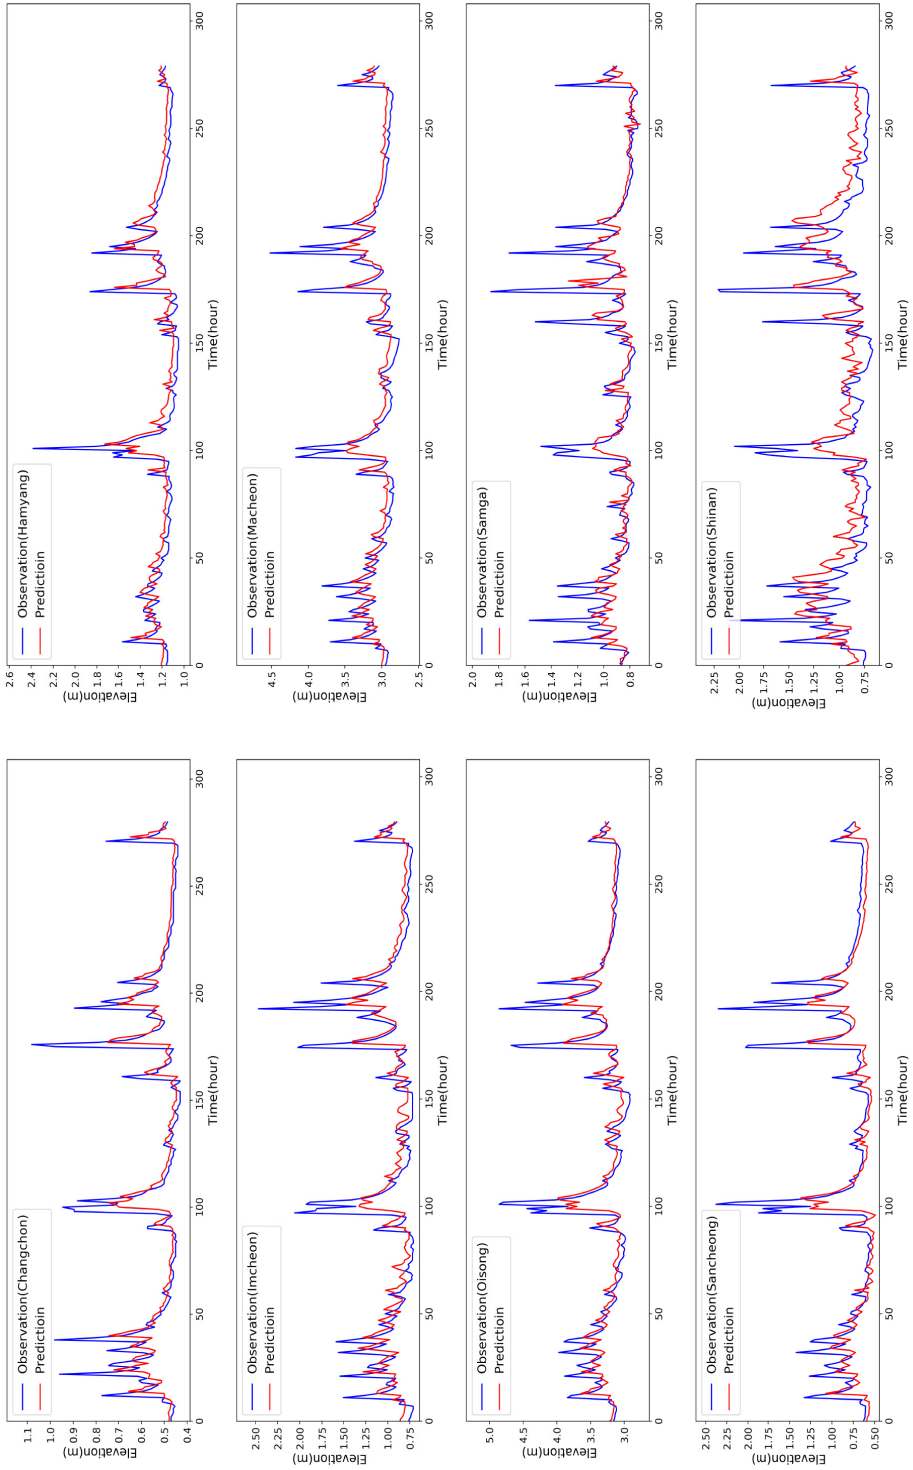
B-14. Comparison of scatter plot of LSTM prediction (12h) vs. measured water elevation data



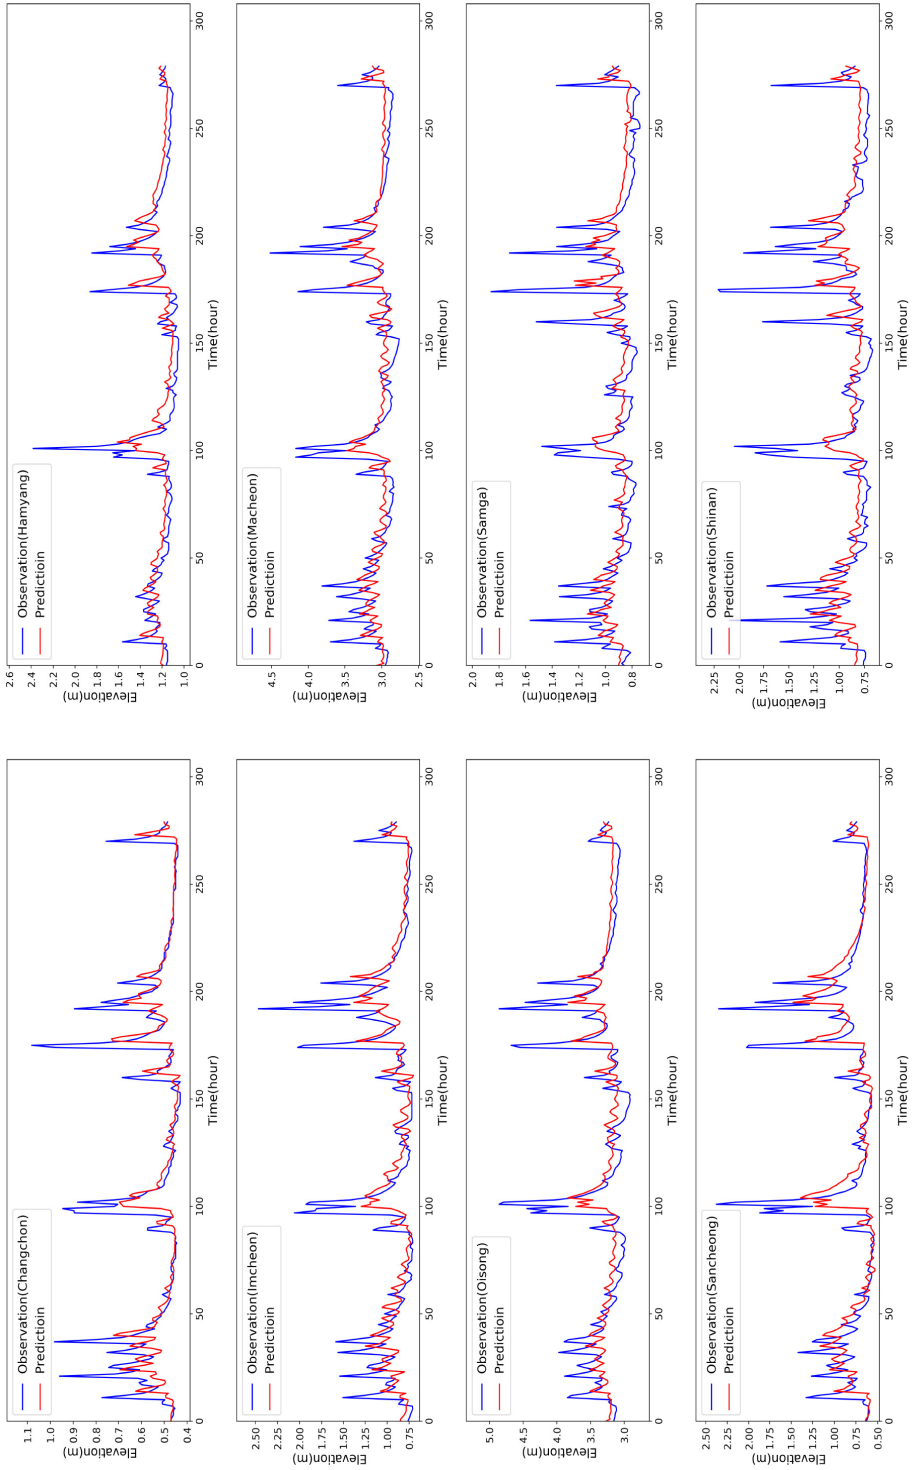
C-1-1. Comparison of LSTM prediction using daily water elevation (1 day) vs. measured water elevation data



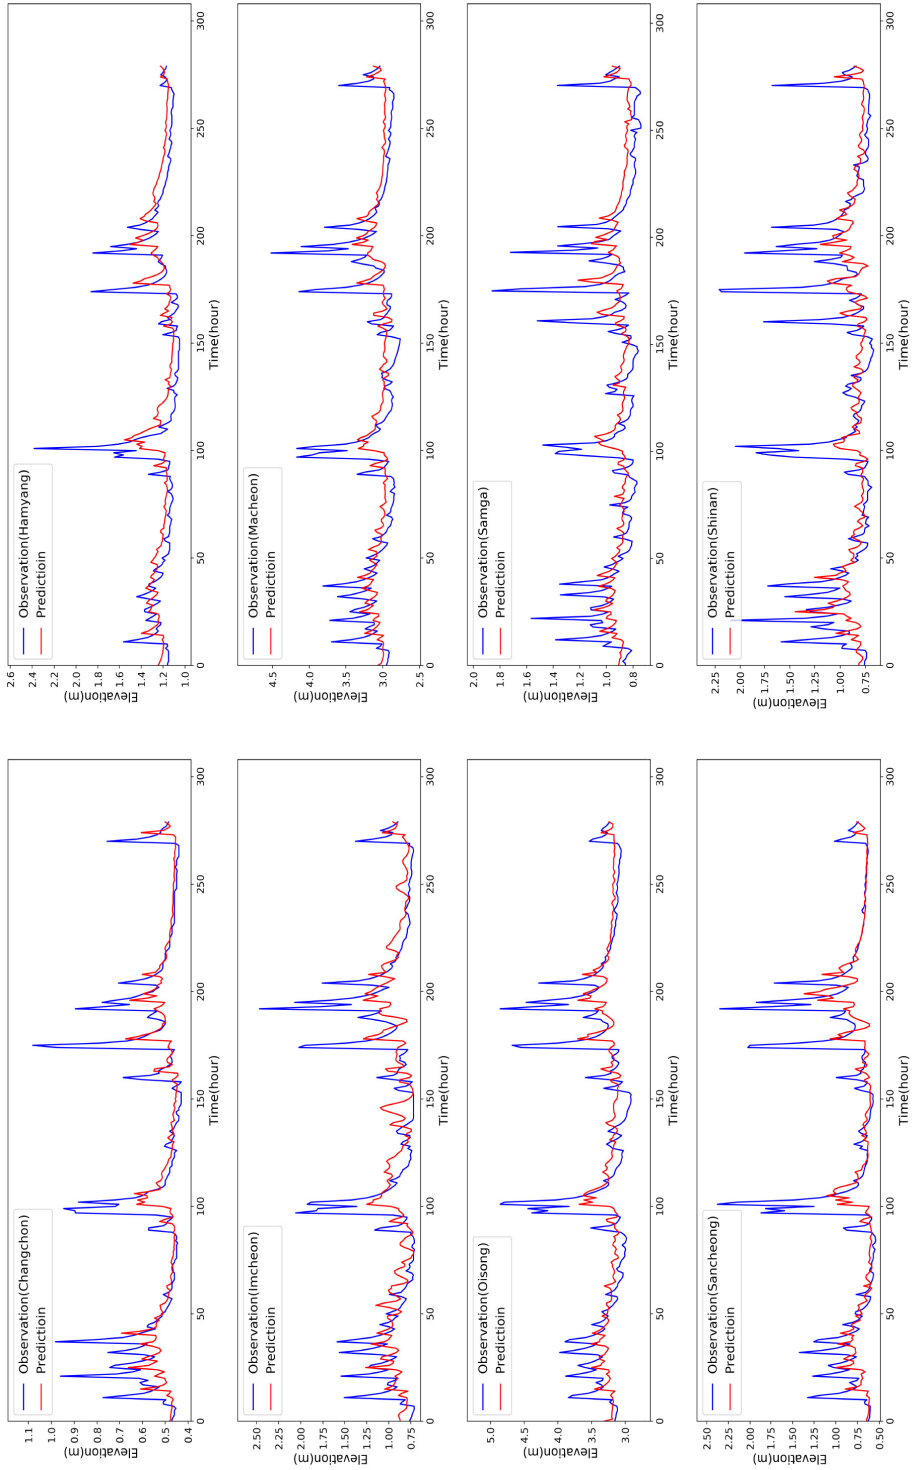
C-1-2. Comparison of LSTM prediction using daily water elevation (2 day) vs. measured water elevation data



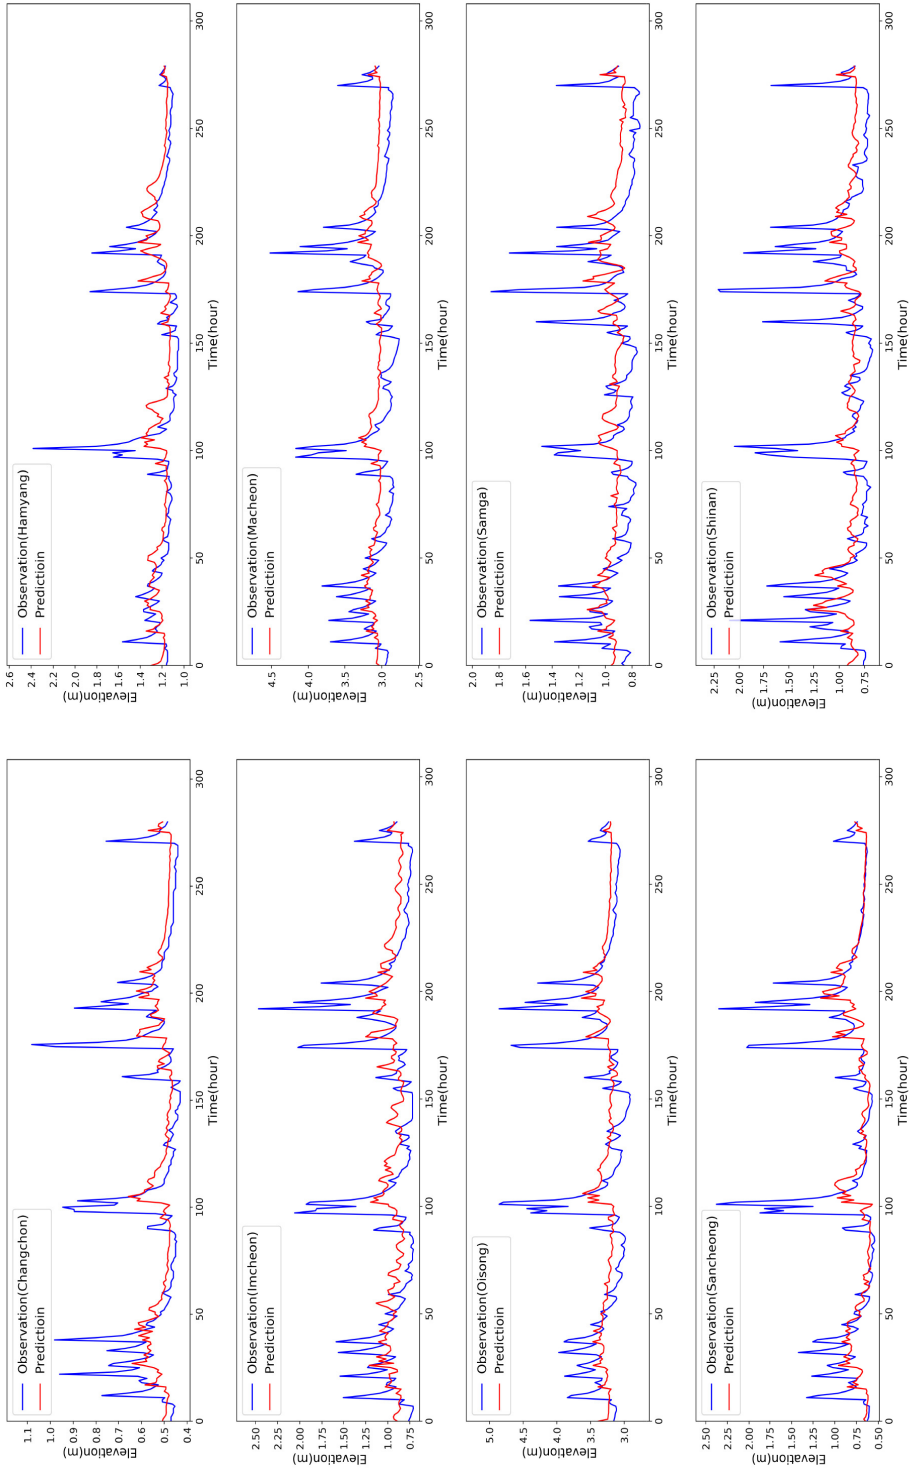
C-1-3. Comparison of LSTM prediction using daily water elevation (3 day) vs. measured water elevation data



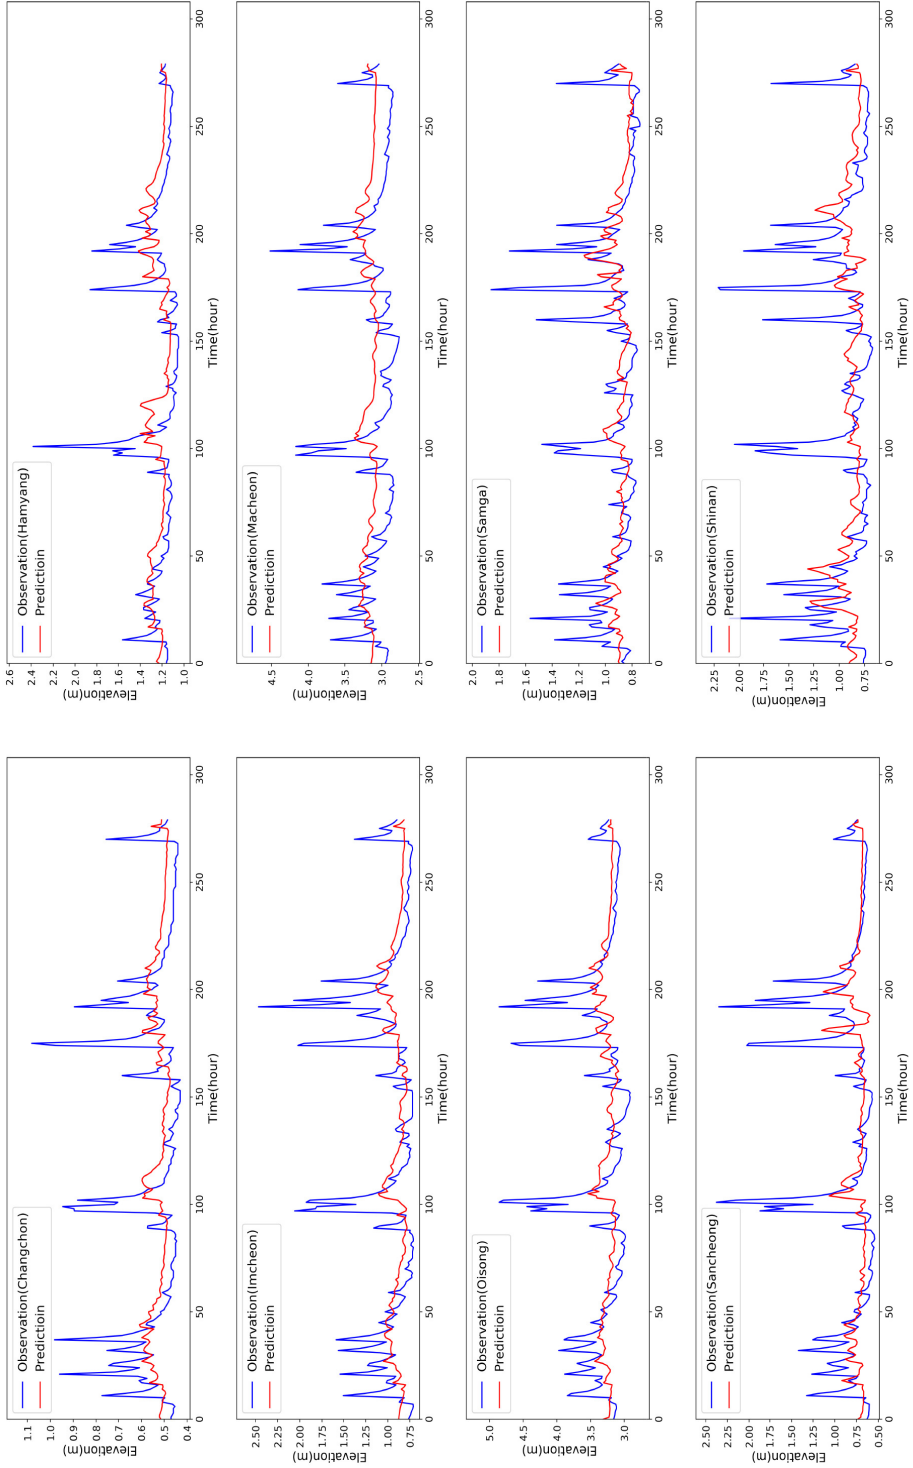
C-1-4. Comparison of LSTM prediction using daily water elevation (4 day) vs. measured water elevation data



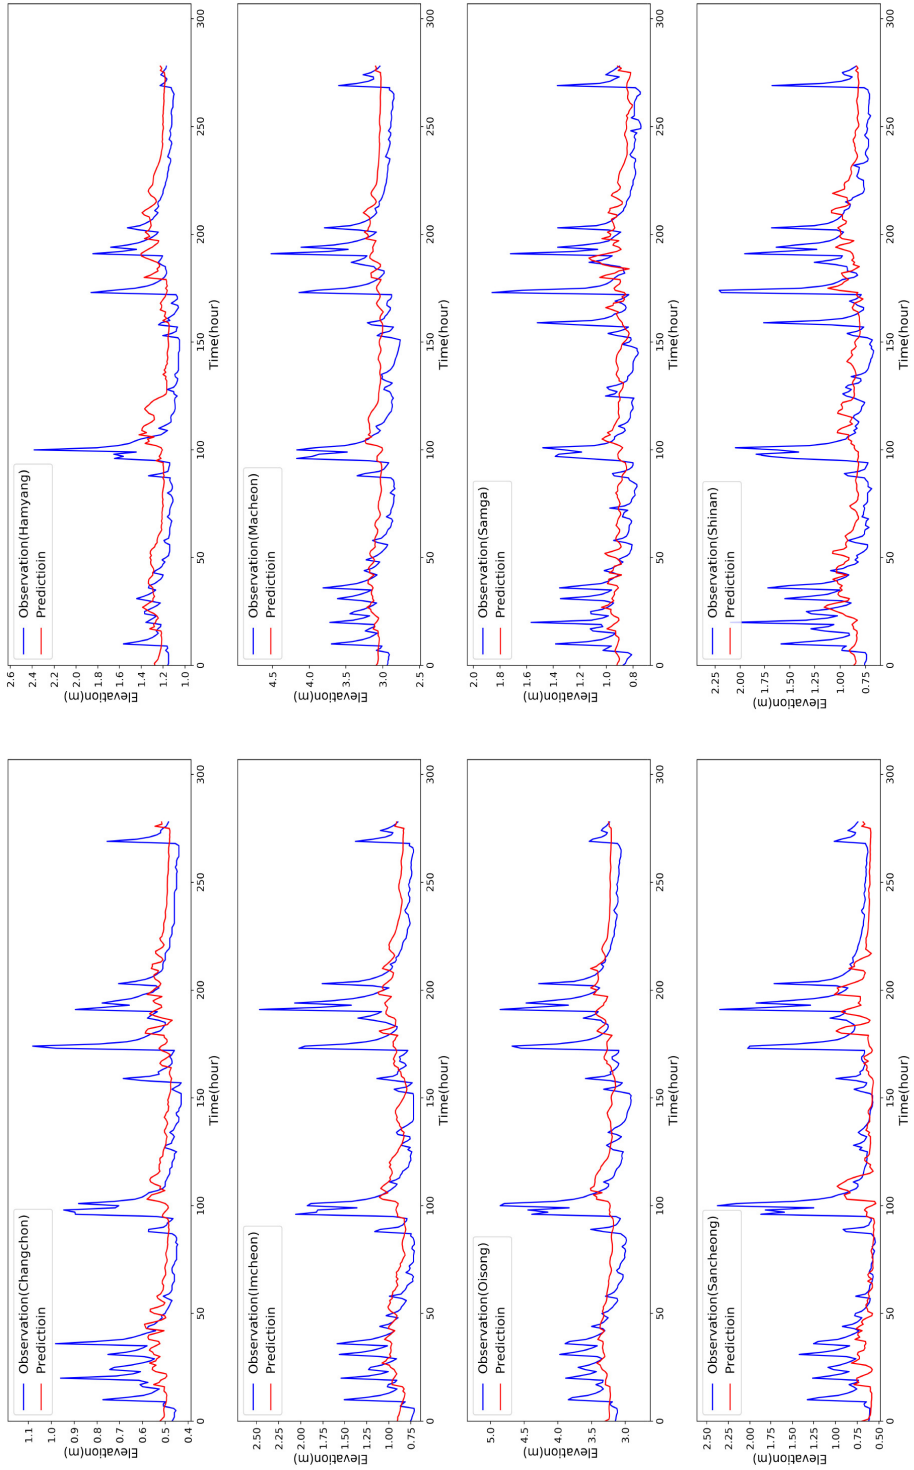
C-1-5. Comparison of LSTM prediction using daily water elevation (5 day) vs. measured water elevation data



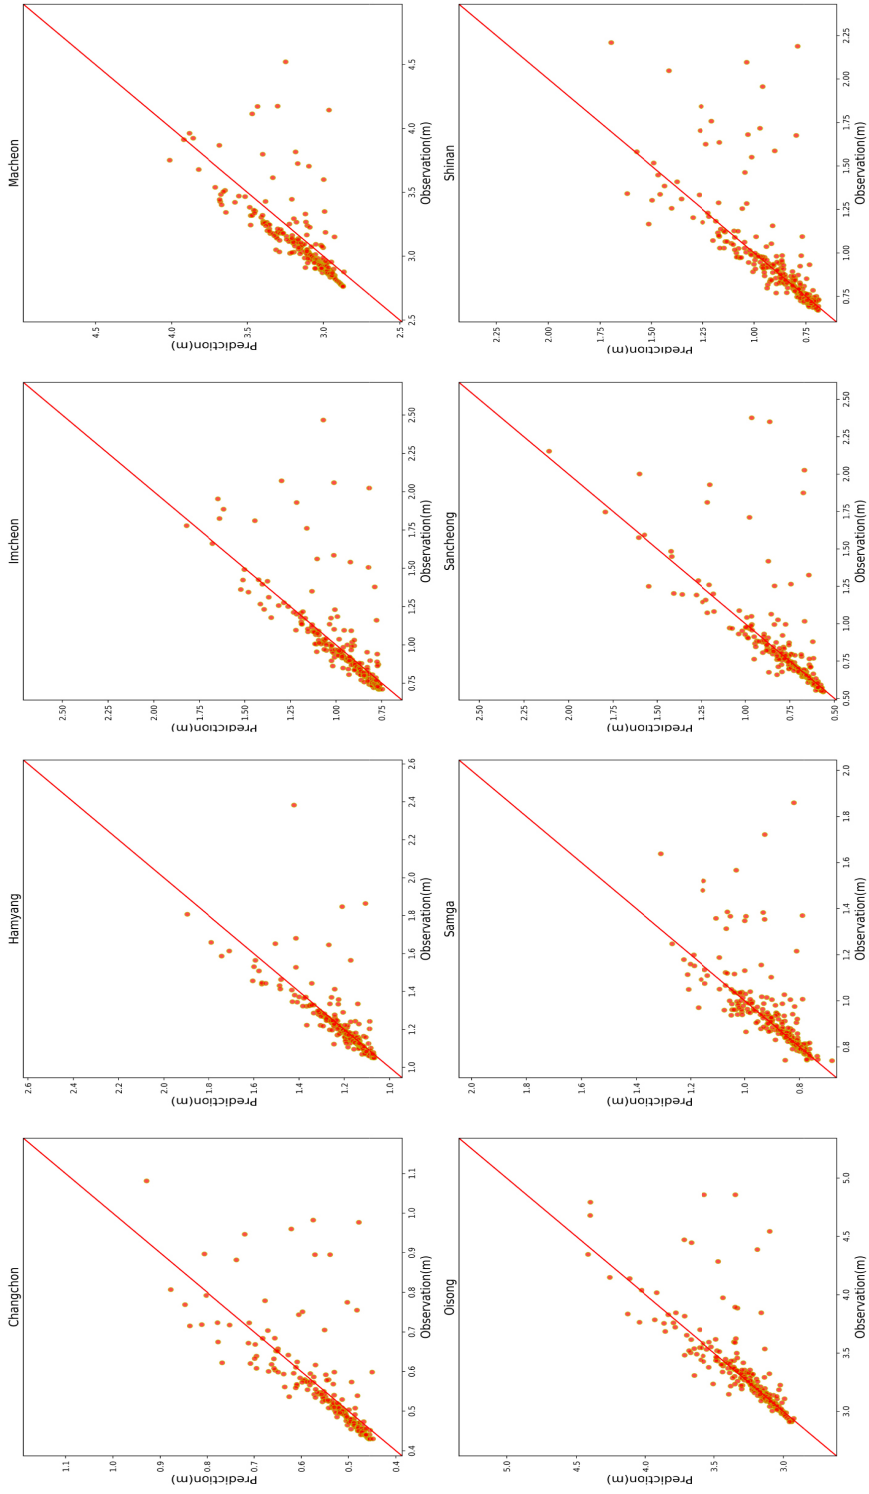
C-1-6. Comparison of LSTM prediction using daily water elevation (6 day) vs. measured water elevation data



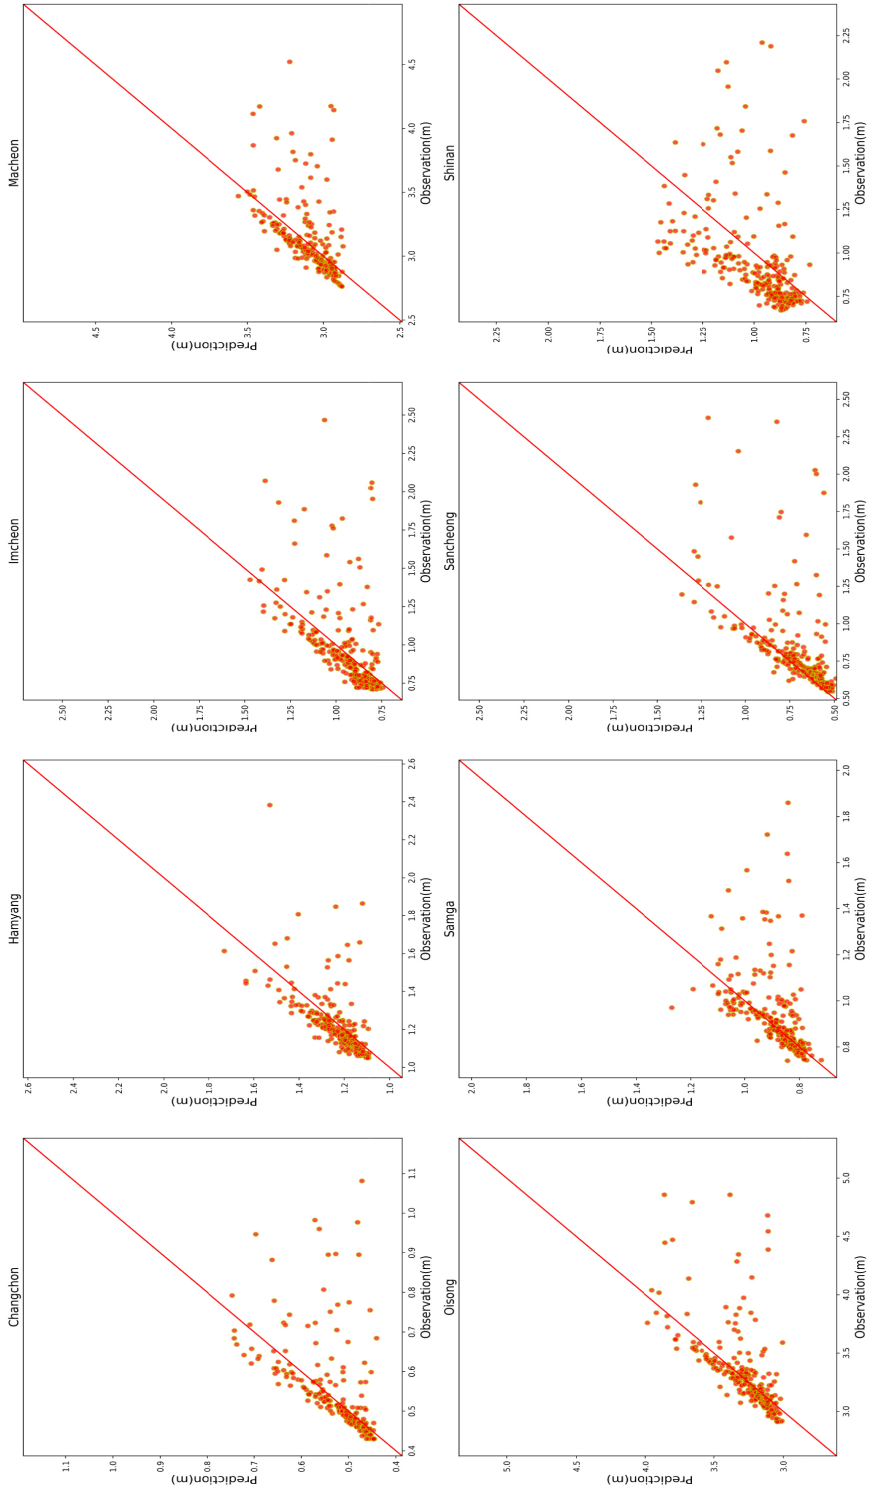
C-1-7. Comparison of LSTM prediction using daily water elevation (7 day) vs. measured water elevation data



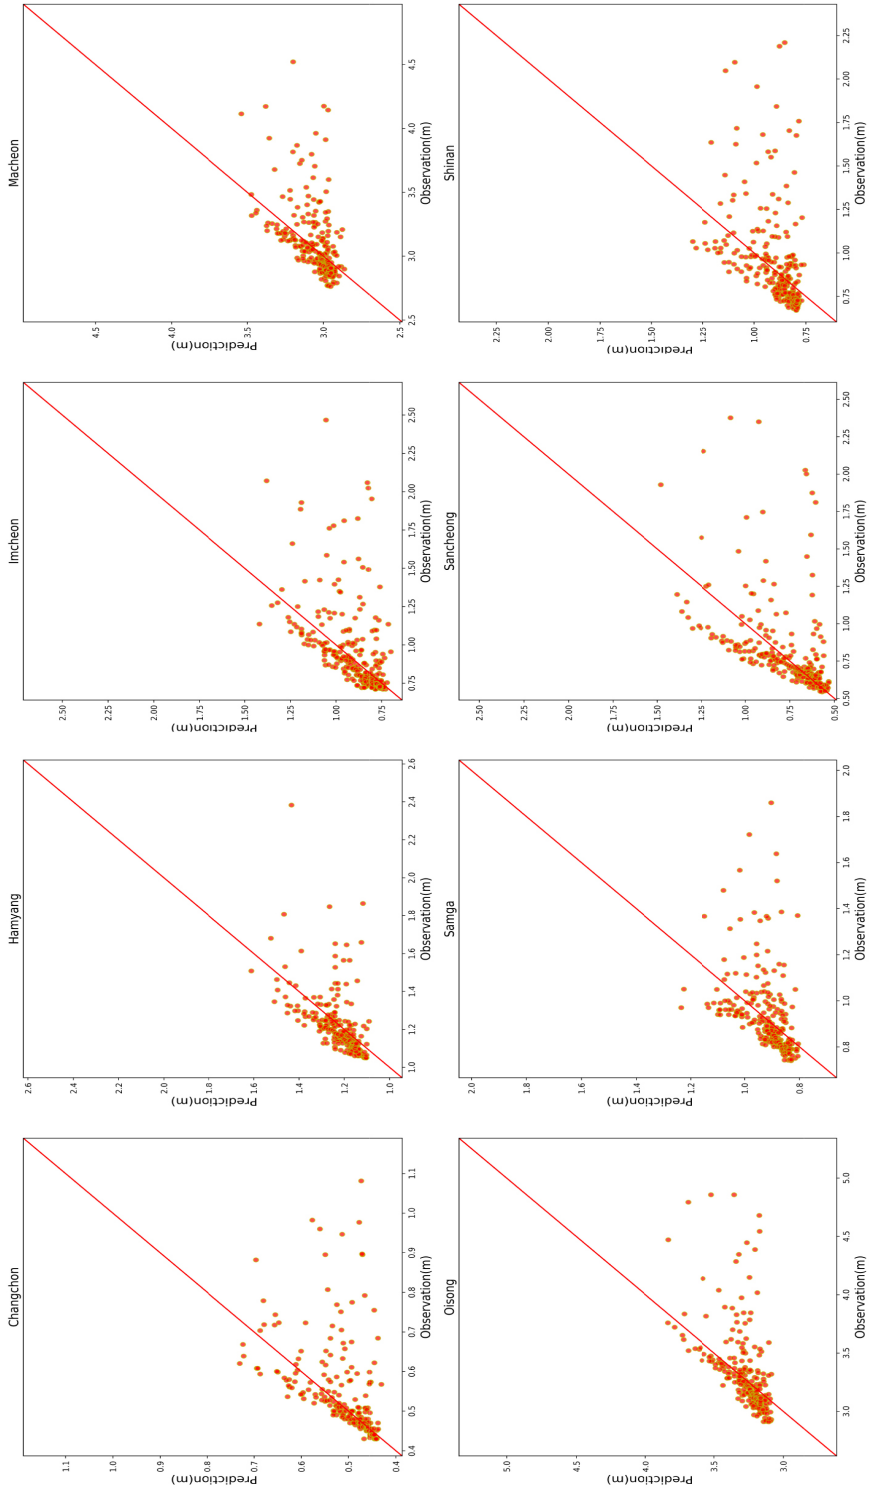
C-1-8. Comparison of scatter plot of LSTM prediction using daily water elevation (1 day) vs. measured water elevation data



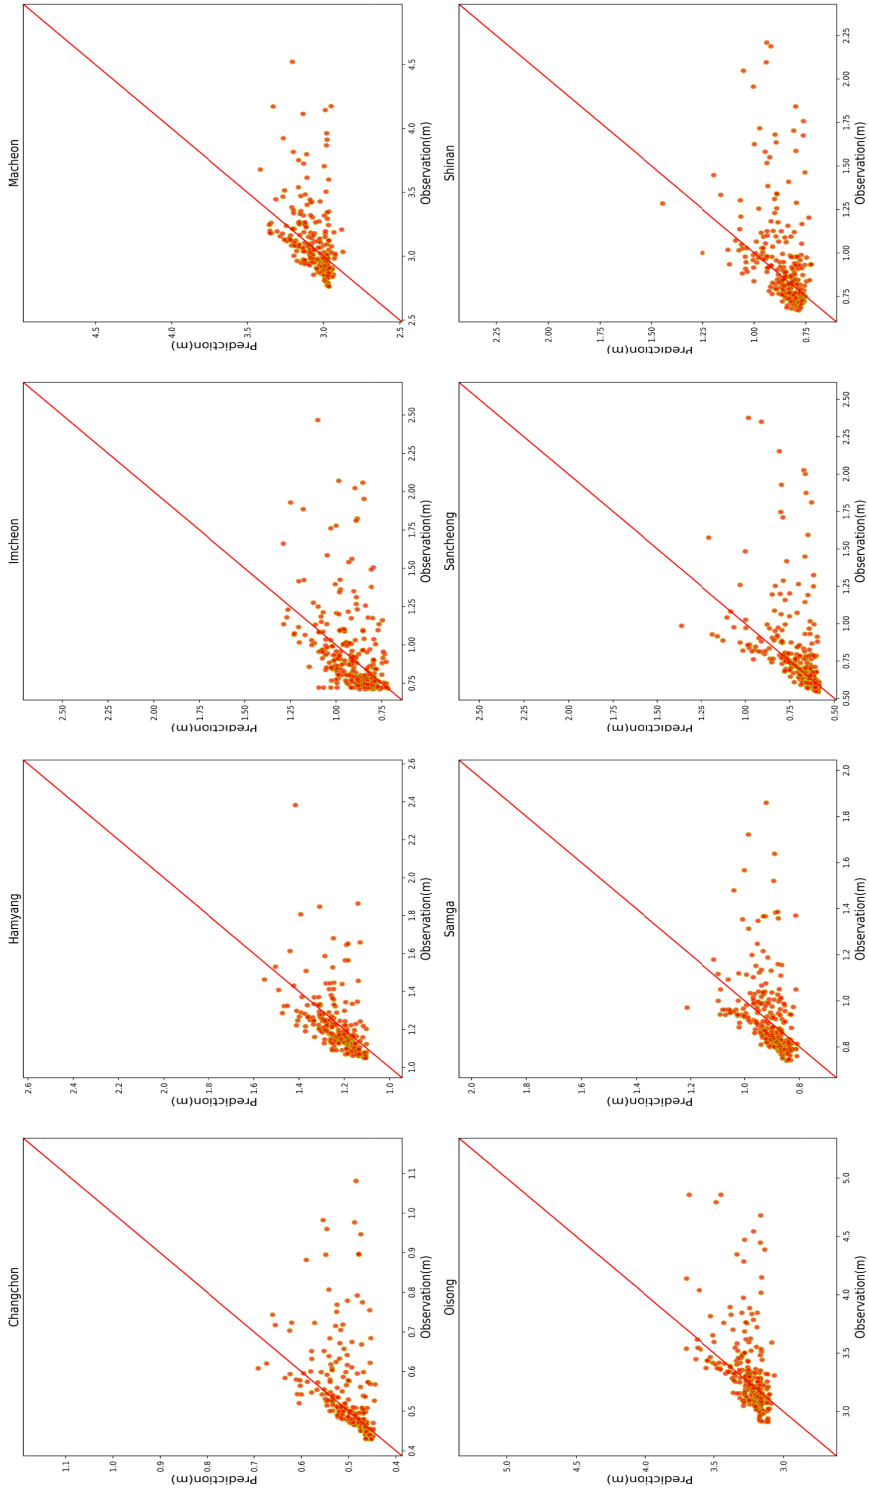
C-1-9. Comparison of scatter plot of LSTM prediction using daily water elevation (2 day) vs. measured water elevation data



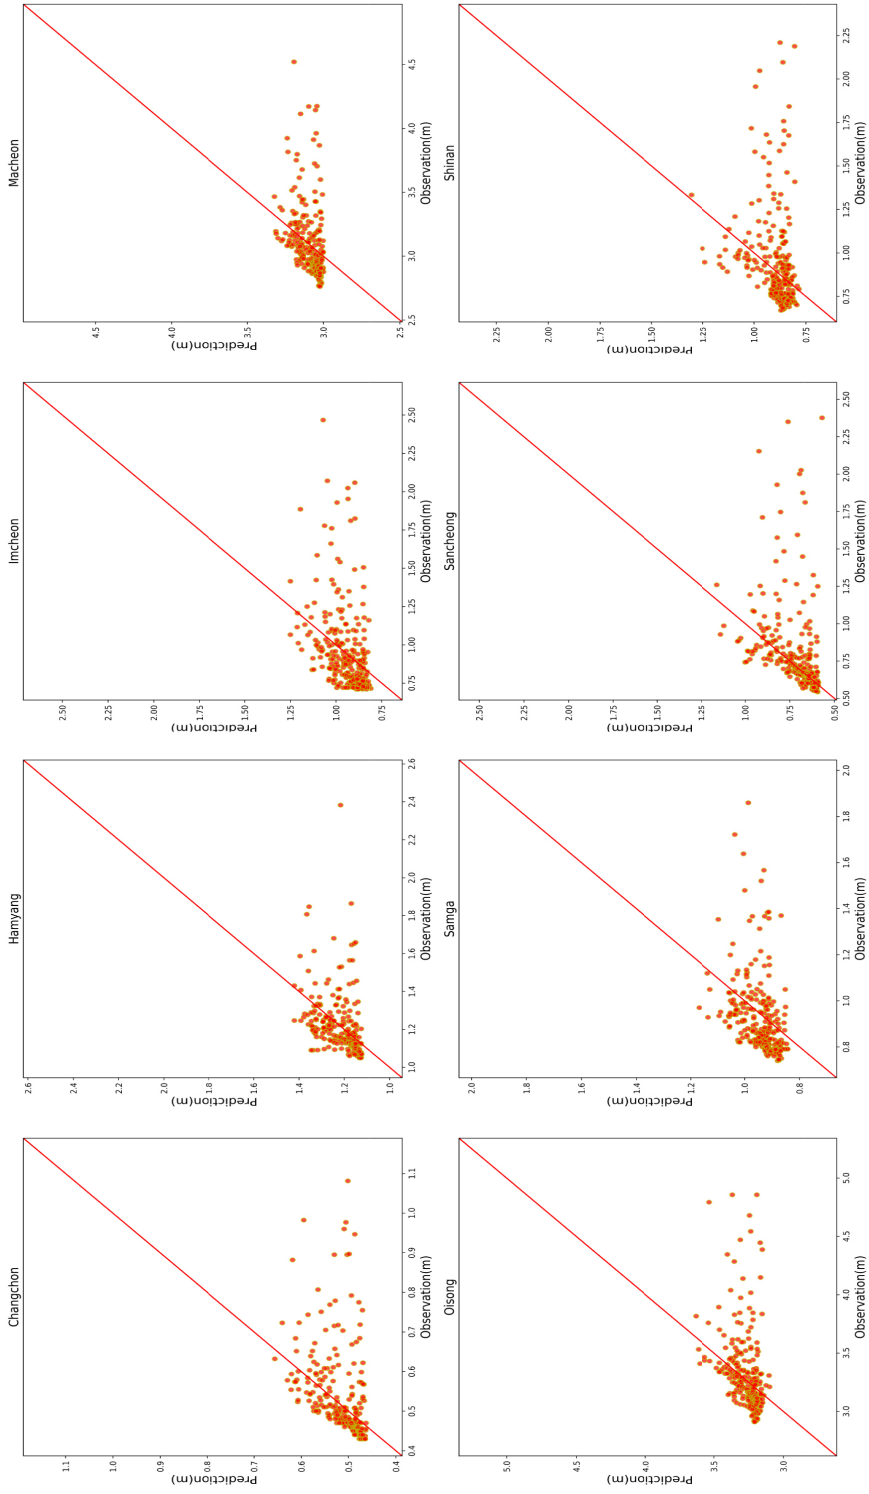
C-1-10. Comparison of scatter plot of LSTM prediction using daily water elevation (3 day) vs. measured water elevation data



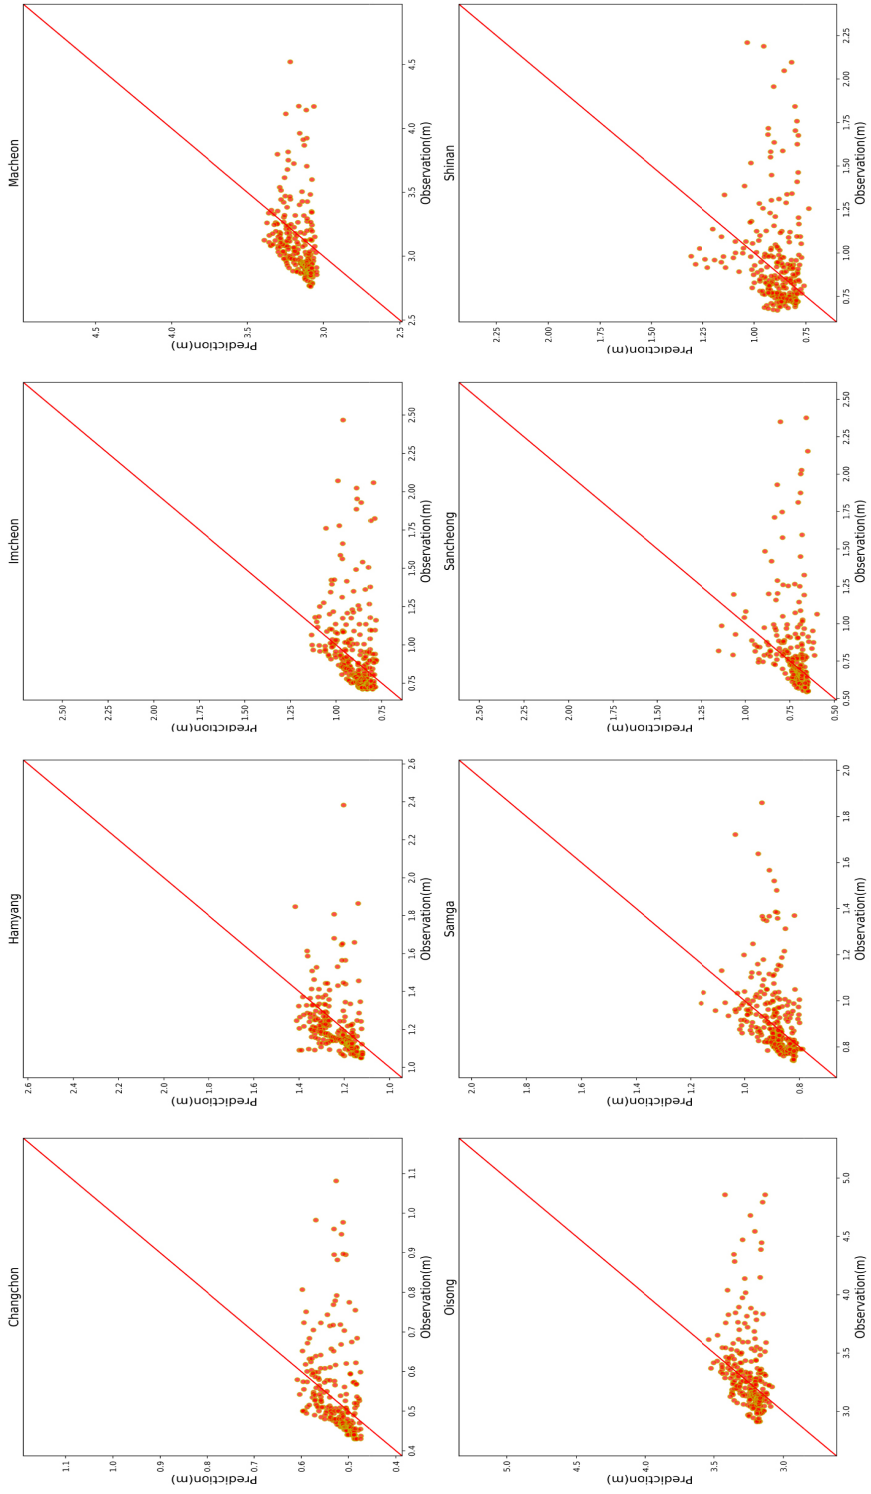
C-1-11. Comparison of scatter plot of LSTM prediction using daily water elevation (4 day) vs. measured water elevation data



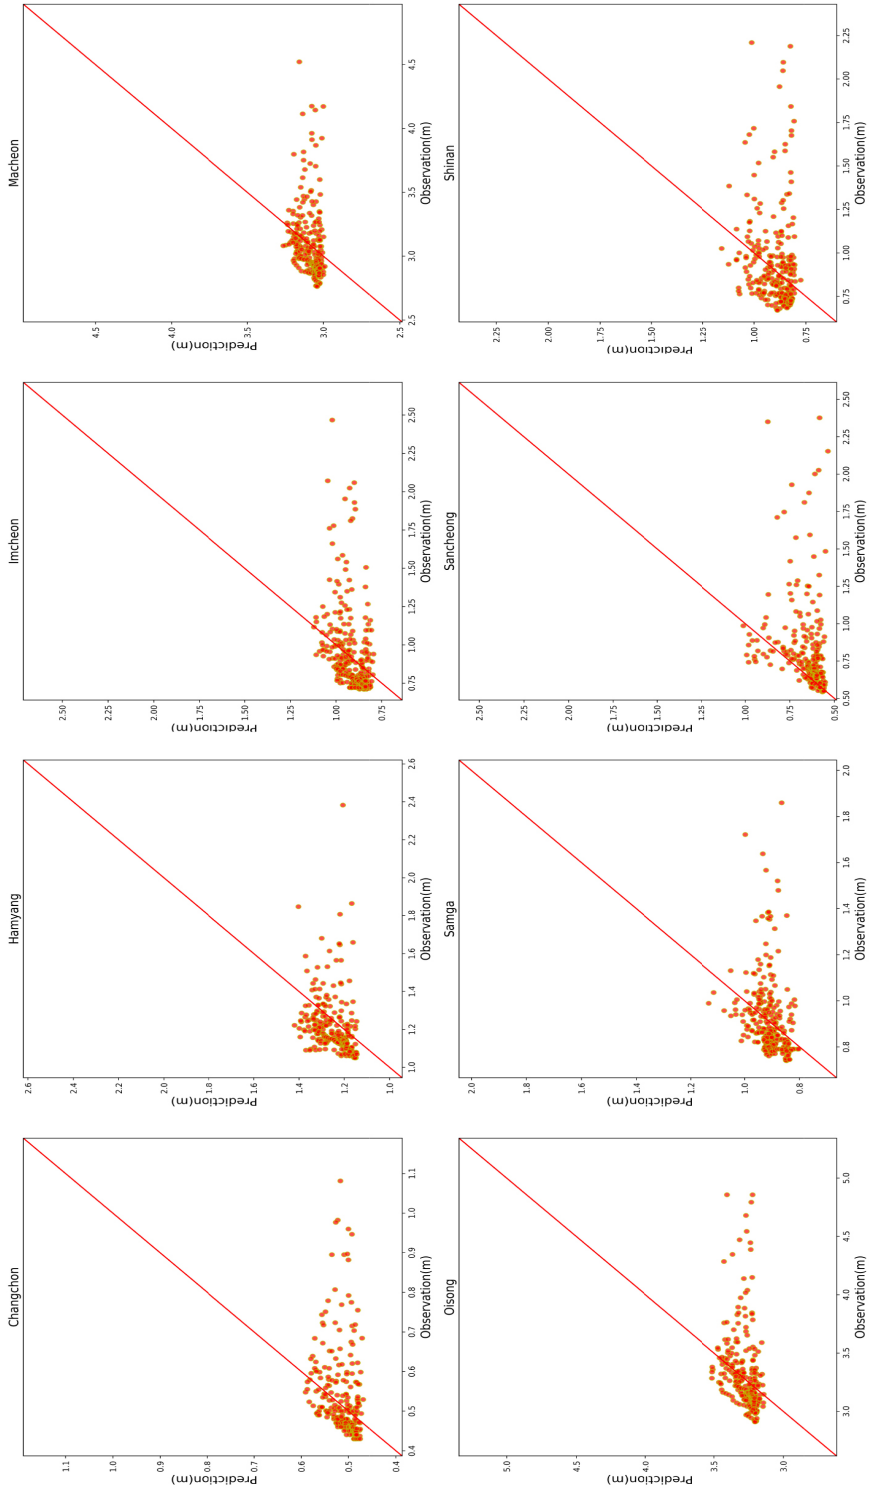
C-1-12. Comparison of scatter plot of LSTM prediction using daily water elevation (5 day) vs. measured water elevation data



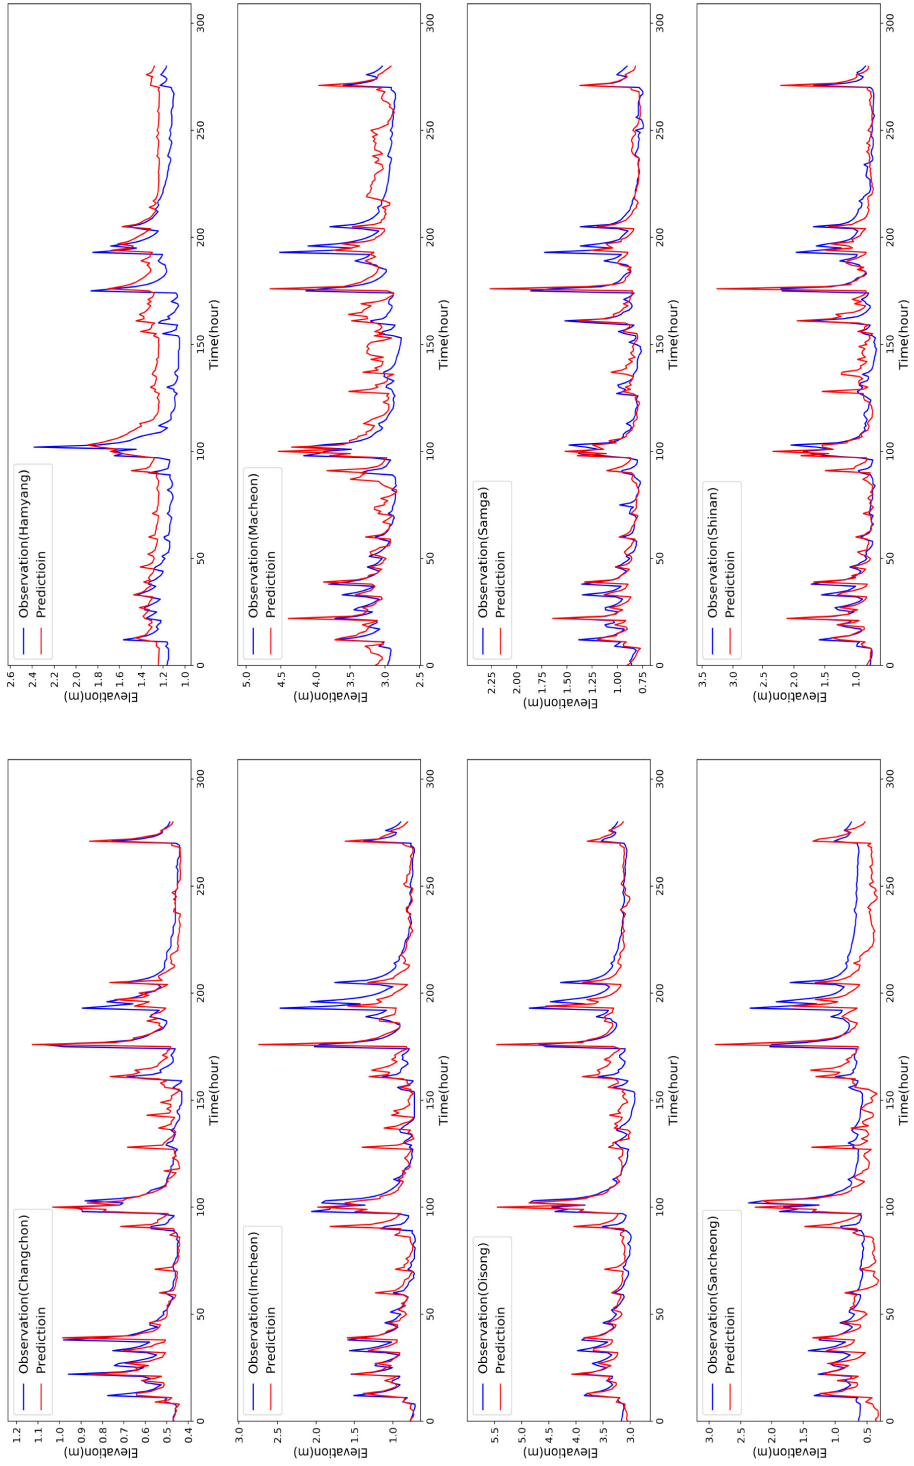
C-1-13. Comparison of scatter plot of LSTM prediction using daily water elevation (6 day) vs. measured water elevation data



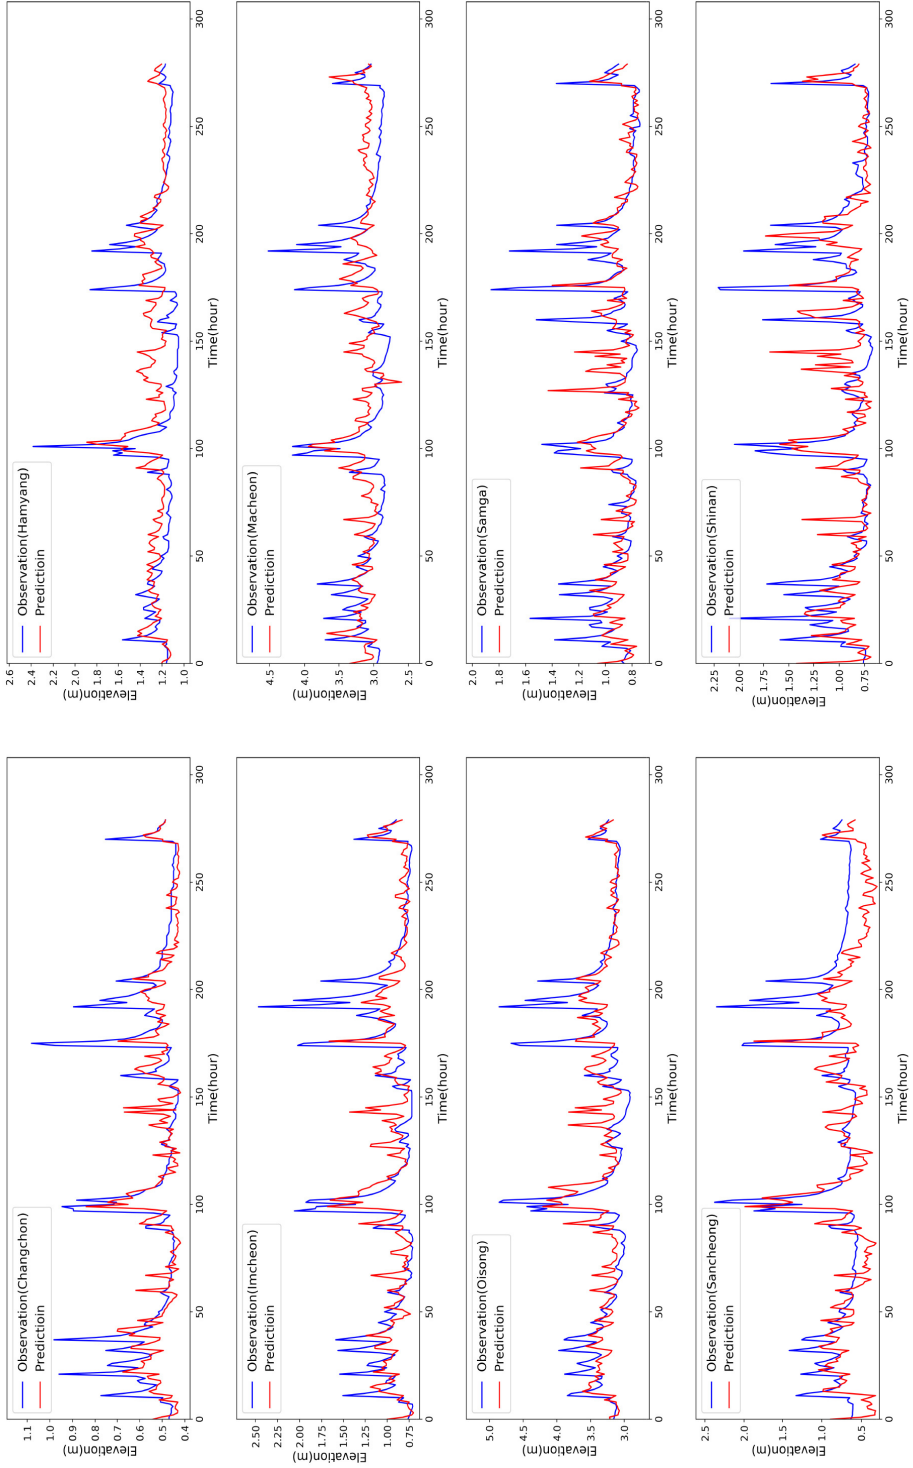
C-1-14. Comparison of scatter plot of LSTM prediction using daily water elevation (7 day) vs. measured water elevation data



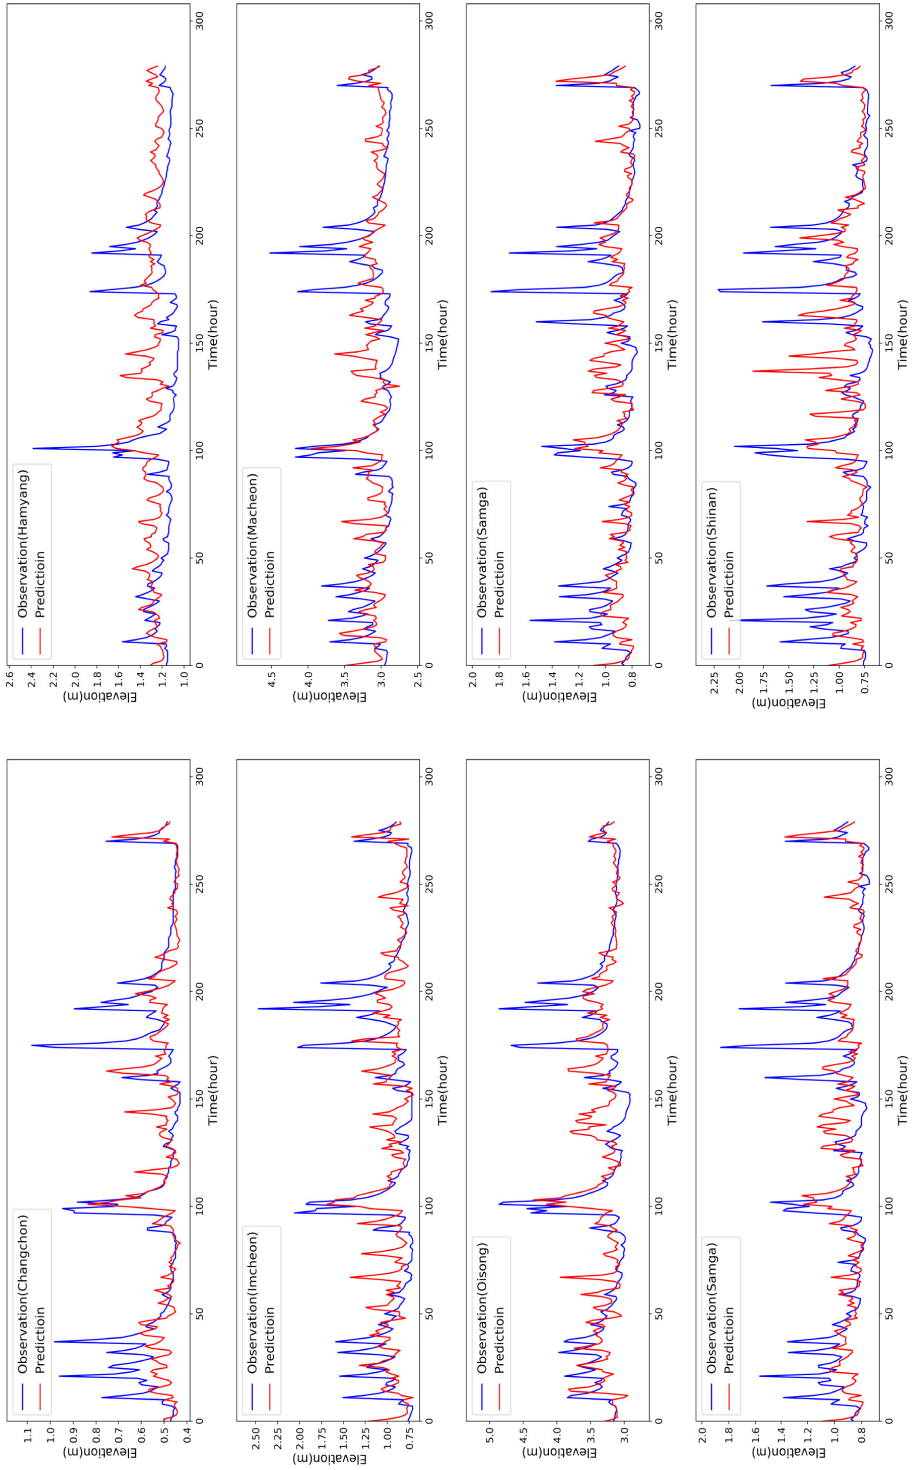
C-2-1. Comparison of LSTM prediction using observation rainfall (1 day) vs. measured water elevation data



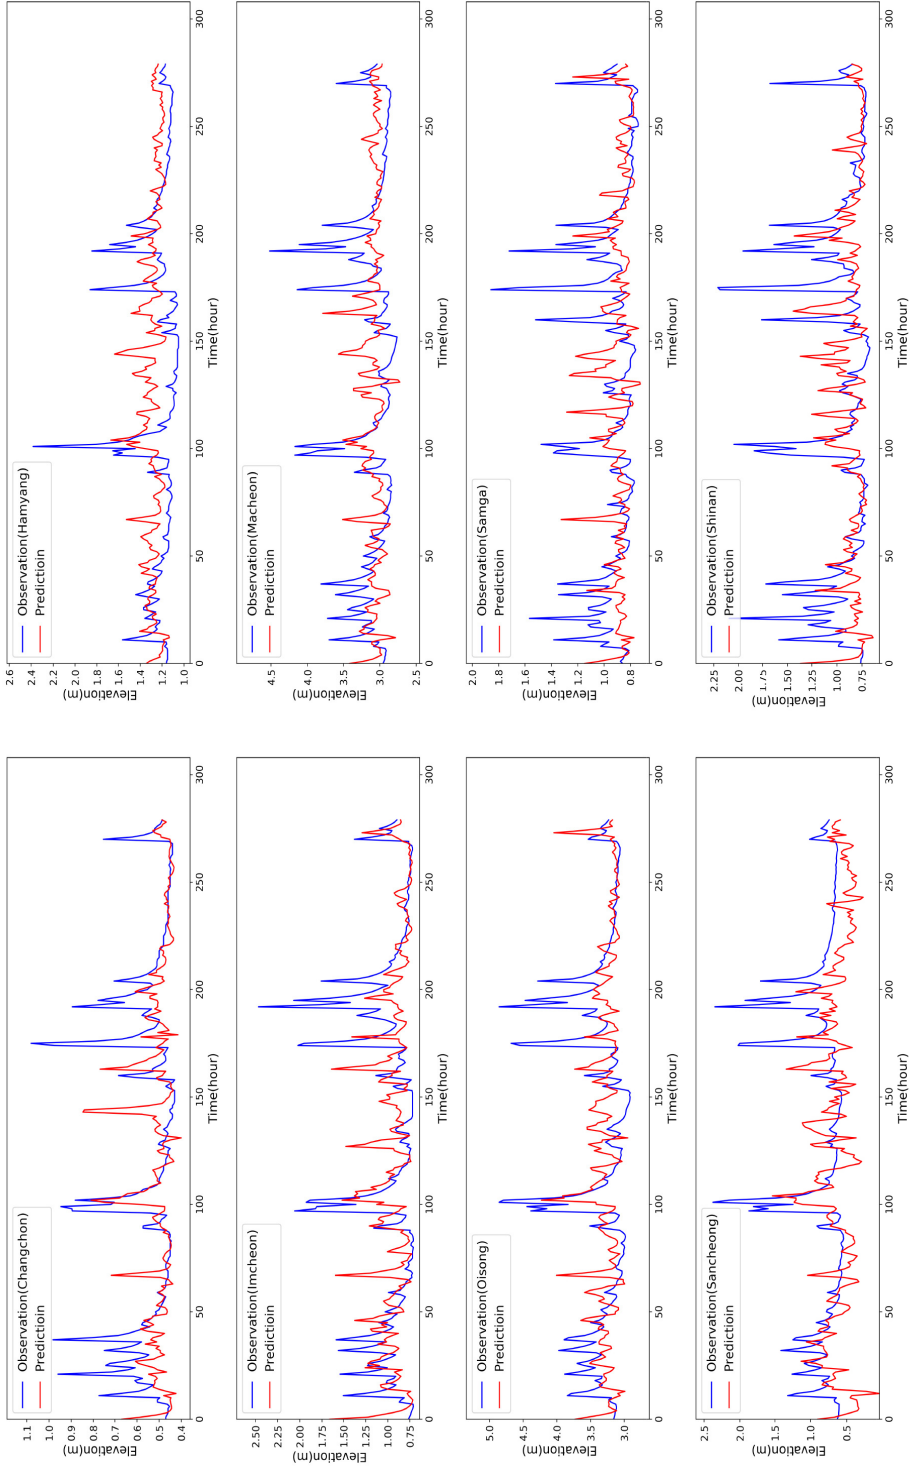
C-2-2. Comparison of LSTM prediction using observation rainfall (2 day) vs. measured water elevation data



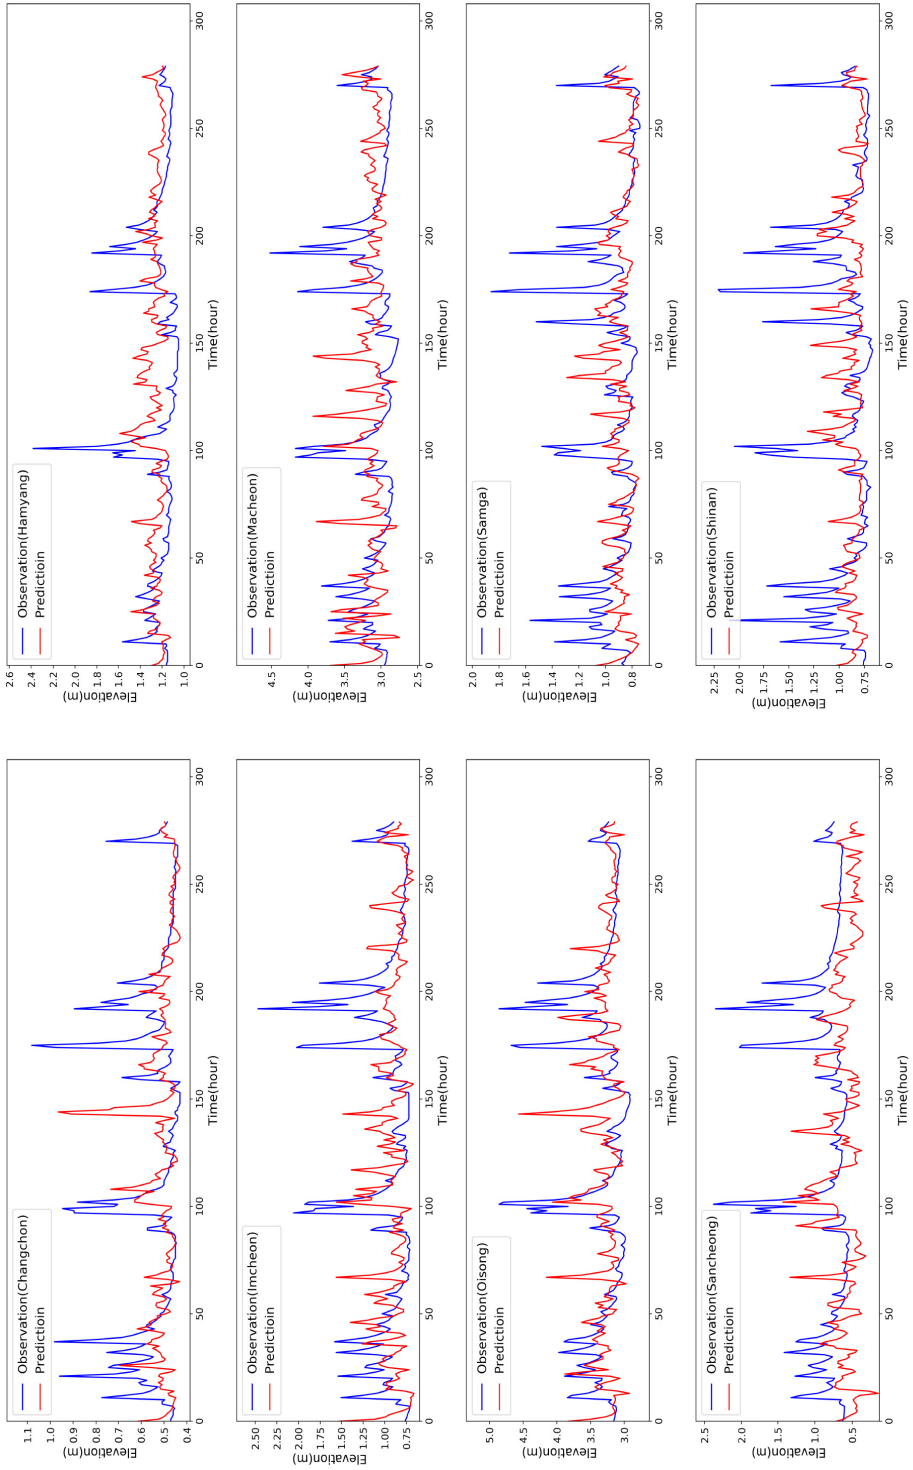
C-2-3. Comparison of LSTM prediction using observation rainfall (3 day) vs. measured water elevation data



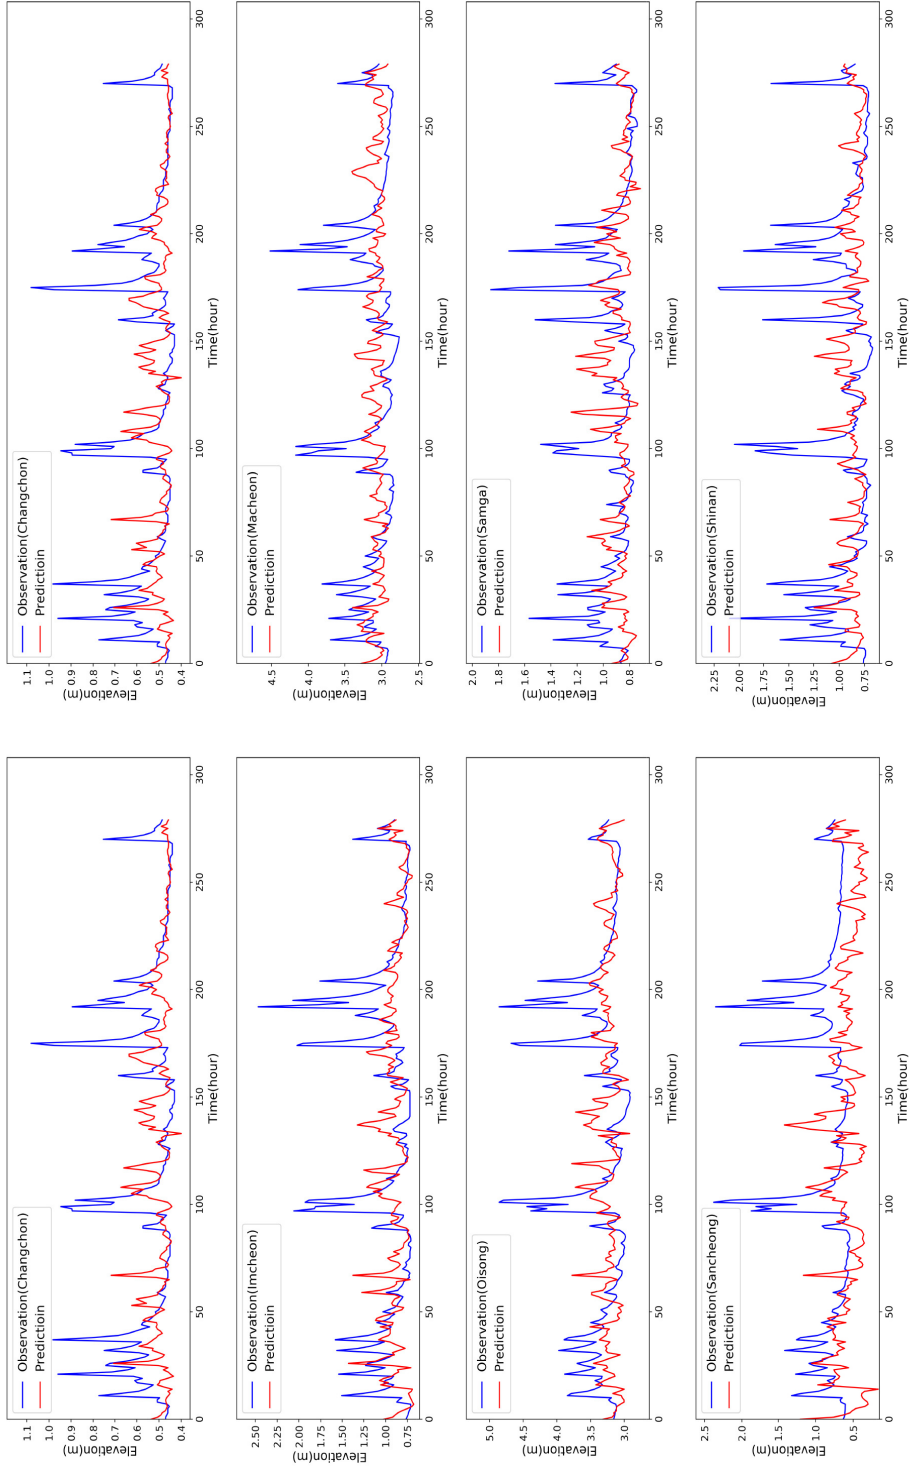
C-2-4. Comparison of LSTM prediction using observation rainfall (4 day) vs. measured water elevation data



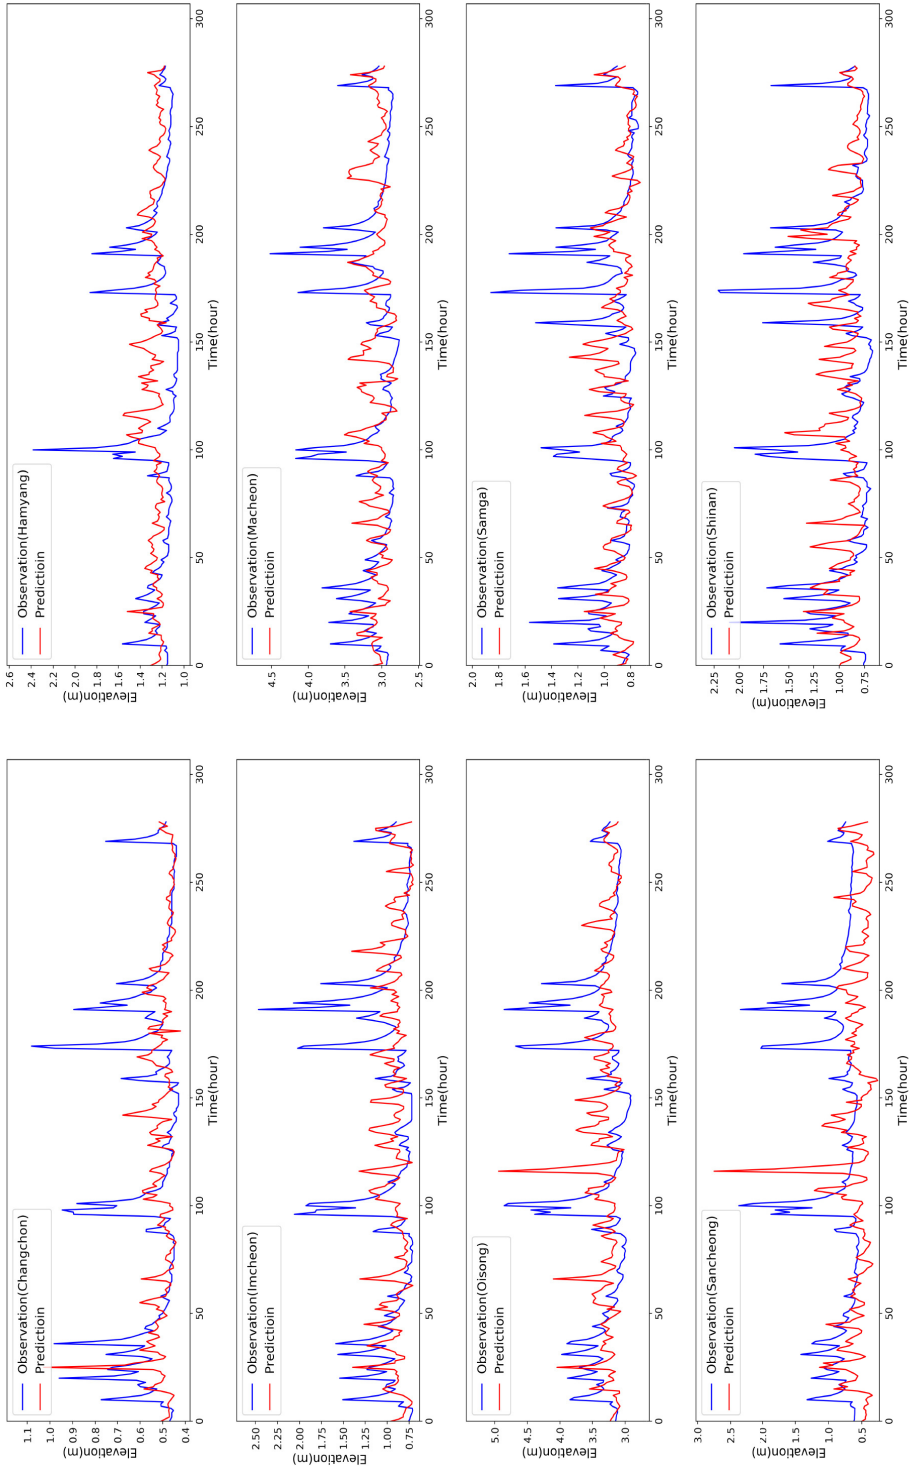
C-2-5. Comparison of LSTM prediction using observation rainfall (5 day) vs. measured water elevation data



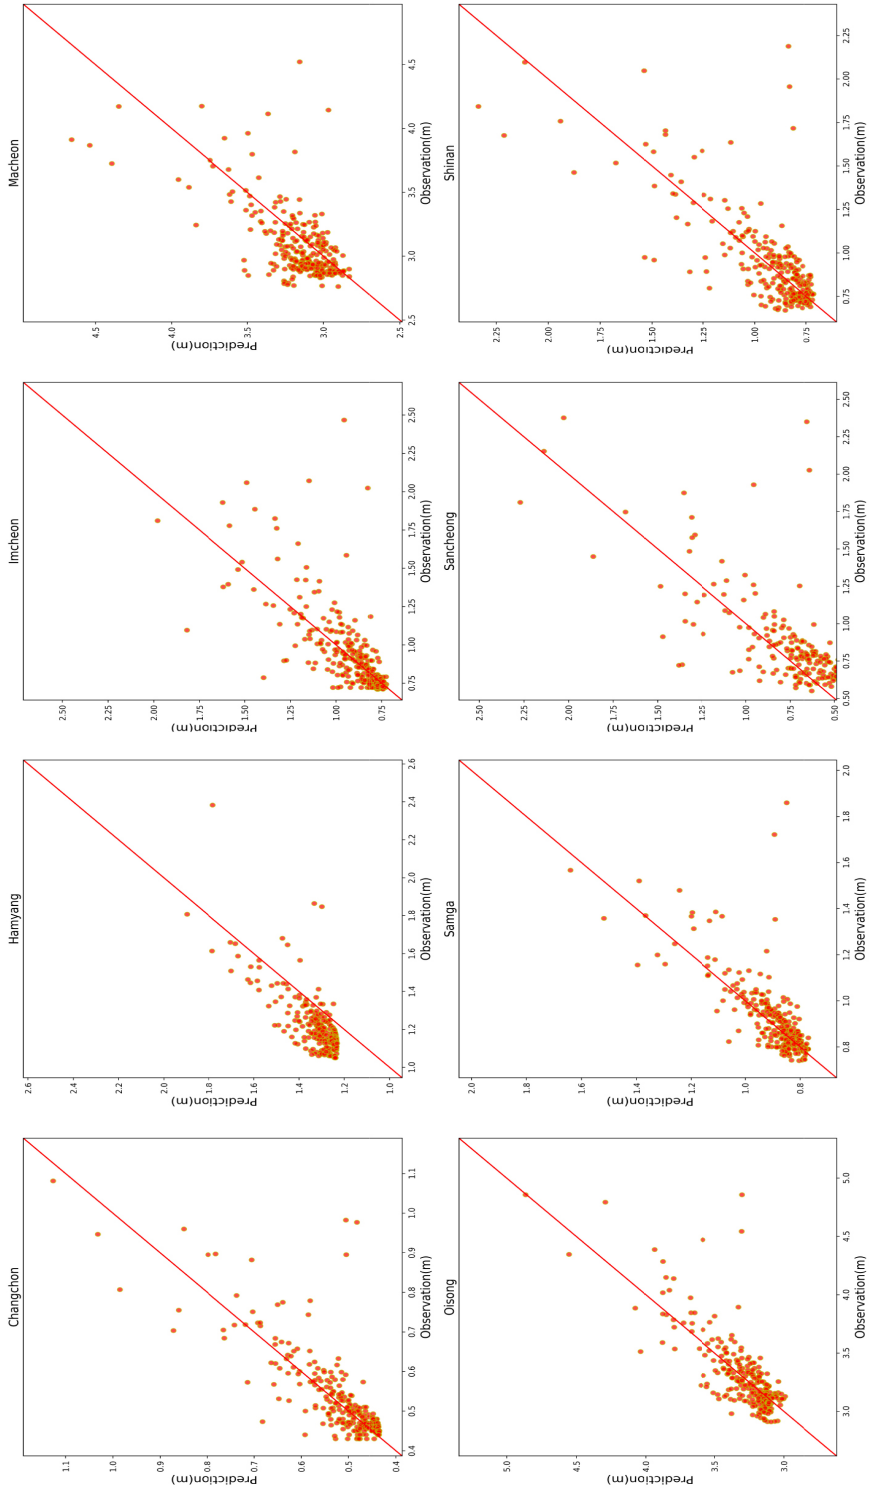
C-2-6. Comparison of LSTM prediction using observation rainfall (6 day) vs. measured water elevation data



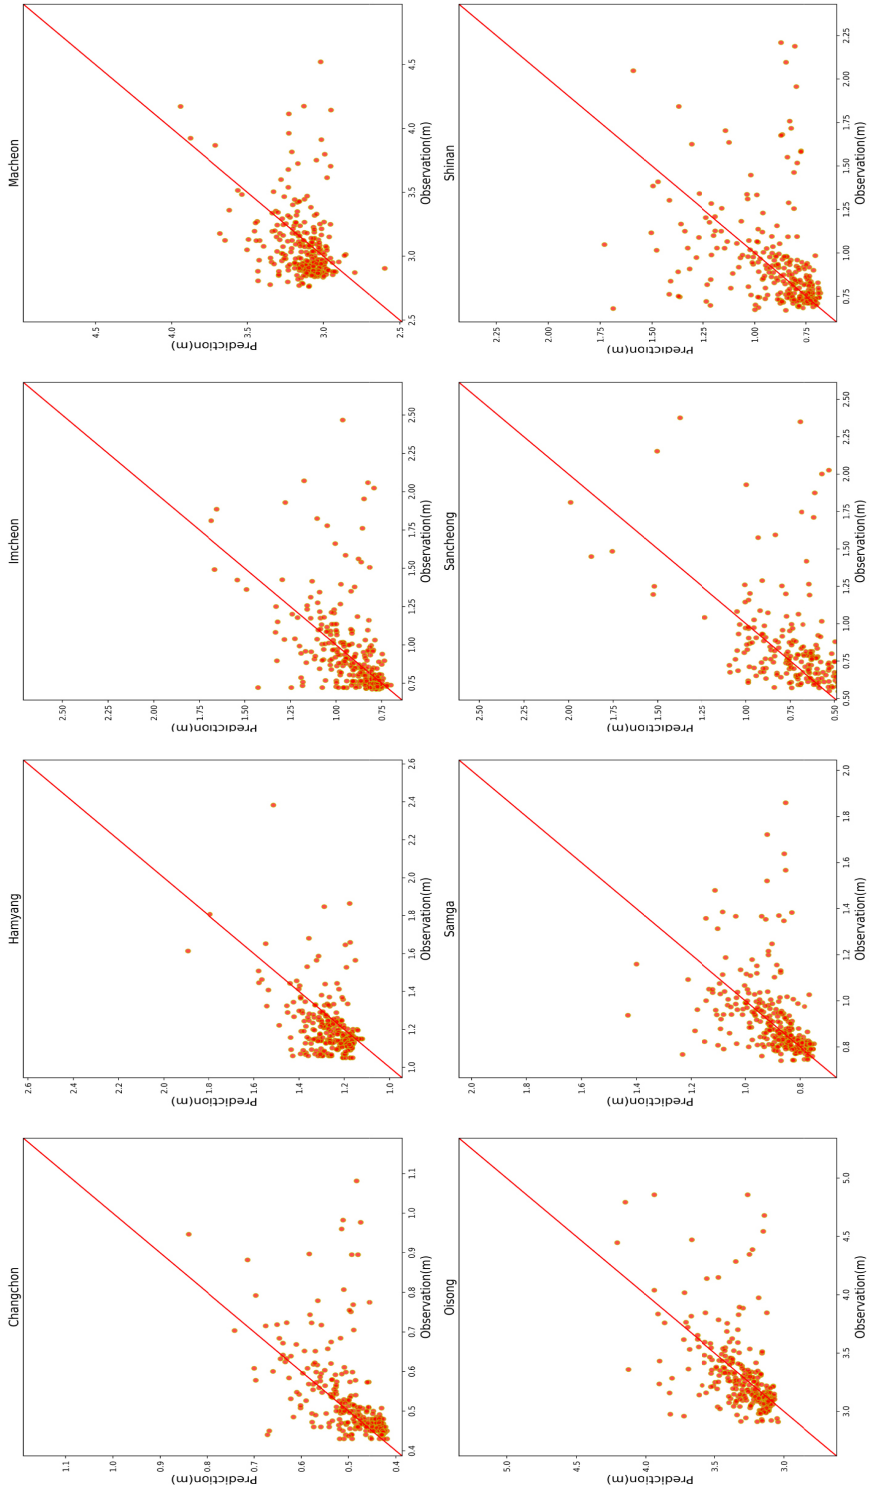
C-2-7. Comparison of LSTM prediction using observation rainfall (7 day) vs. measured water elevation data



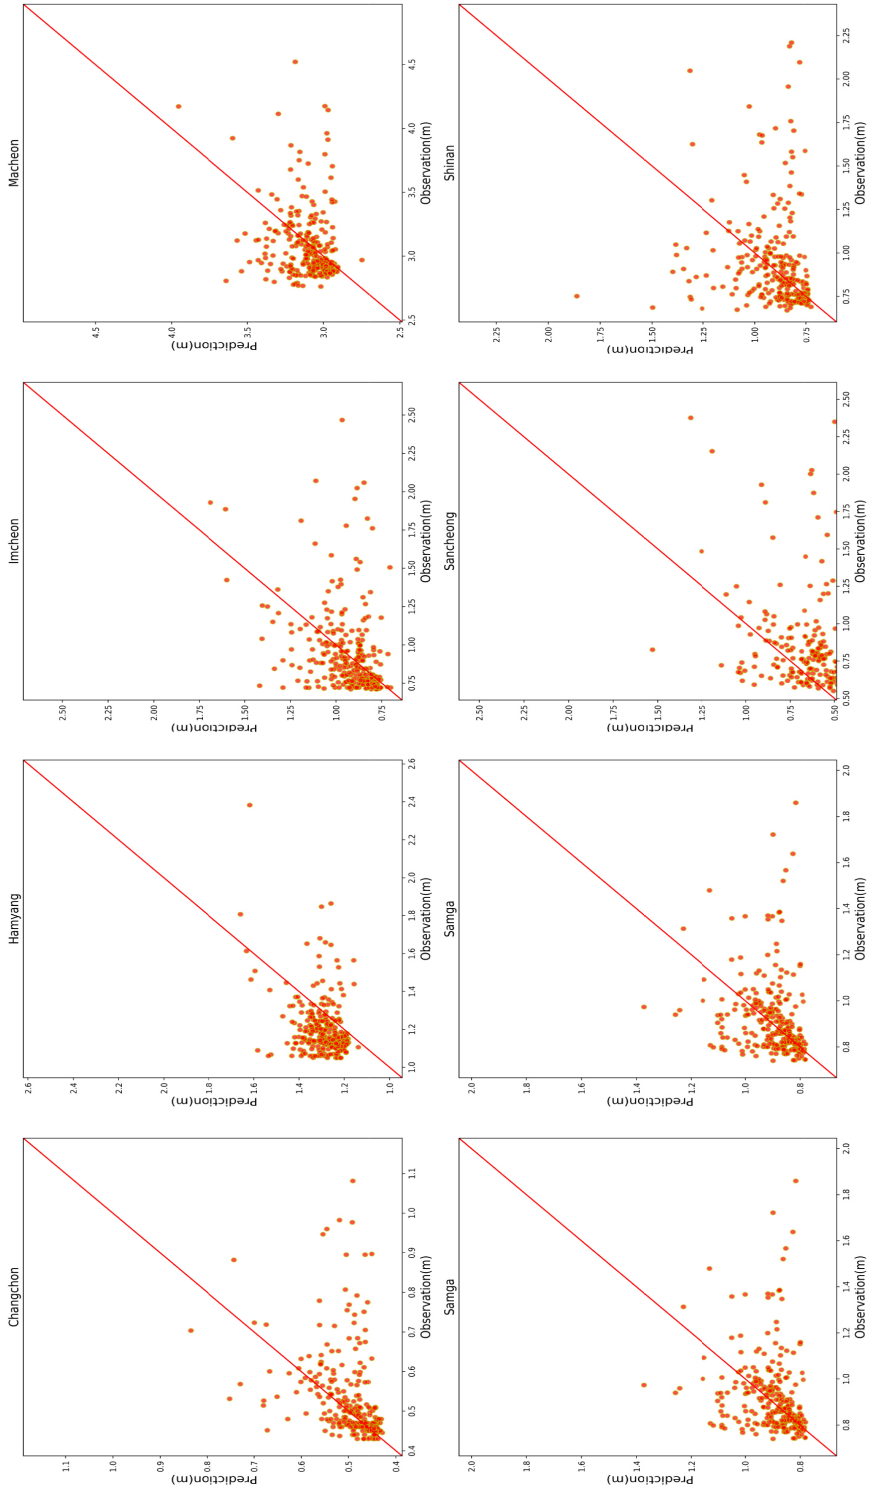
C-2-8. Comparison of scatter plot of LSTM prediction using observation rainfall (1 day) vs. measured water elevation data



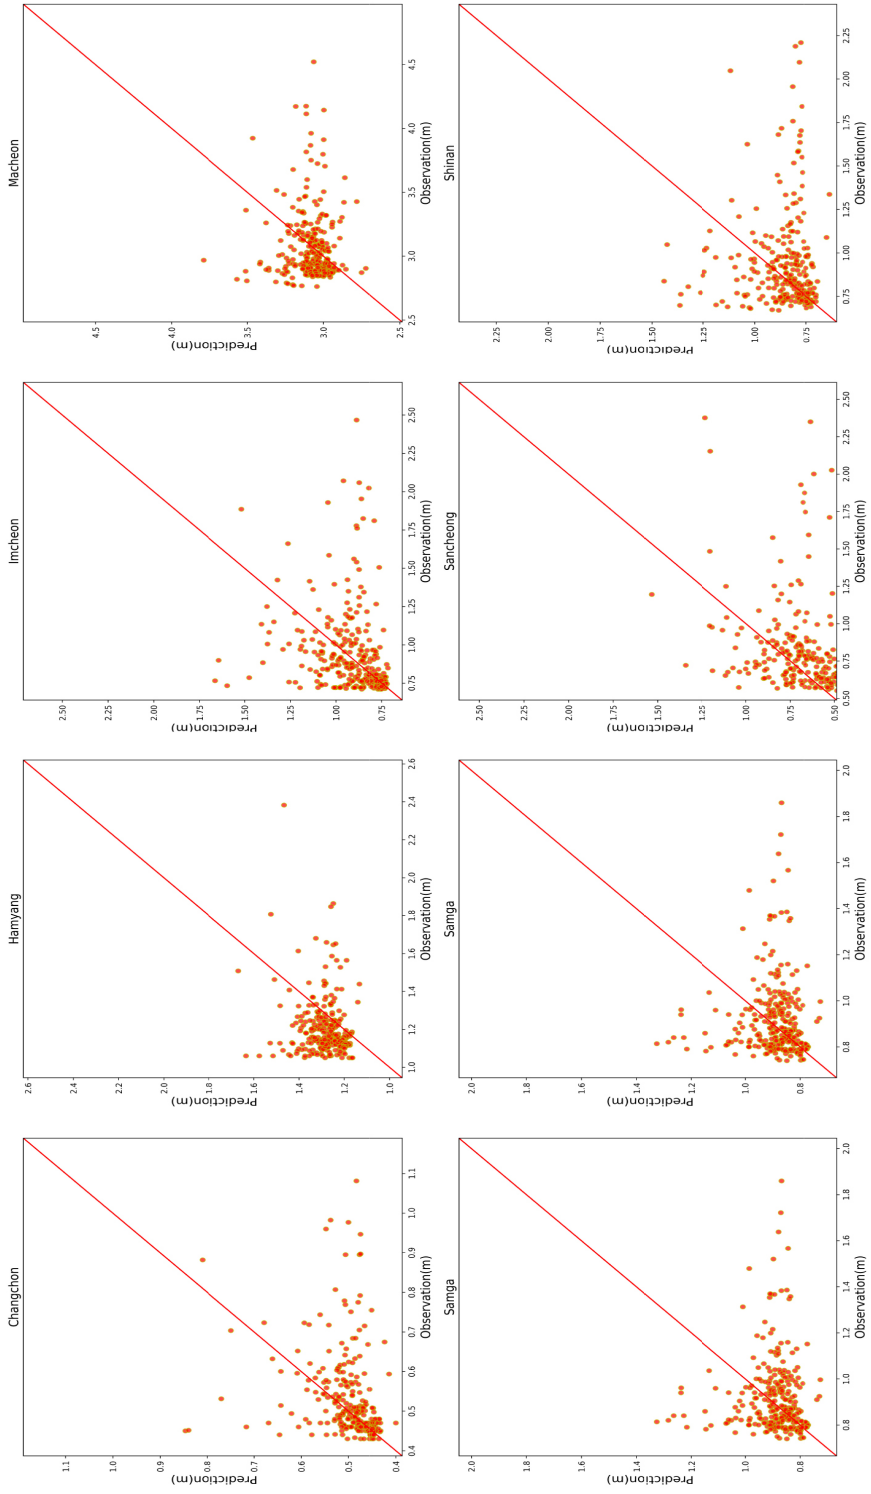
C-2-9. Comparison of scatter plot of LSTM prediction using observation rainfall (2 day) vs. measured water elevation data



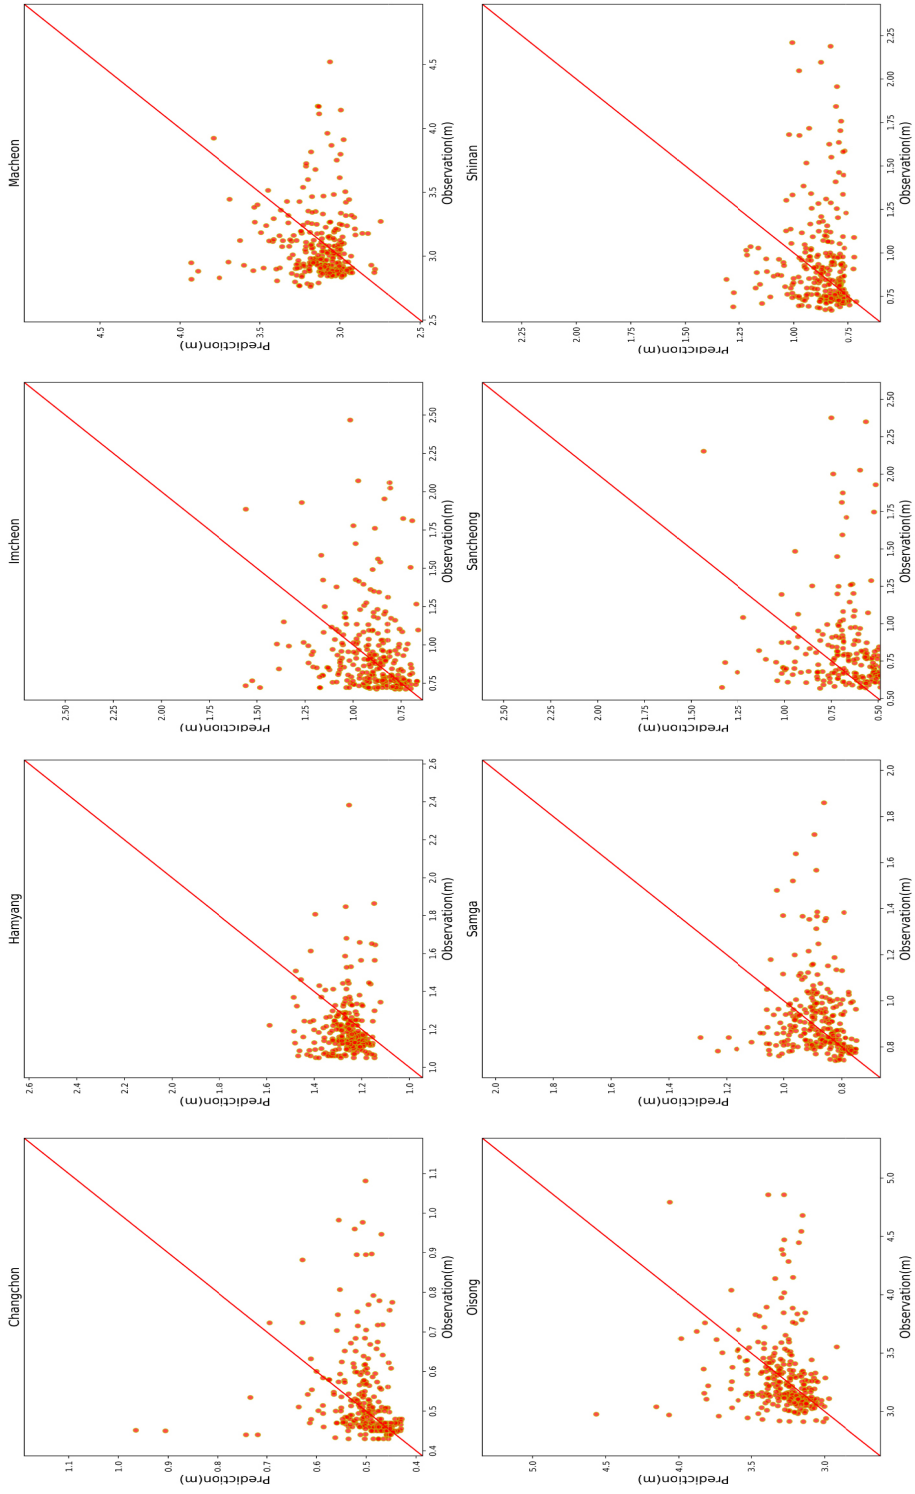
C-2-10. Comparison of scatter plot of LSTM prediction using observation rainfall (3 day) vs. measured water elevation data



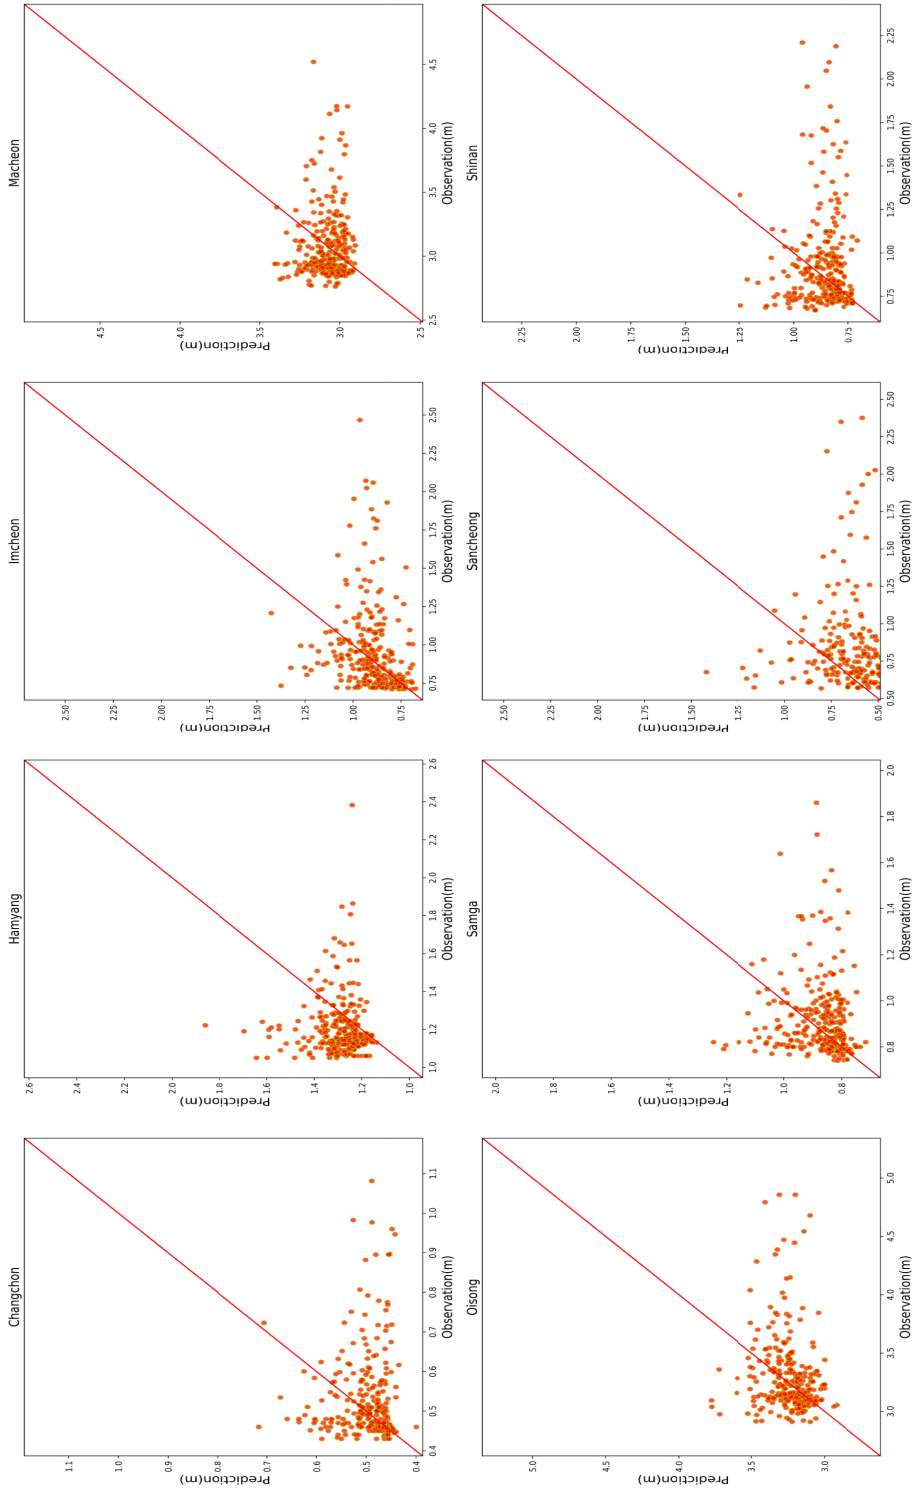
C-2-11. Comparison of scatter plot of LSTM prediction using observation rainfall (4 day) vs. measured water elevation data



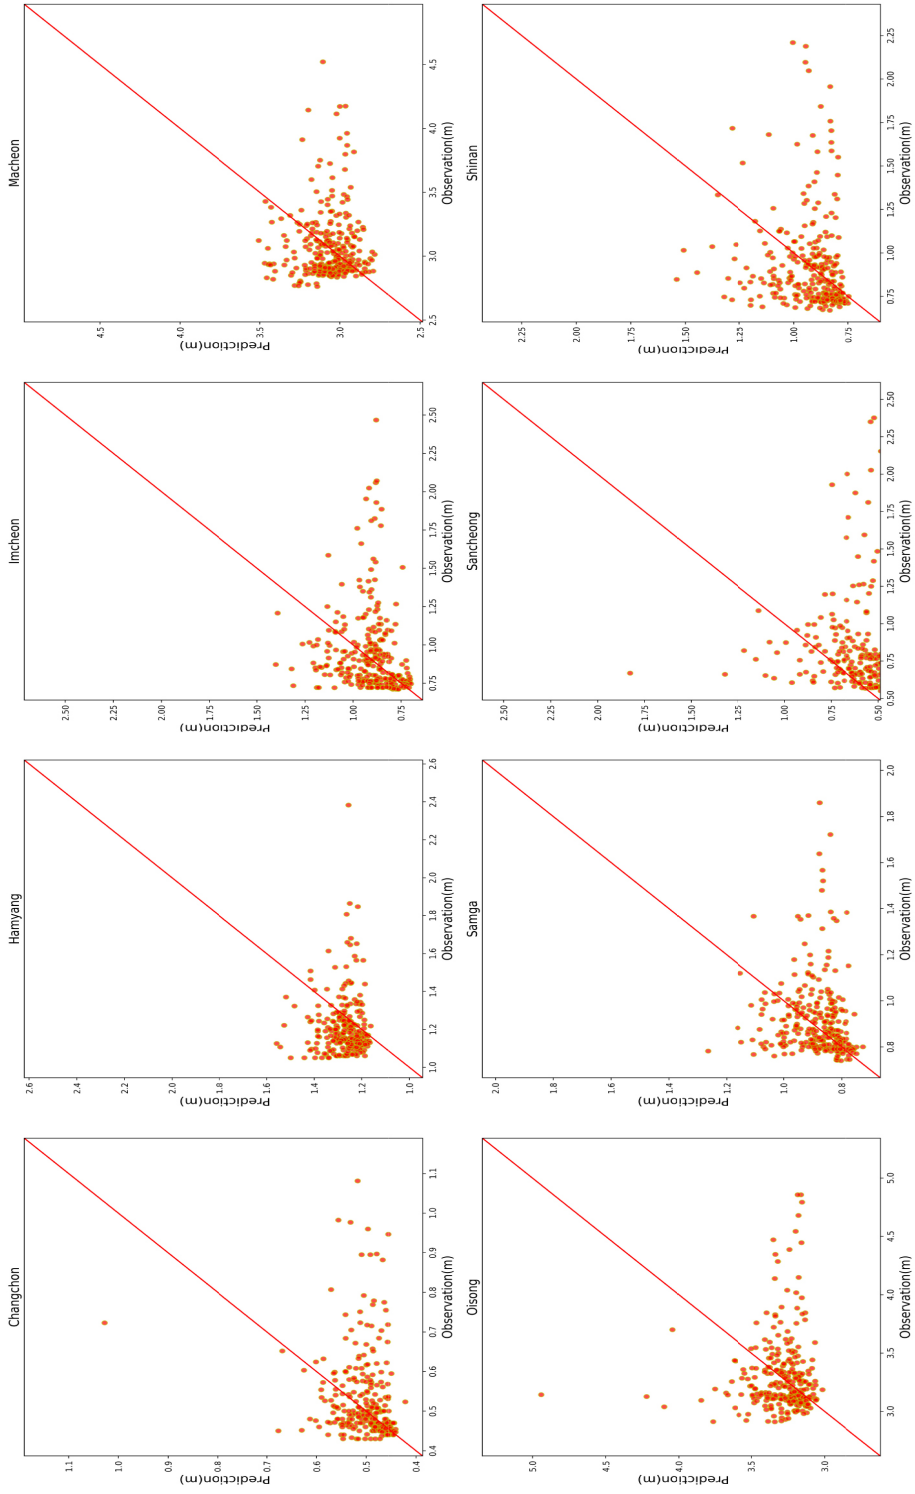
C-2-12. Comparison of scatter plot of LSTM prediction using observation rainfall (5 day) vs. measured water elevation data



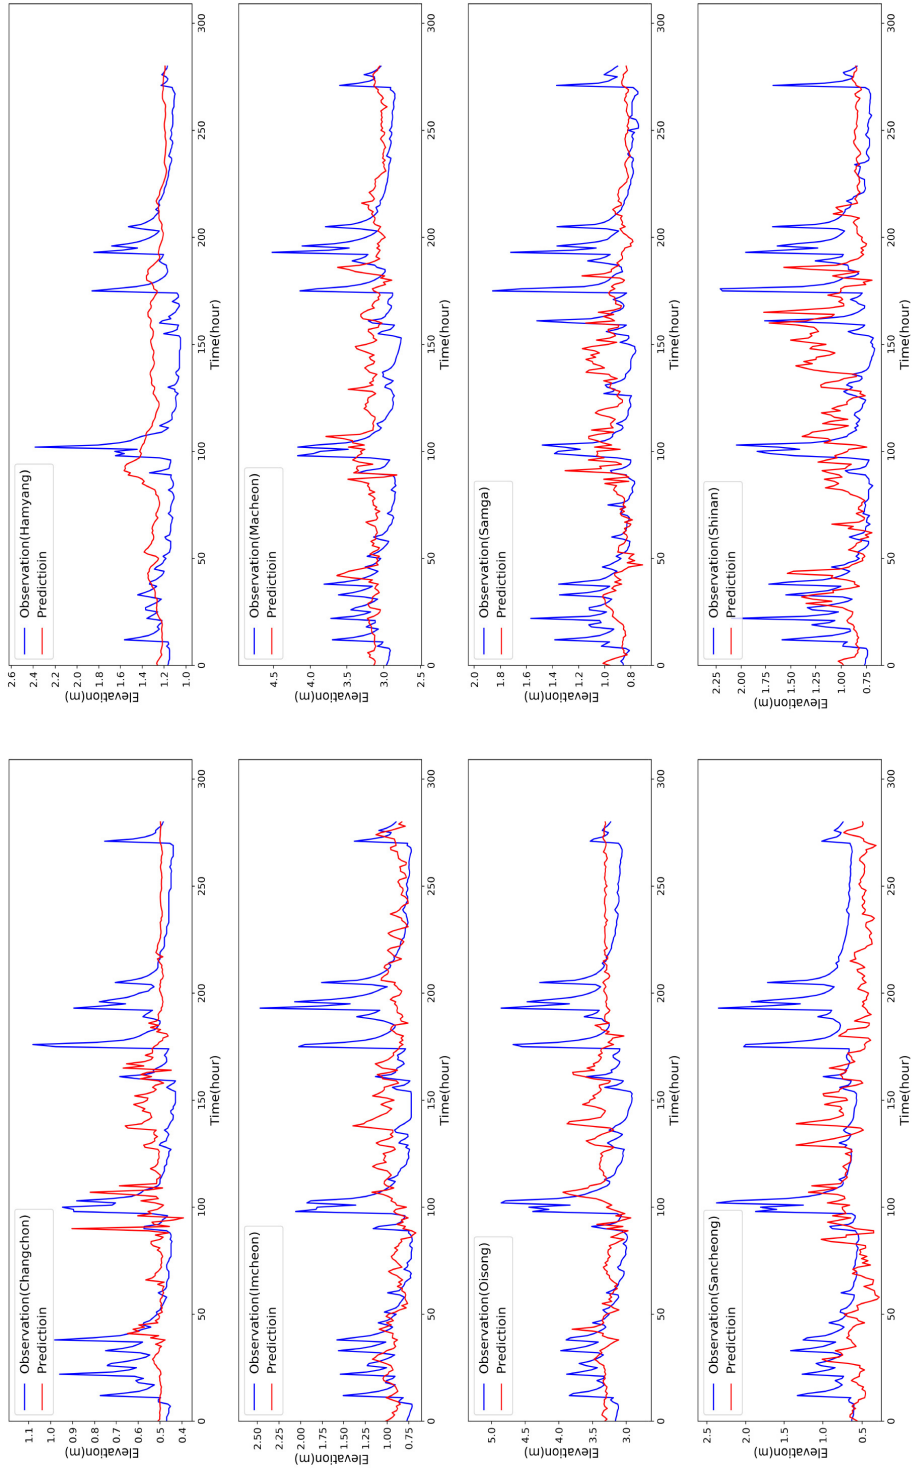
C-2-13. Comparison of scatter plot of LSTM prediction using observation rainfall (6 day) vs. measured water elevation data



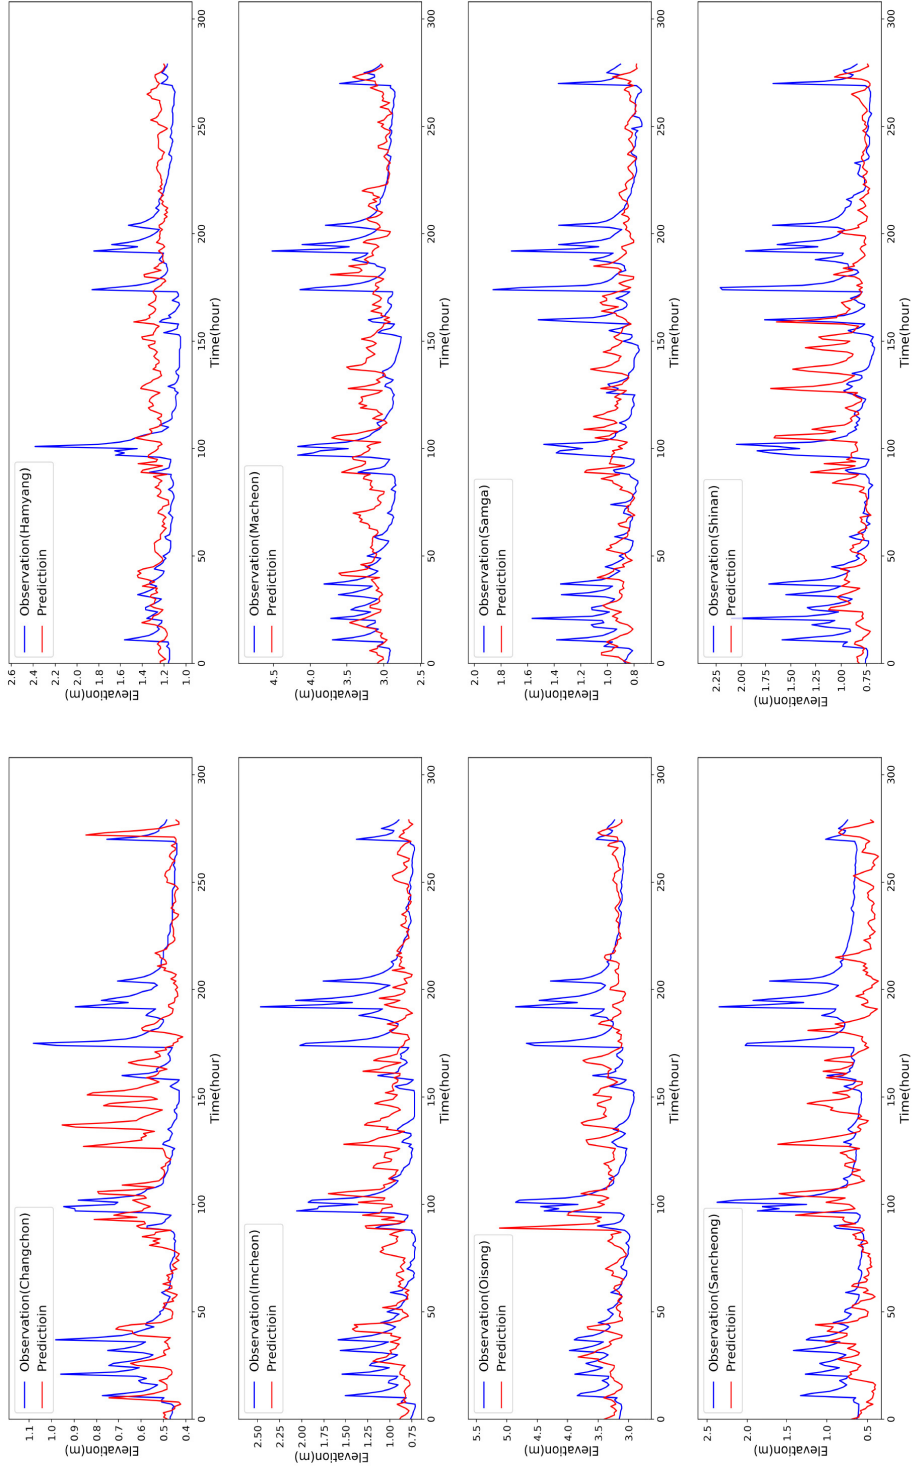
C-2-14. Comparison of scatter plot of LSTM prediction using observation rainfall (7 day) vs. measured water elevation data



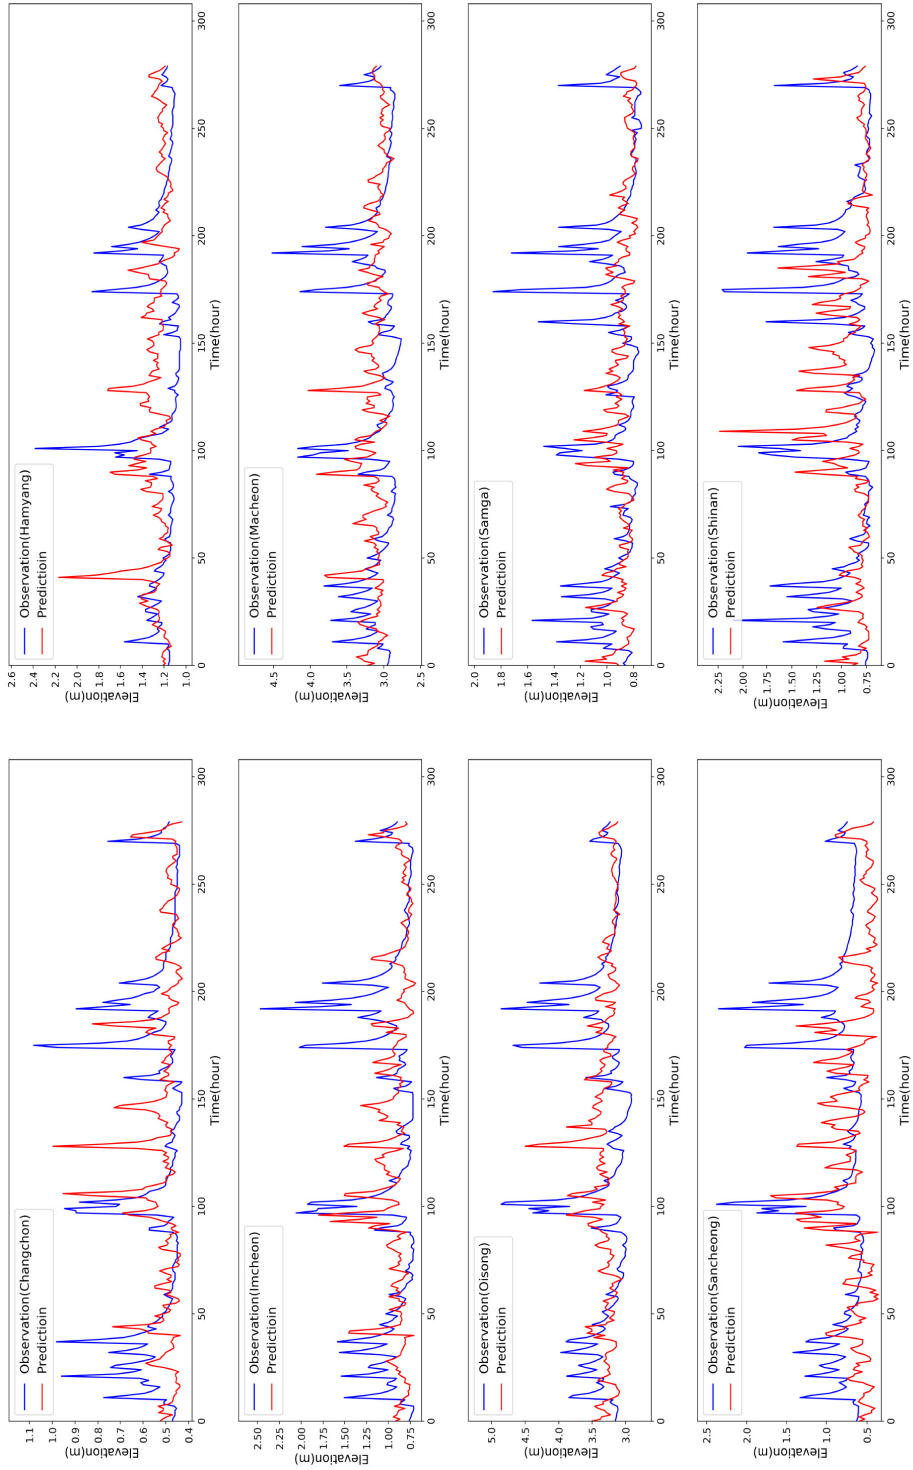
C-3-1. Comparison of 1 day prediction using 40 day interval S2S vs. measured water elevation data



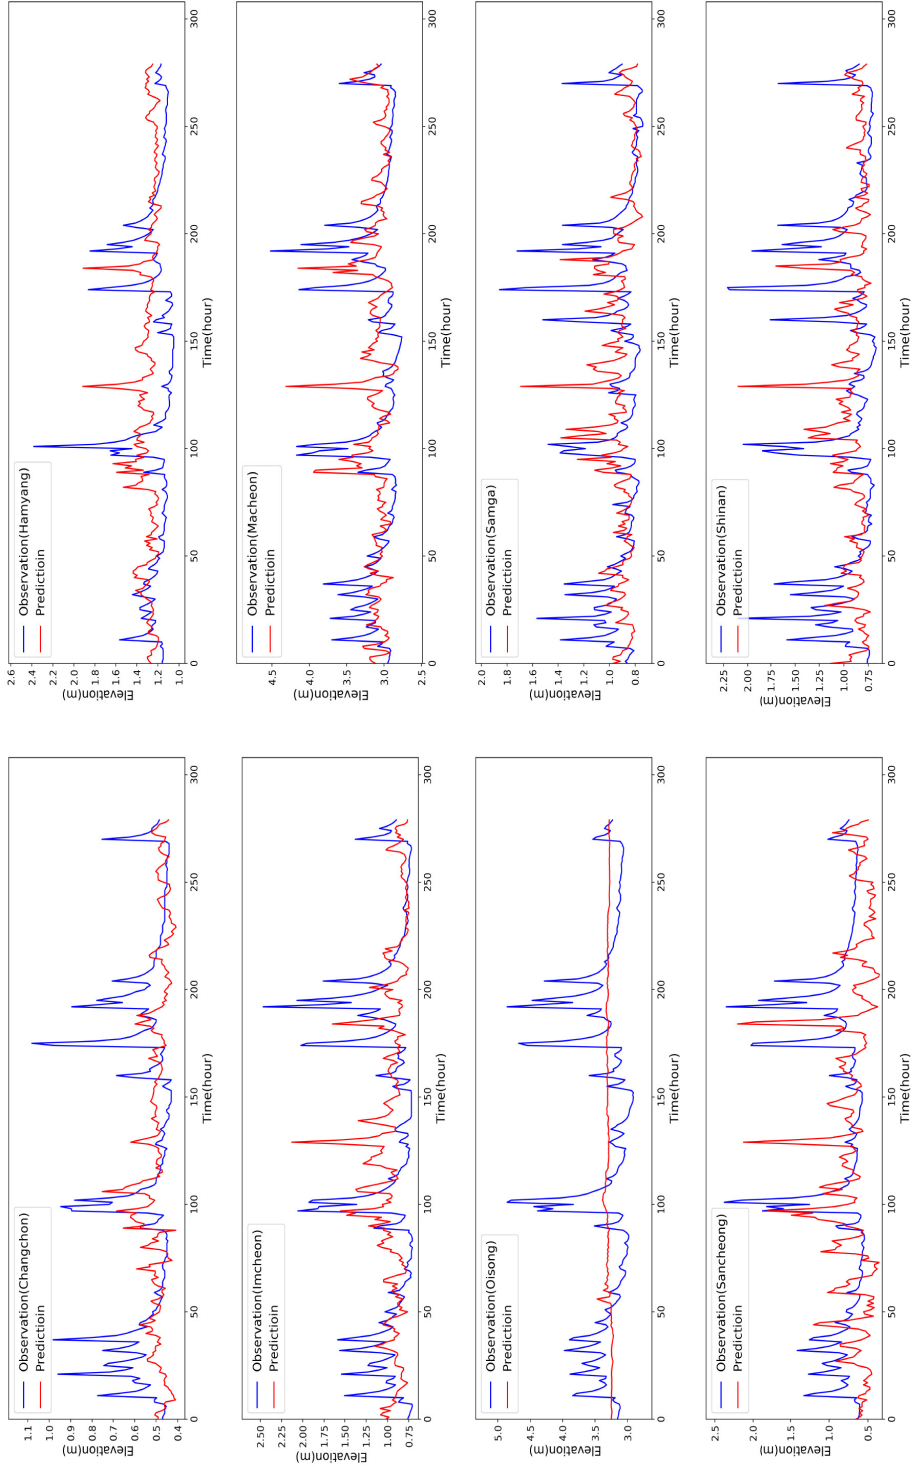
C-3-2. Comparison of 2 day prediction using 40 day interval S2S vs. measured water elevation data



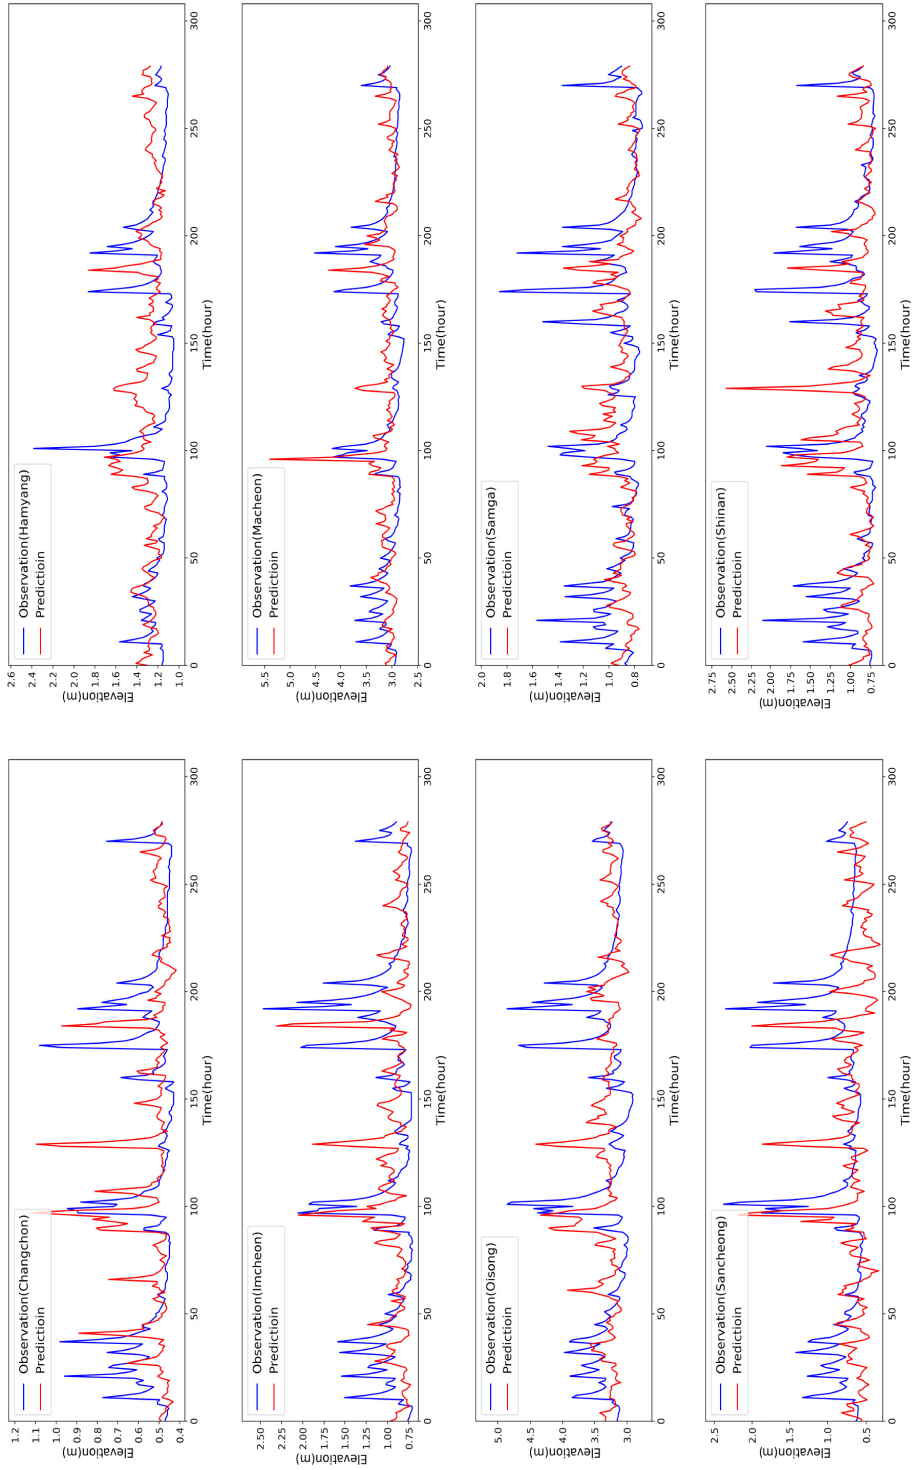
C-3-3. Comparison of 3 day prediction using 40 day interval S2S vs. measured water elevation data



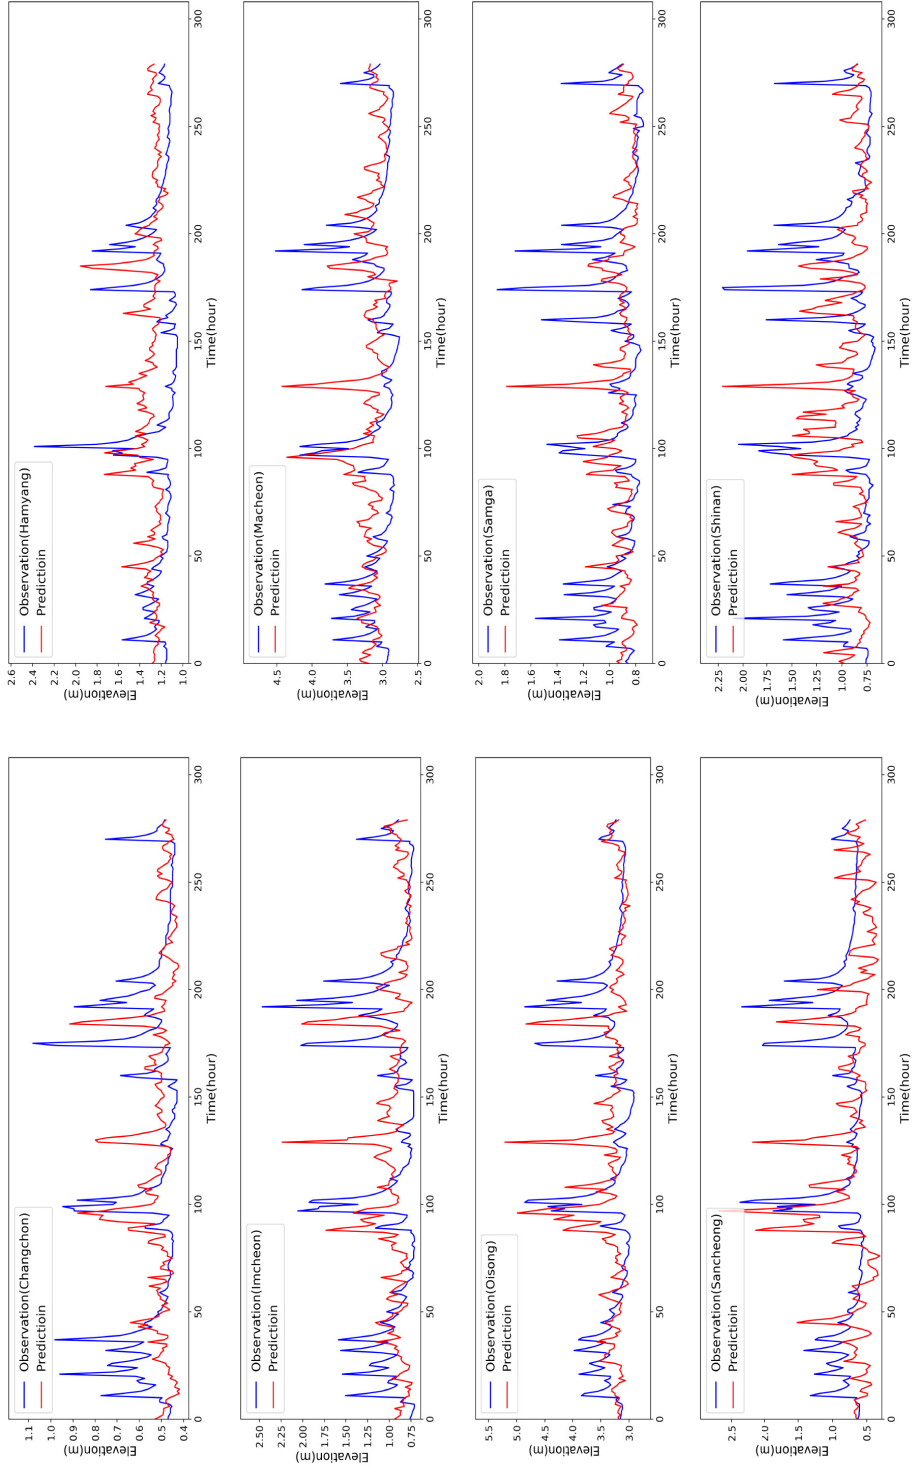
C-3-4. Comparison of 4 day prediction using 40 day interval S2S vs. measured water elevation data



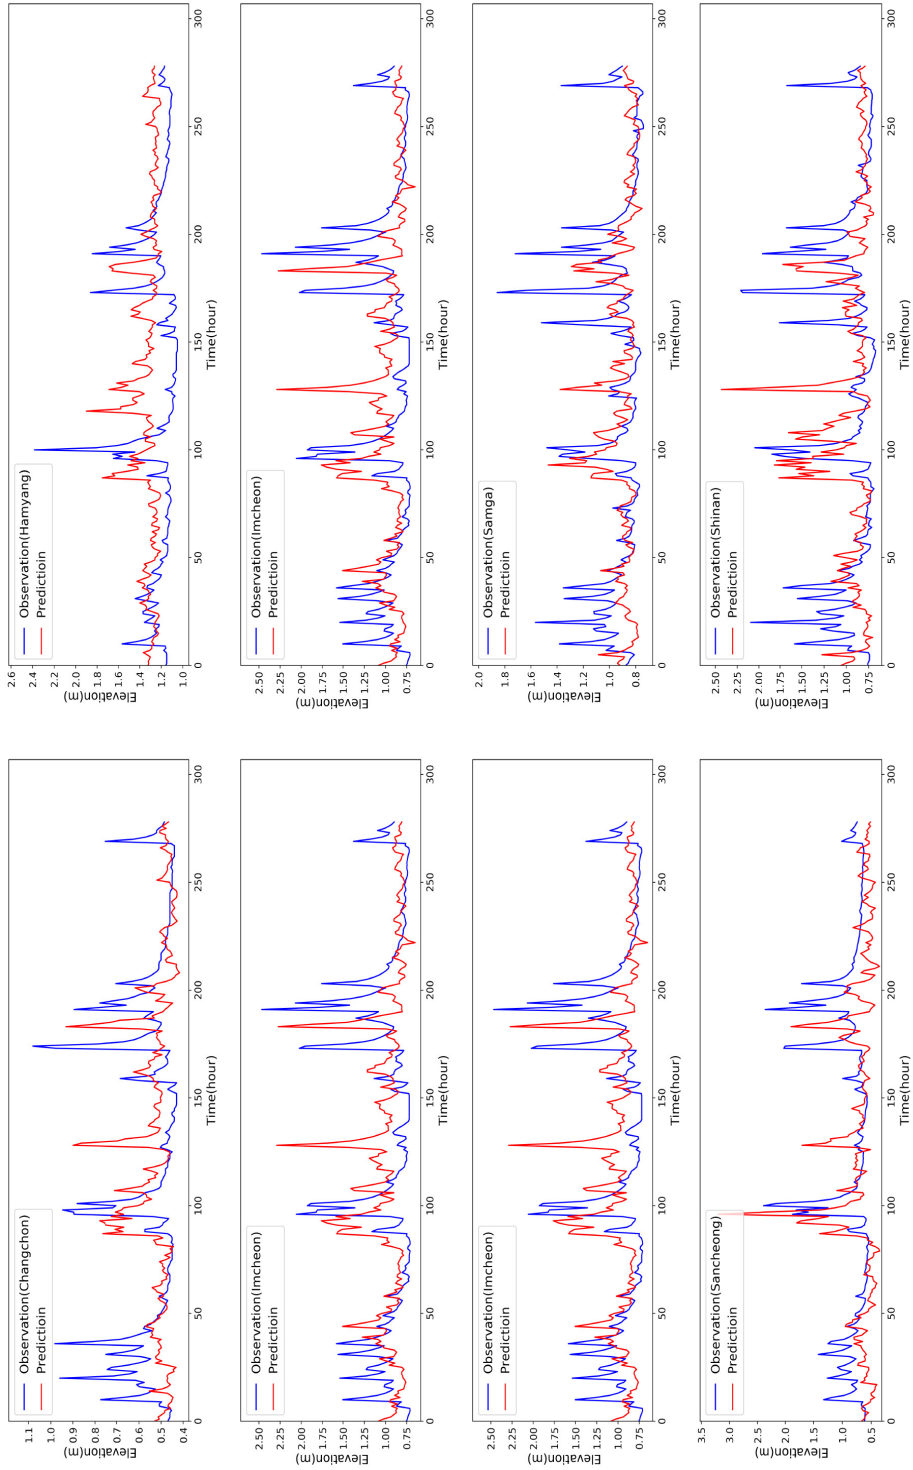
C-3-5. Comparison of 5 day prediction using 40 day interval S2S vs. measured water elevation data



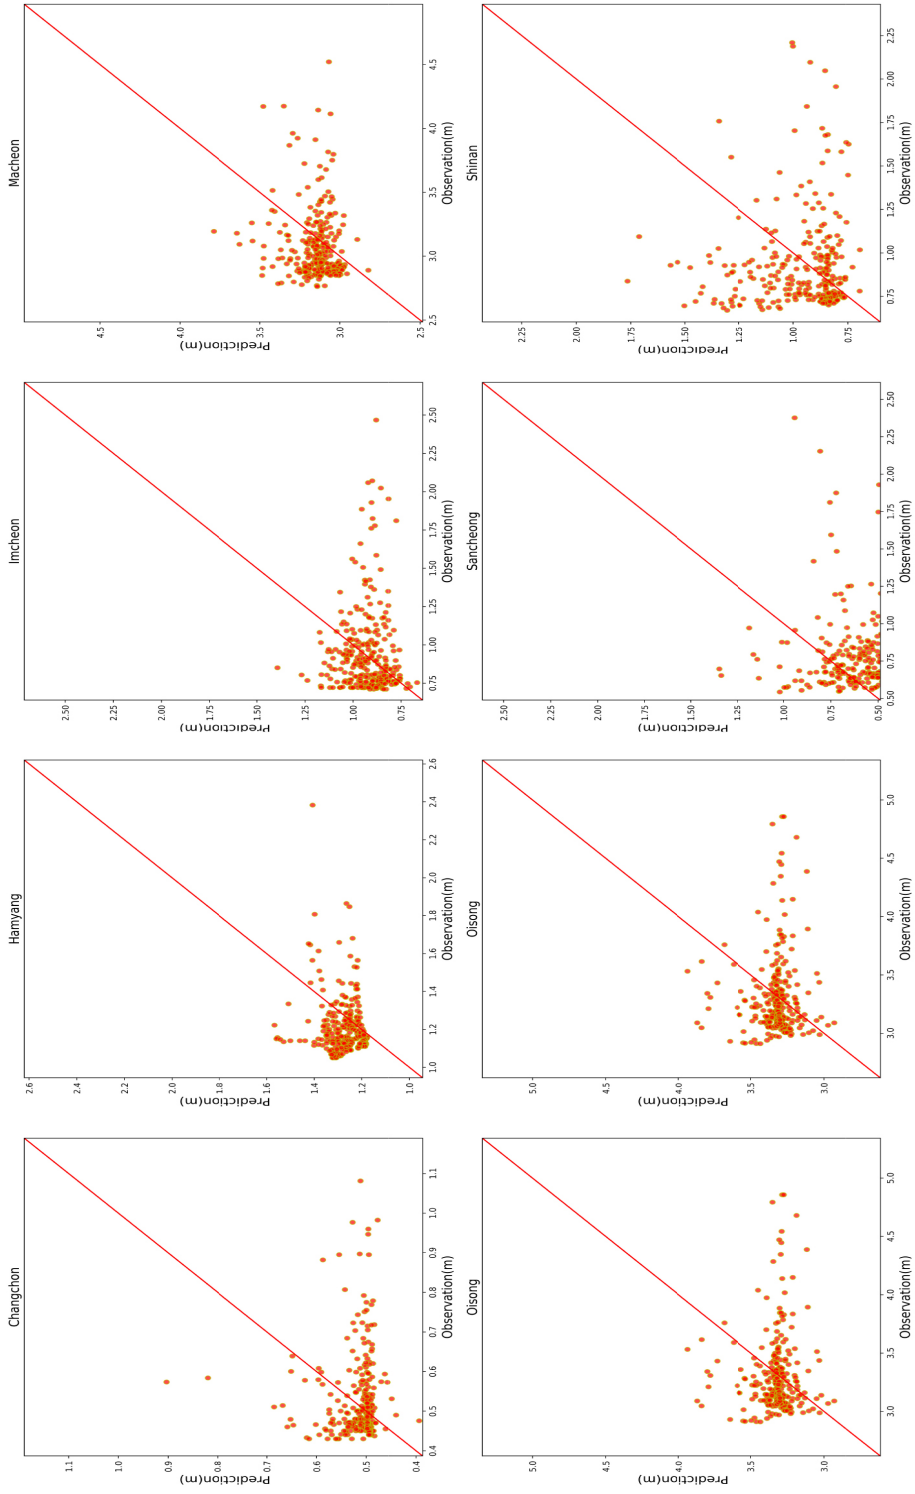
C-3-6. Comparison of 6 day prediction using 40 day interval S2S vs. measured water elevation data



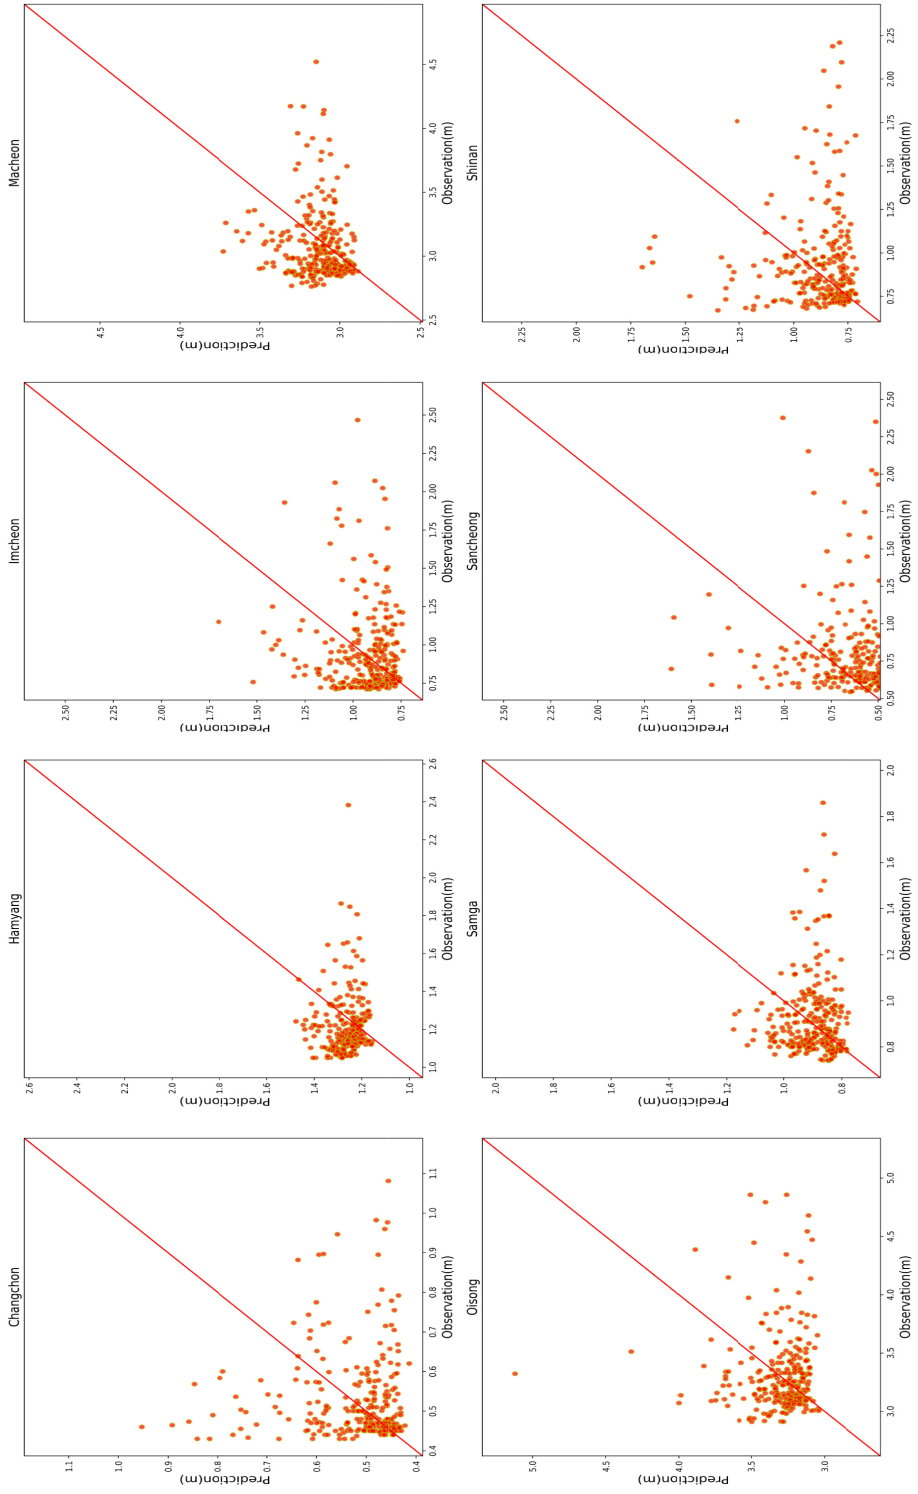
C-3-7. Comparison of 7 day prediction using 40 day interval S2S vs. measured water elevation data



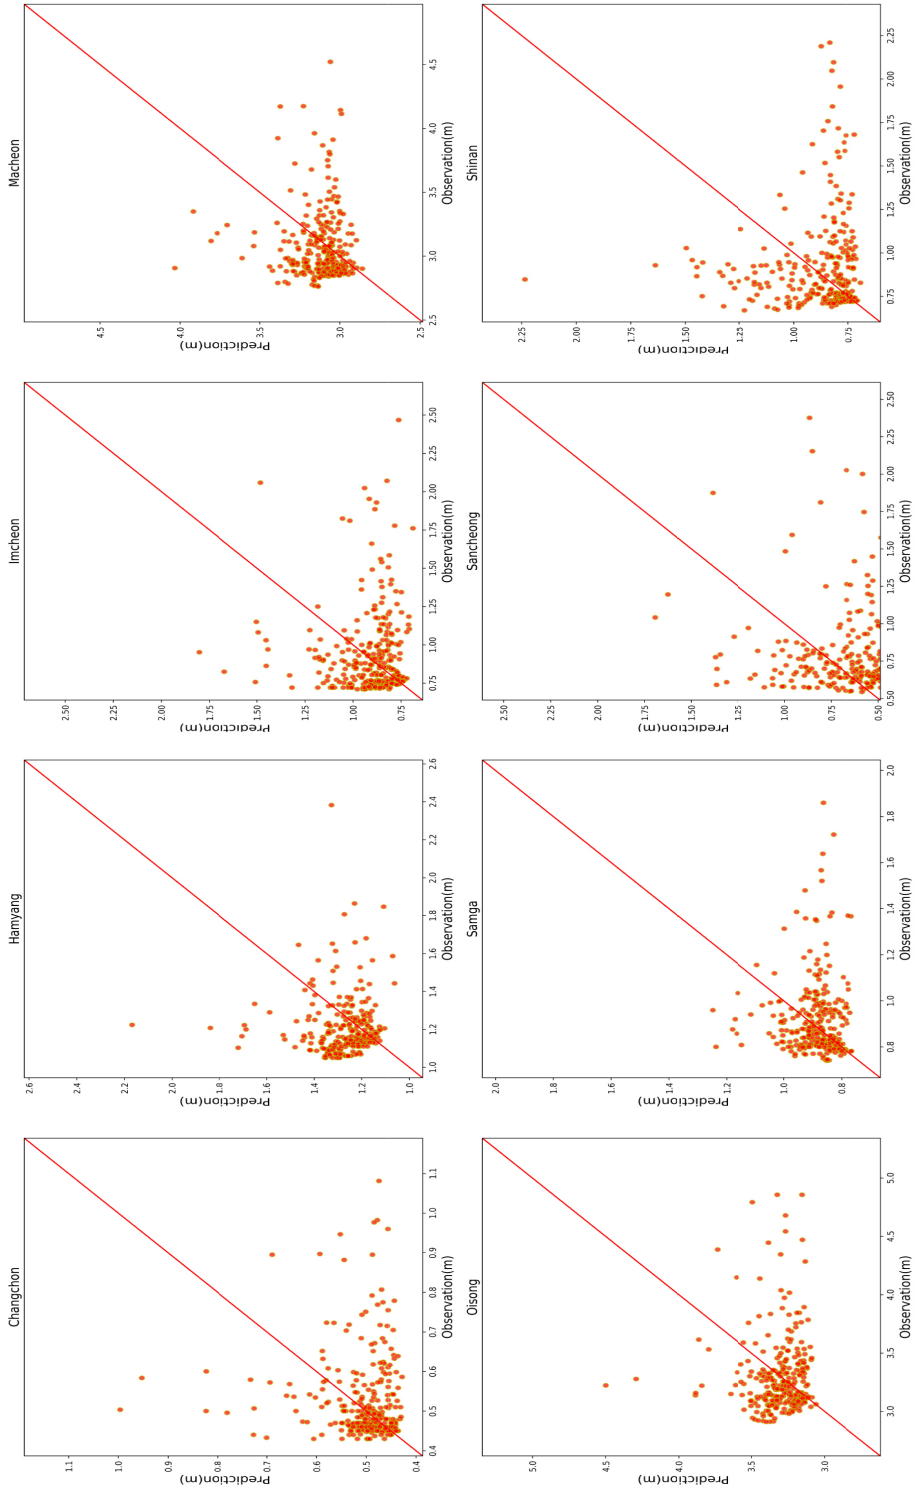
C-3-8. Comparison of scatter plot of LSTM 1 day prediction using 40 day interval S2S vs. measured water elevation data



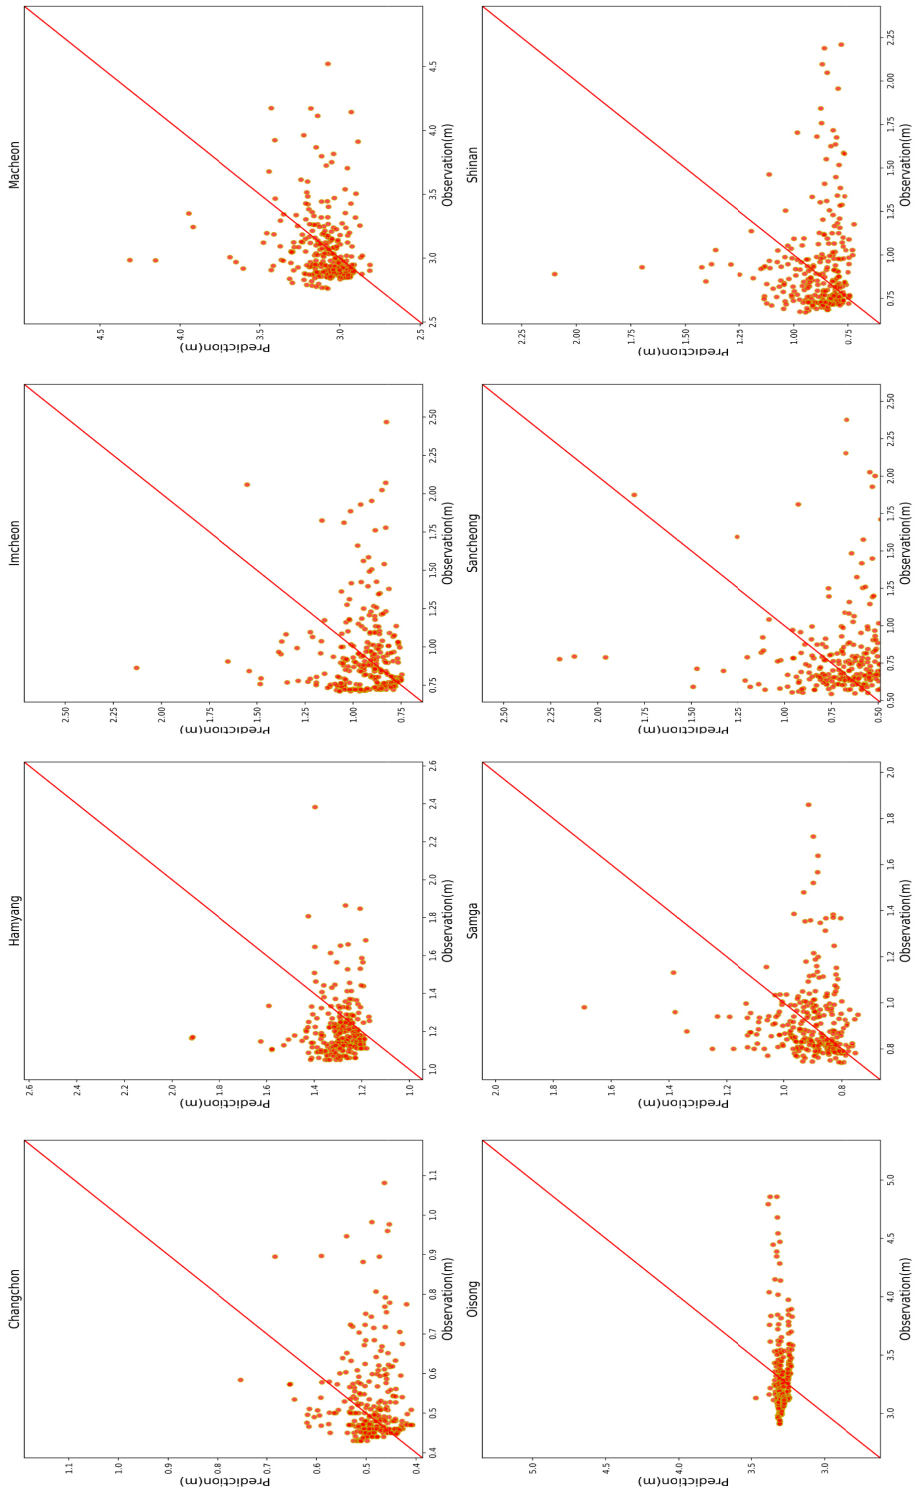
C-3-9. Comparison of scatter plot of LSTM 2 day prediction using 40 day interval S2S vs. measured water elevation data



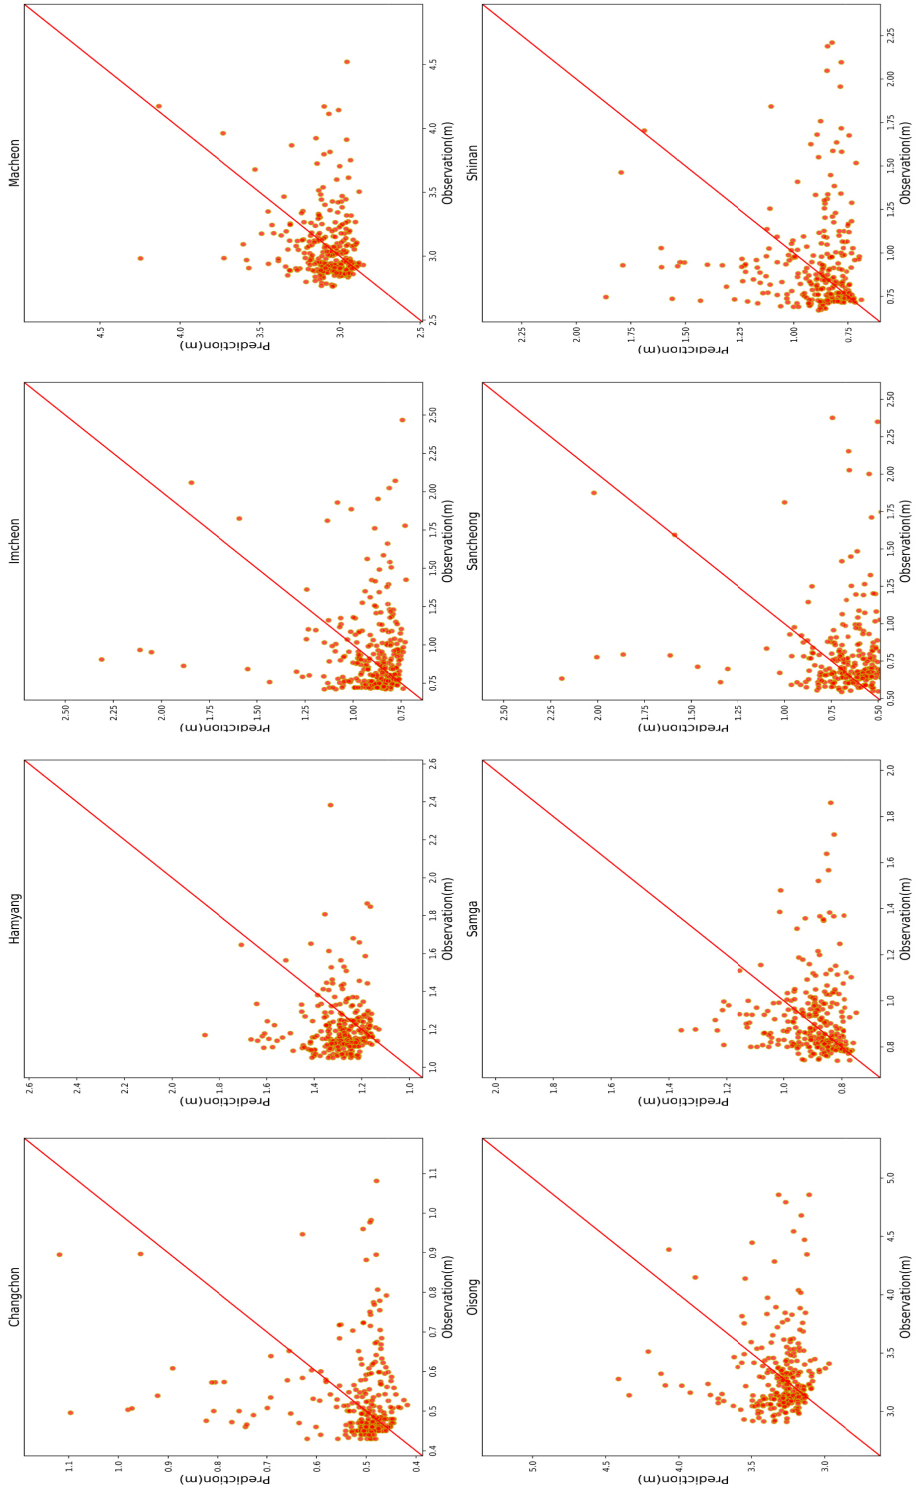
C-3-10. Comparison of scatter plot of LSTM 3 day prediction using 40 day interval S2S vs. measured water elevation data



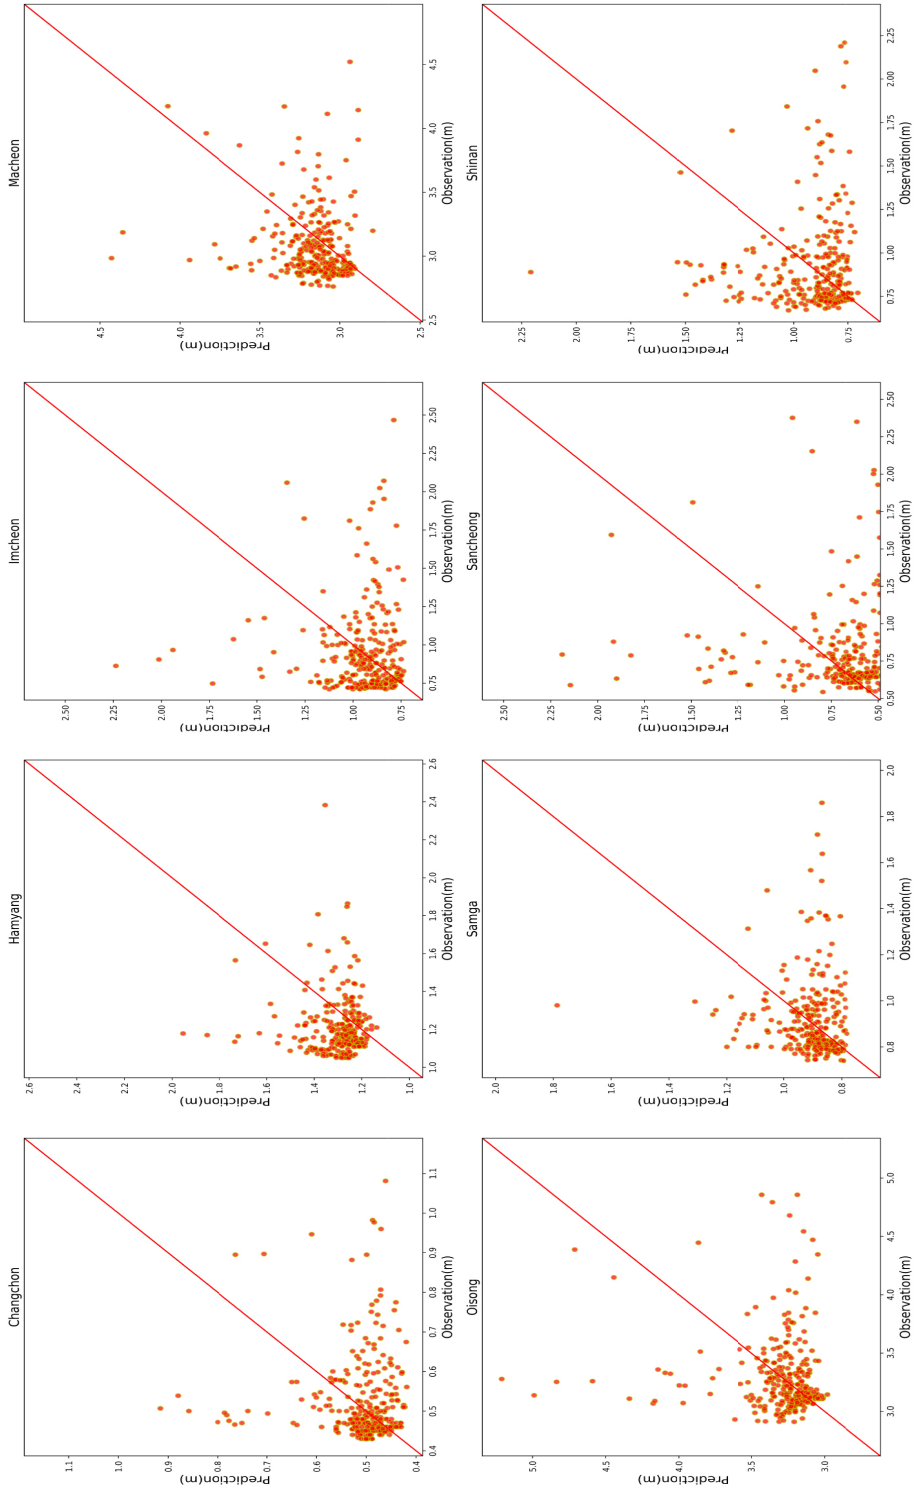
C-3-11. Comparison of scatter plot of LSTM 4 day prediction using 40 day interval S2S vs. measured water elevation data



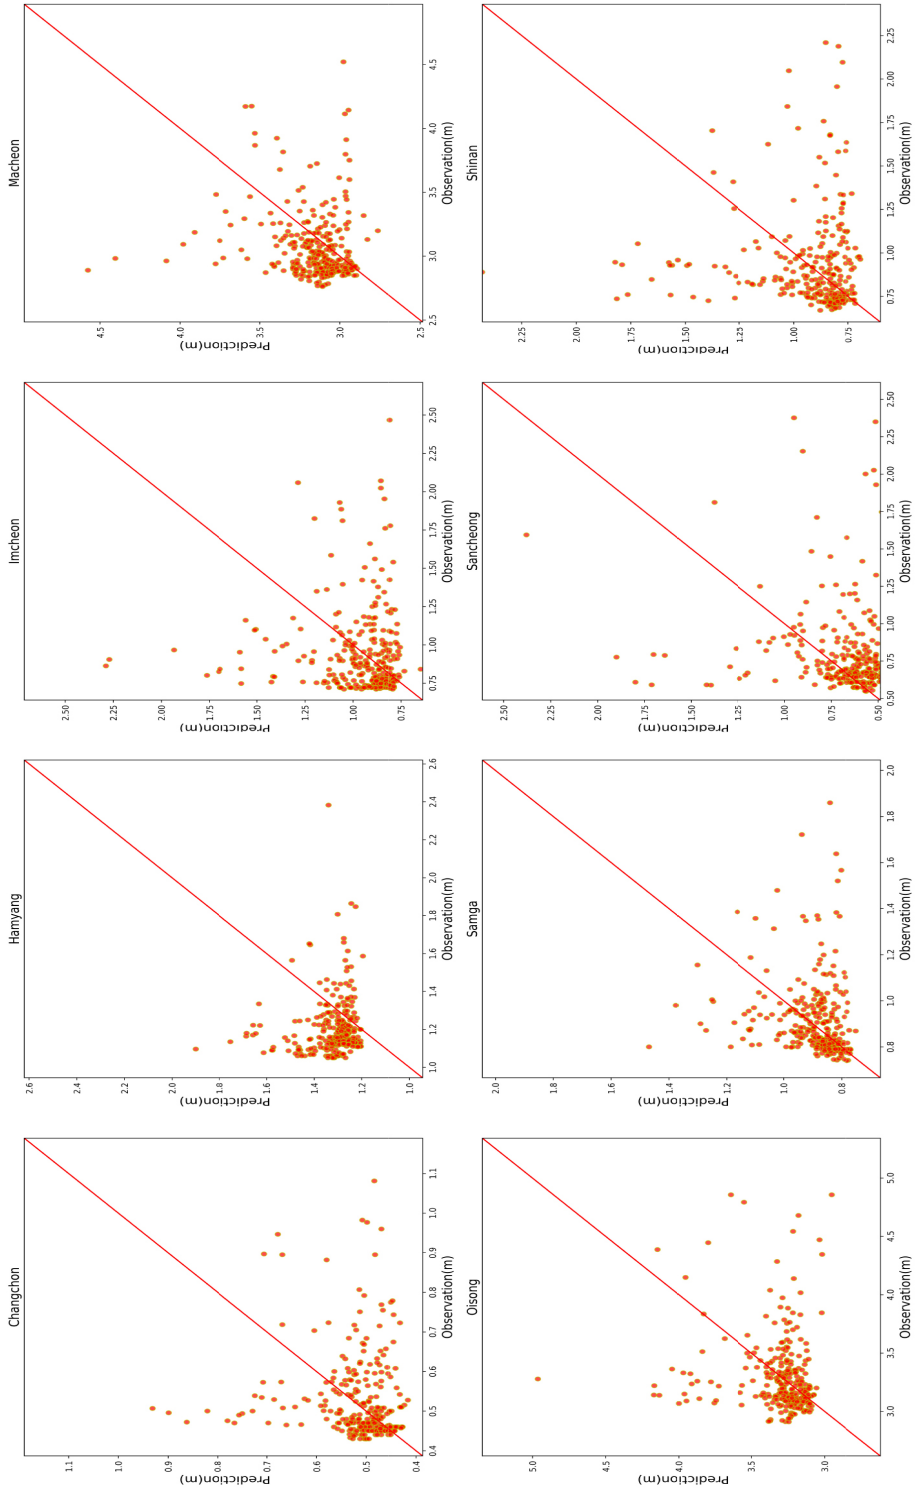
C-3-12. Comparison of scatter plot of LSTM 5 day prediction using 40 day interval S2S vs. measured water elevation data



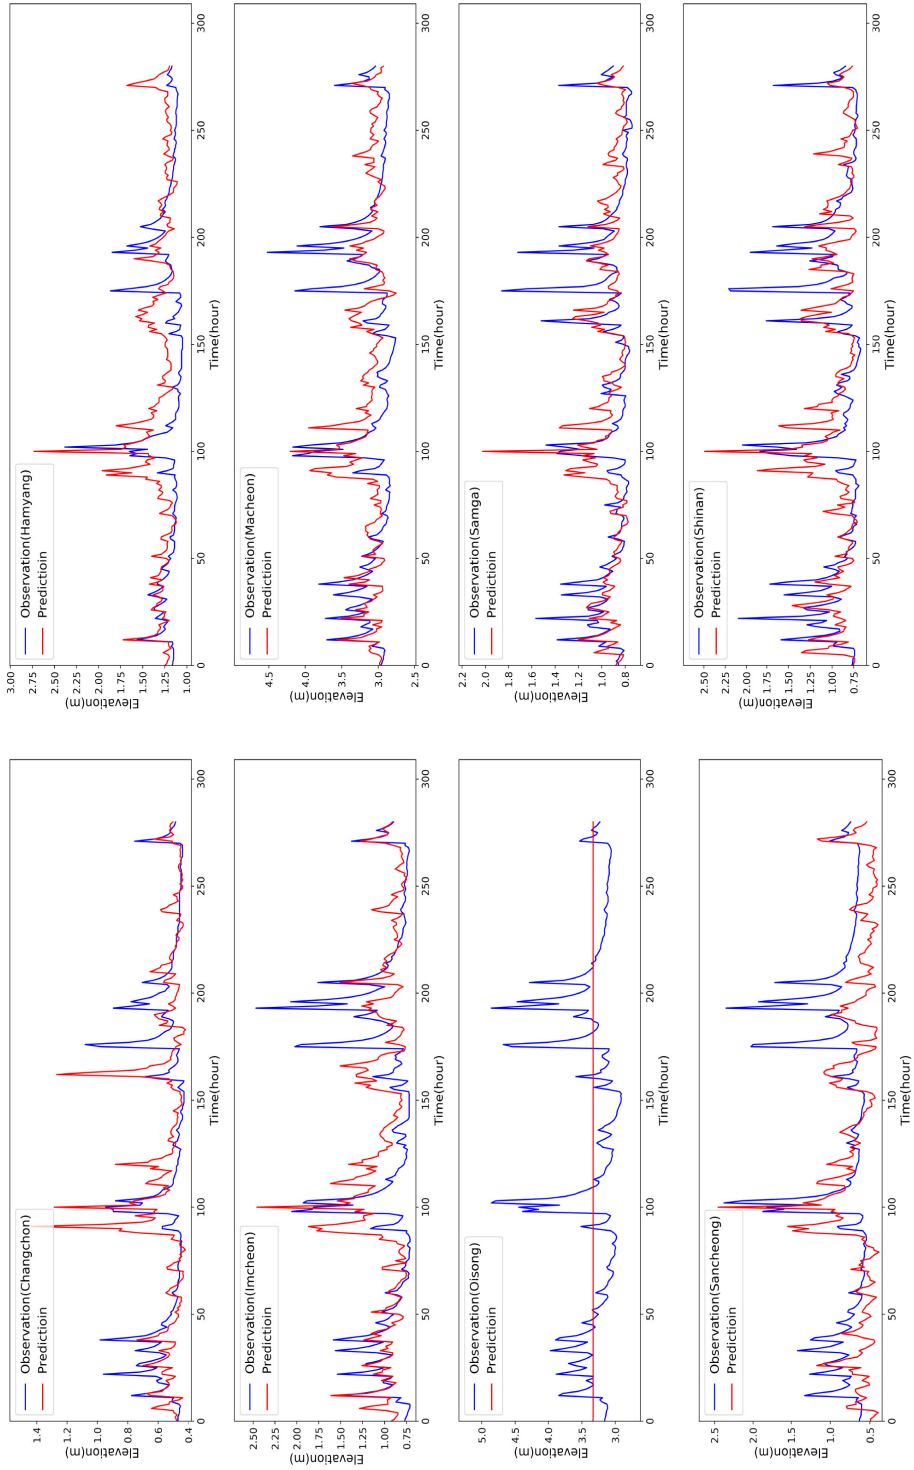
C-3-13. Comparison of scatter plot of LSTM 6 day prediction using 40 day interval S2S vs. measured water elevation data



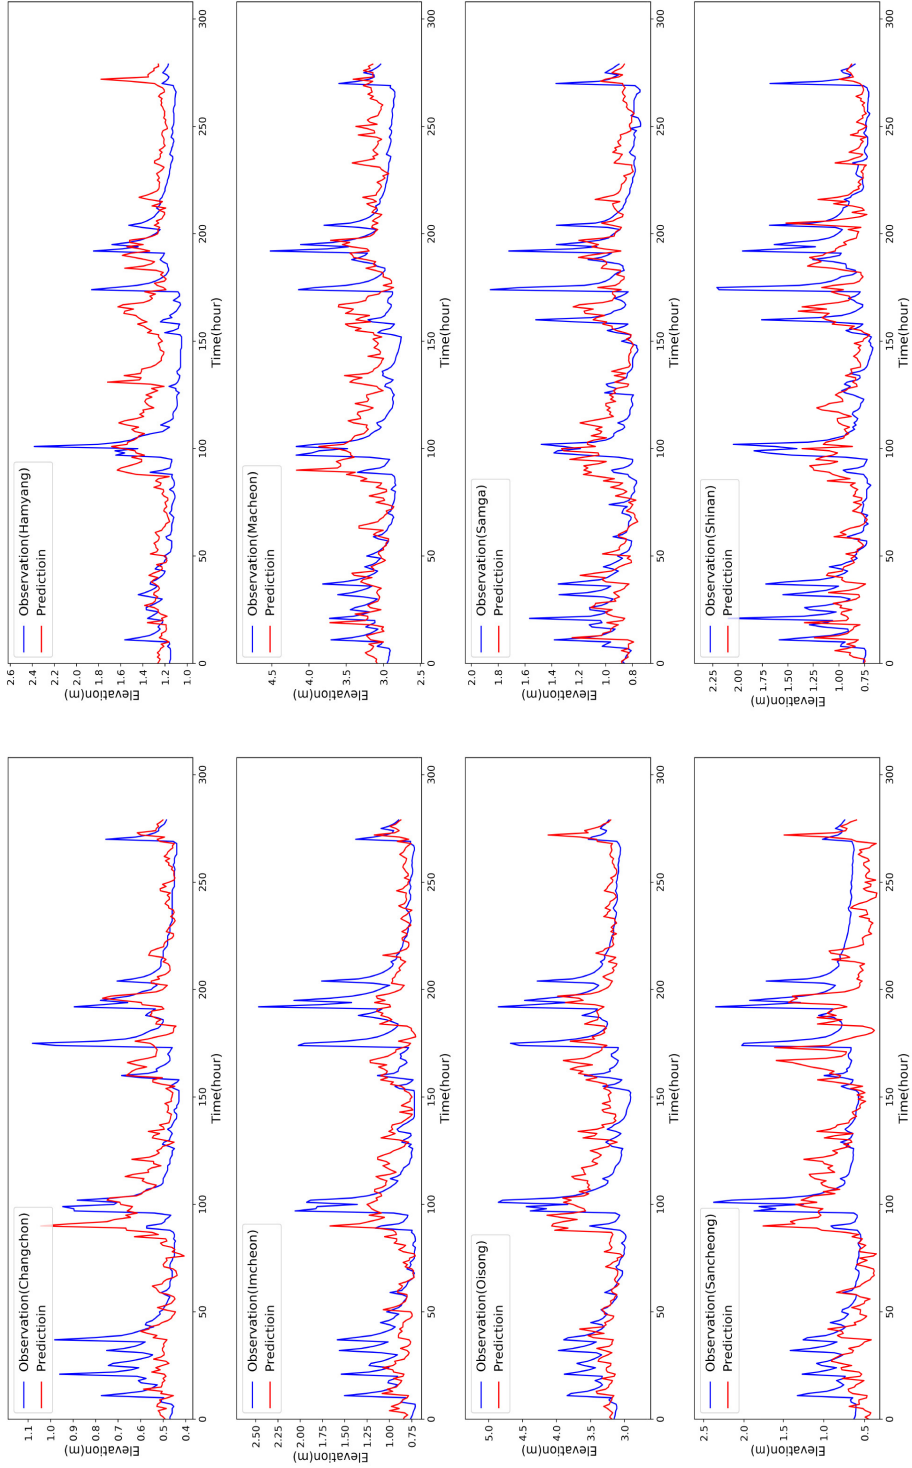
C-3-14. Comparison of scatter plot of LSTM 7 day prediction using 40 day interval S2S vs. measured water elevation data



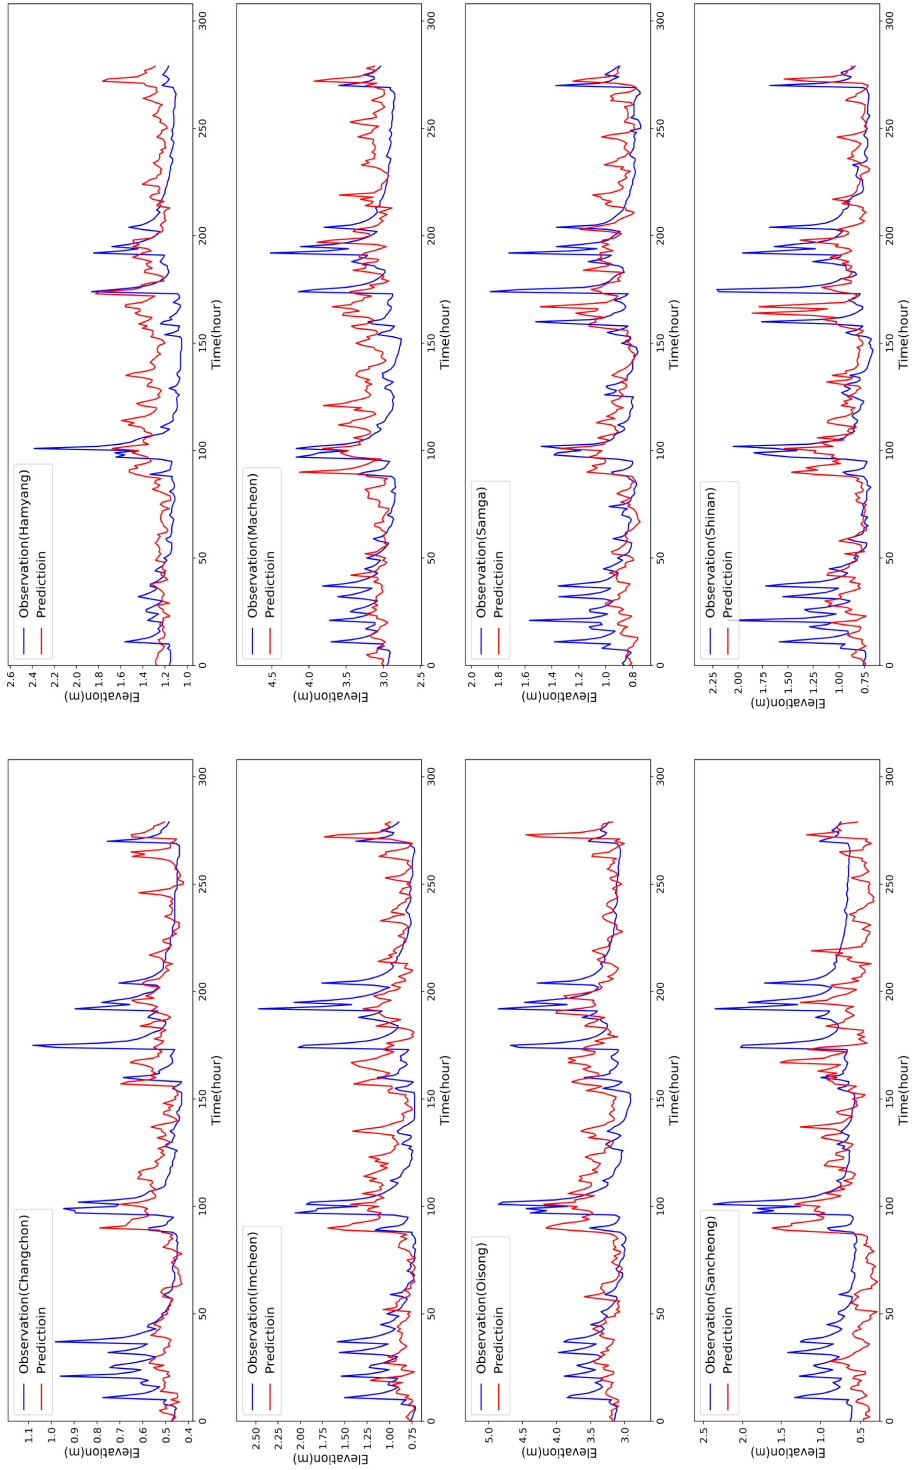
C-4-1. Comparison of 1 day prediction using 7 day interval S2S vs. measured water elevation data



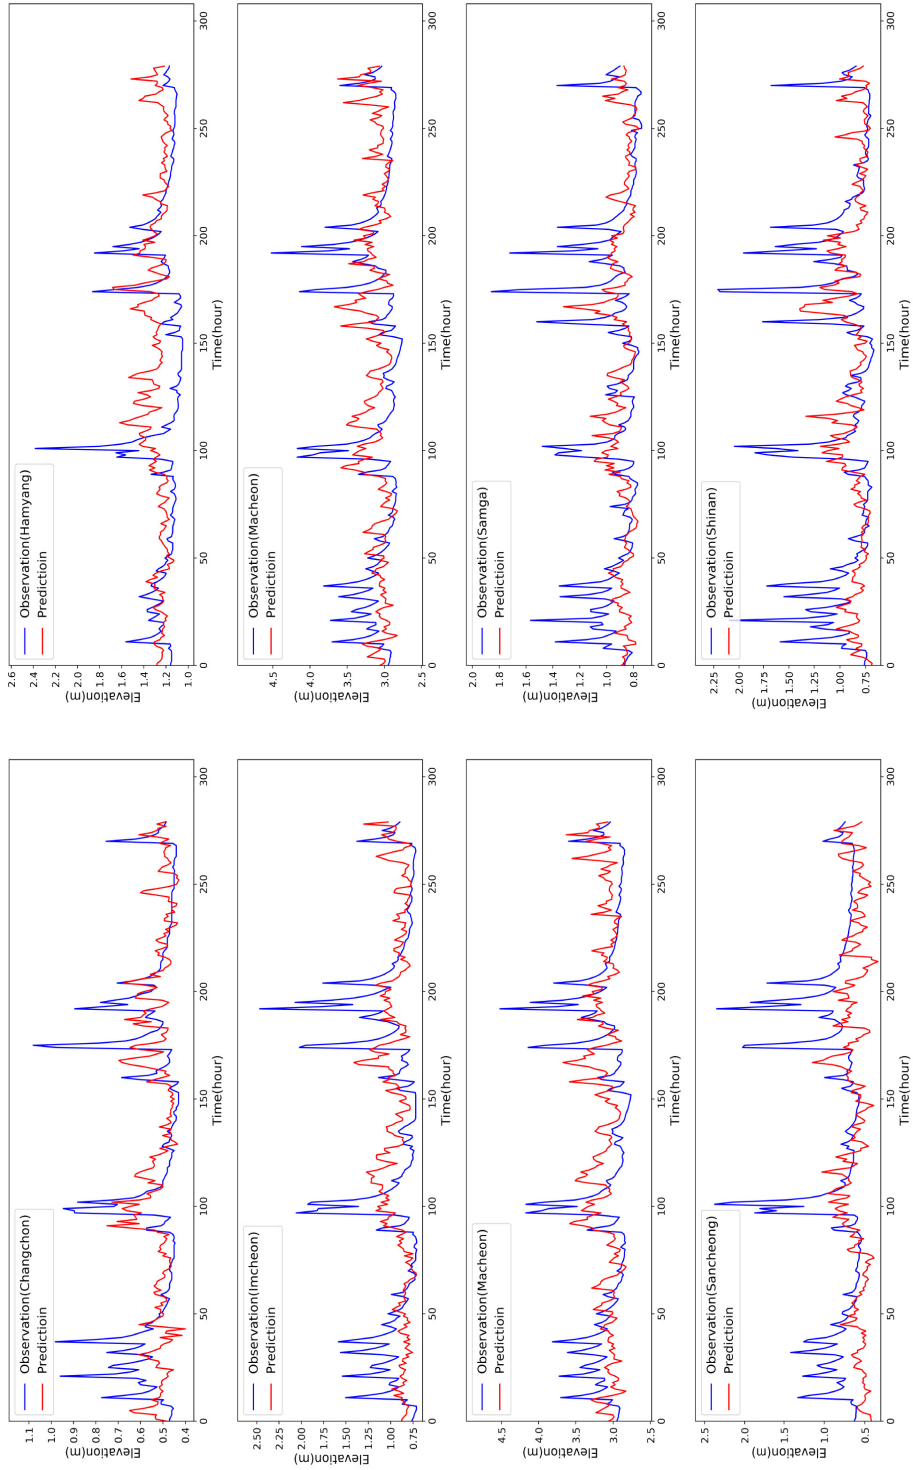
C-4-2. Comparison of 2 day prediction using 7 day interval S2S vs. measured water elevation data



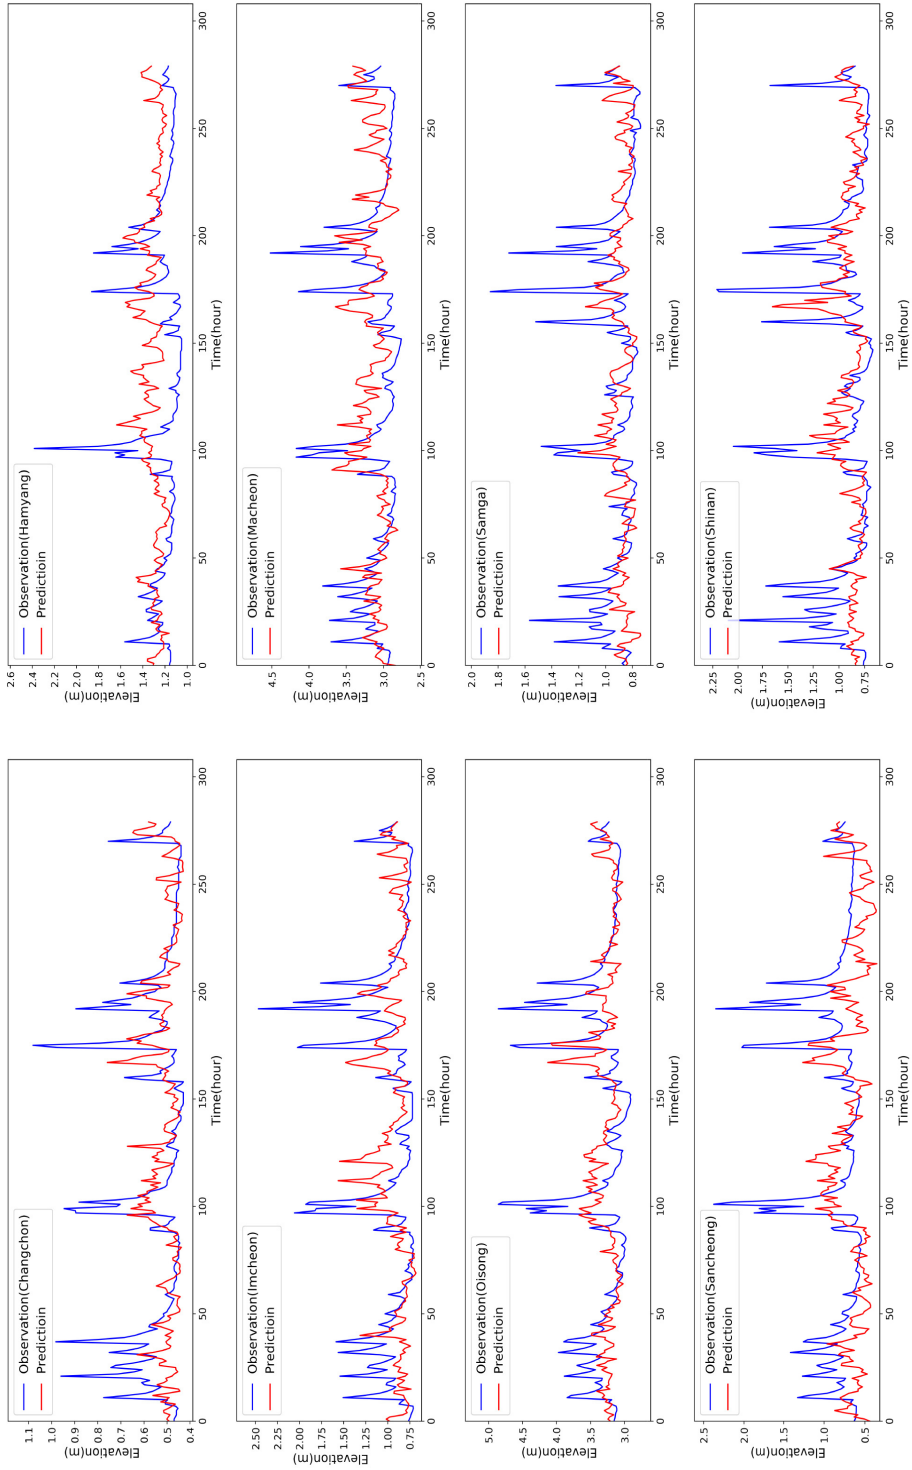
C-4-3. Comparison of 3 day prediction using 7 day interval S2S vs. measured water elevation data



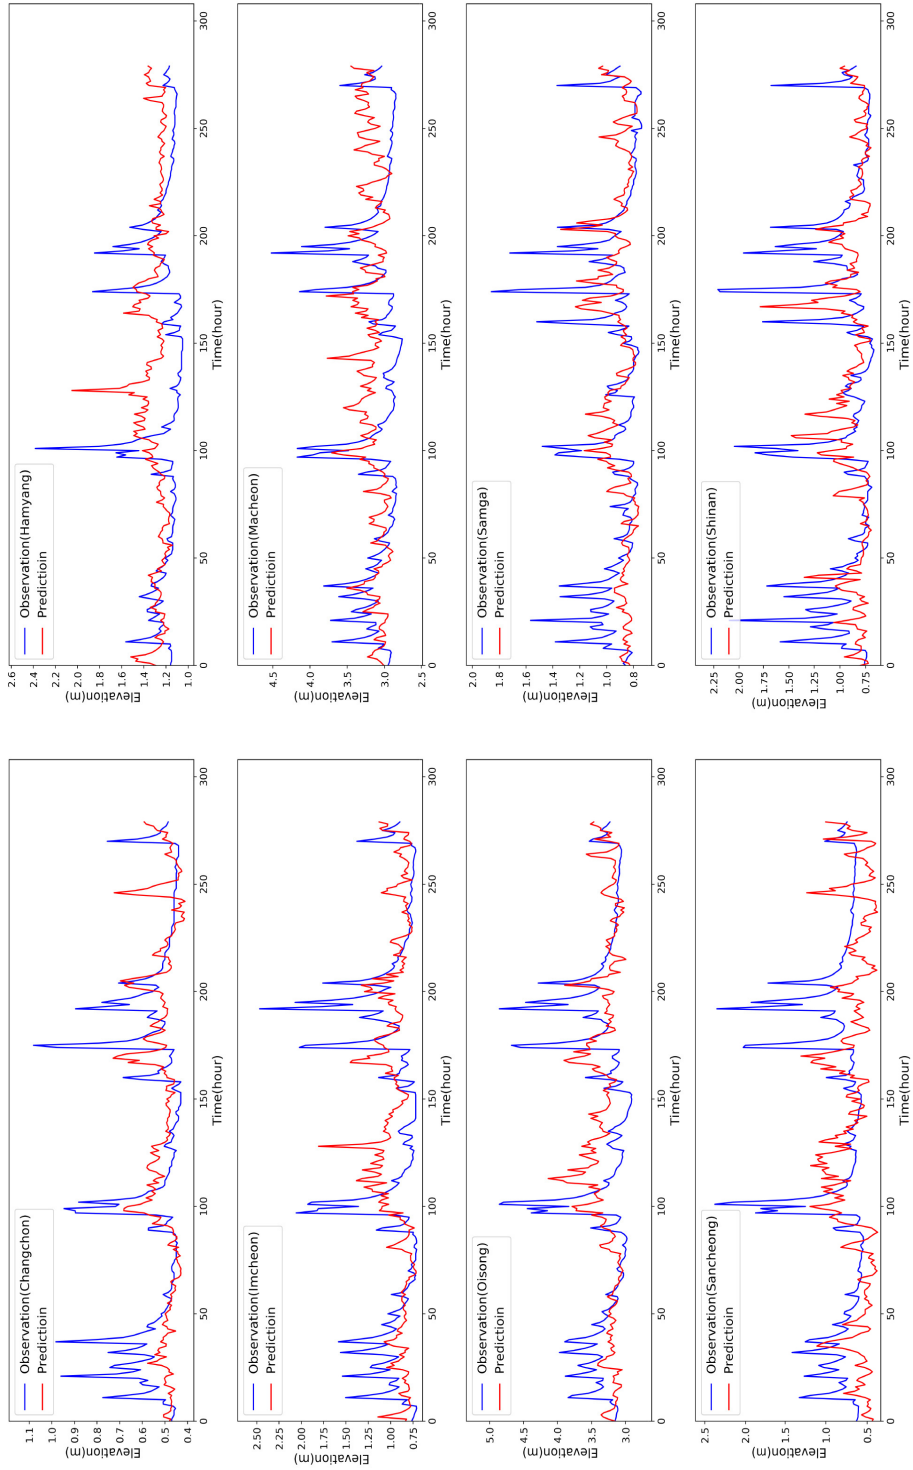
C-4-4. Comparison of 4 day prediction using 7 day interval S2S vs. measured water elevation data



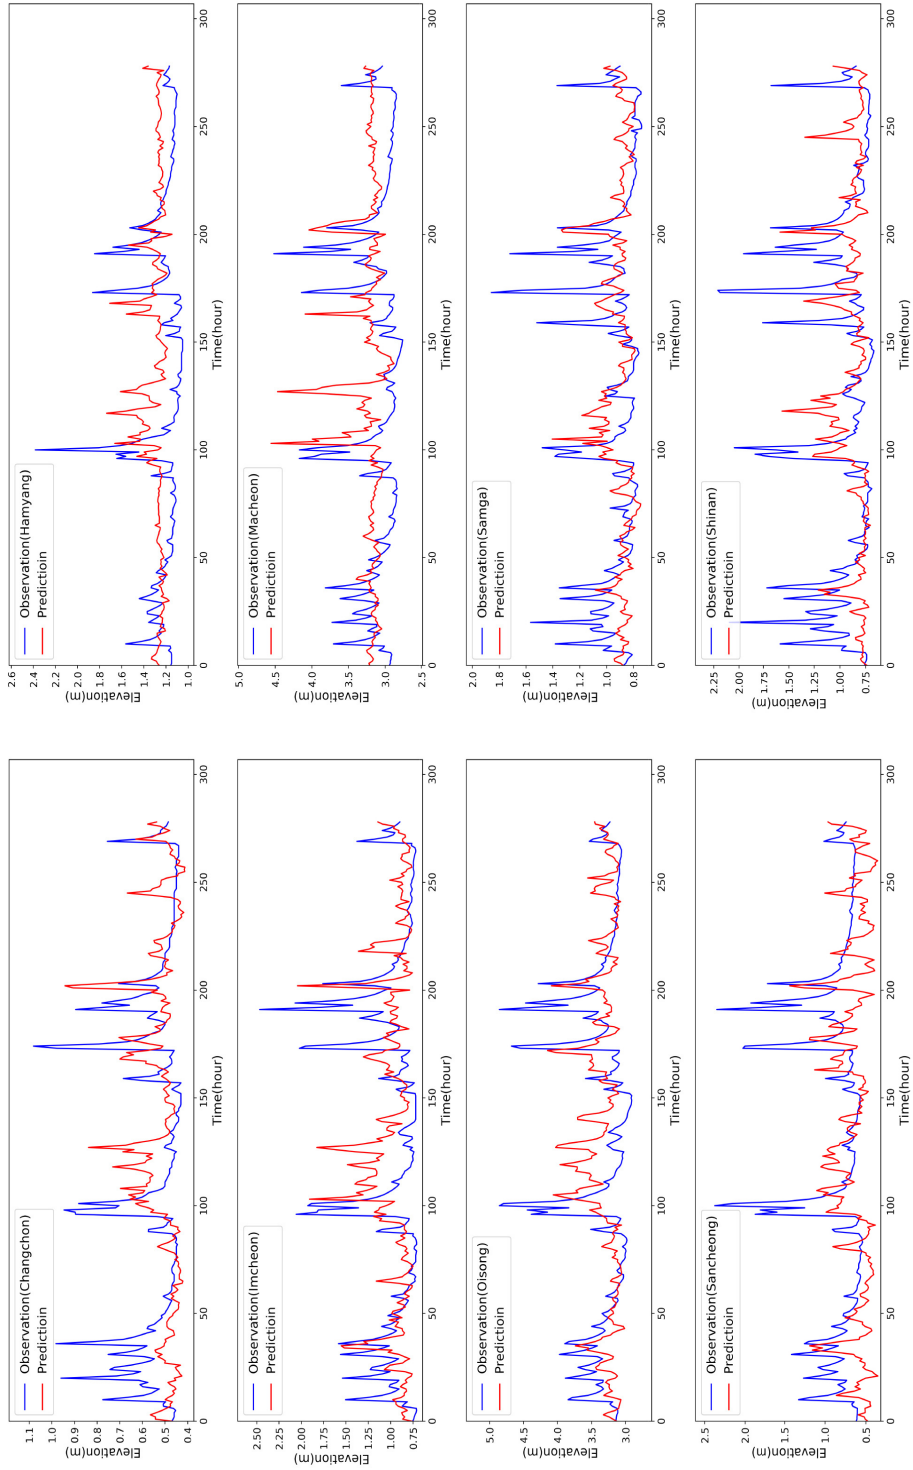
C-4-5. Comparison of 5 day prediction using 7 day interval S2S vs. measured water elevation data



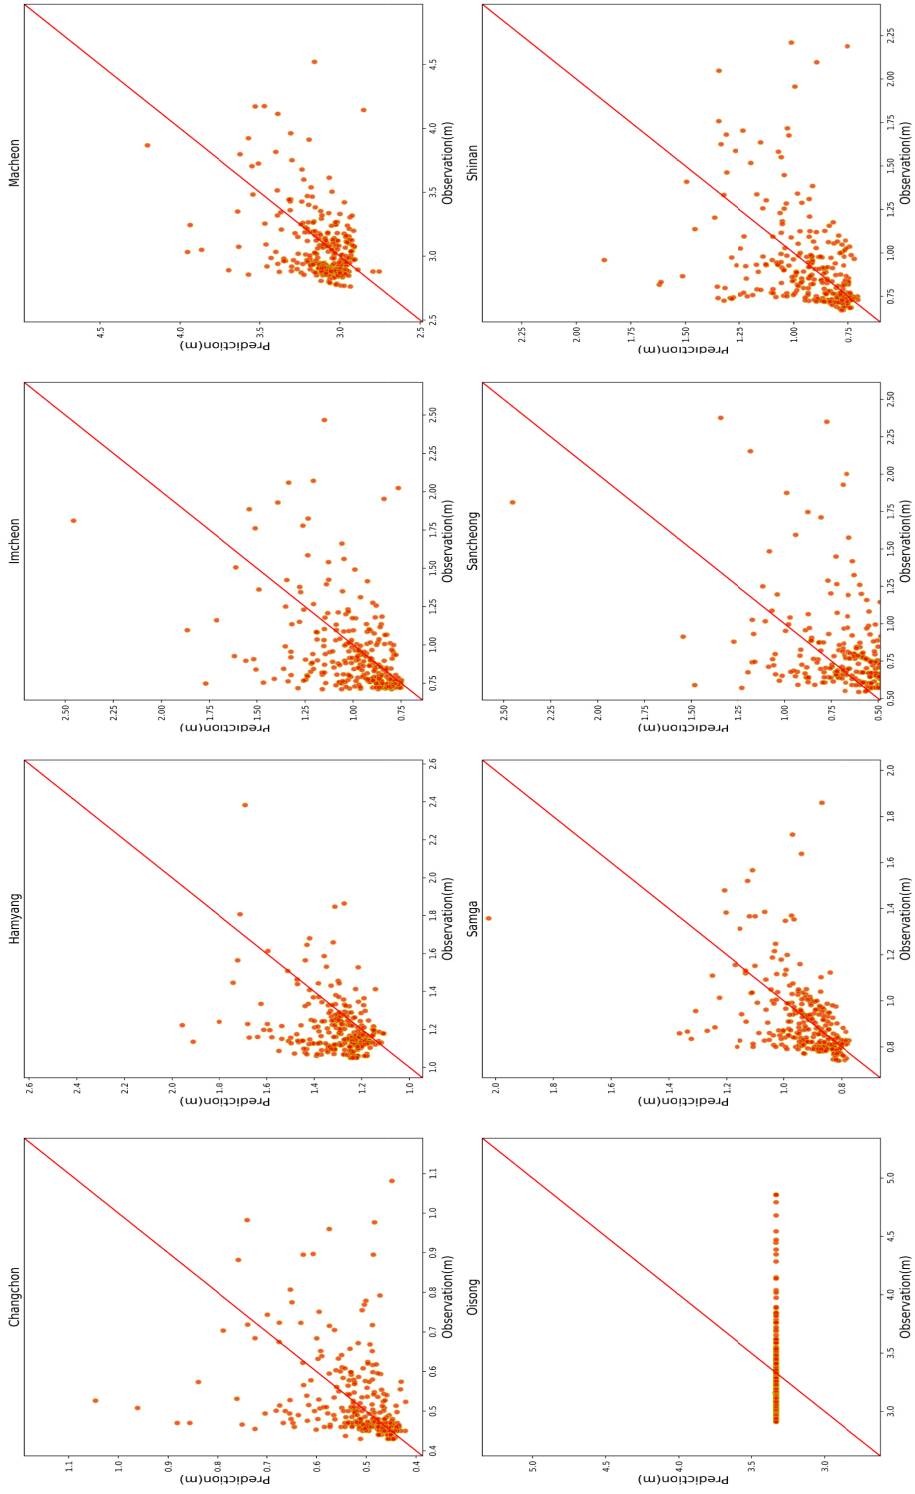
C-4-6. Comparison of 6 day prediction using 7 day interval S2S vs. measured water elevation data



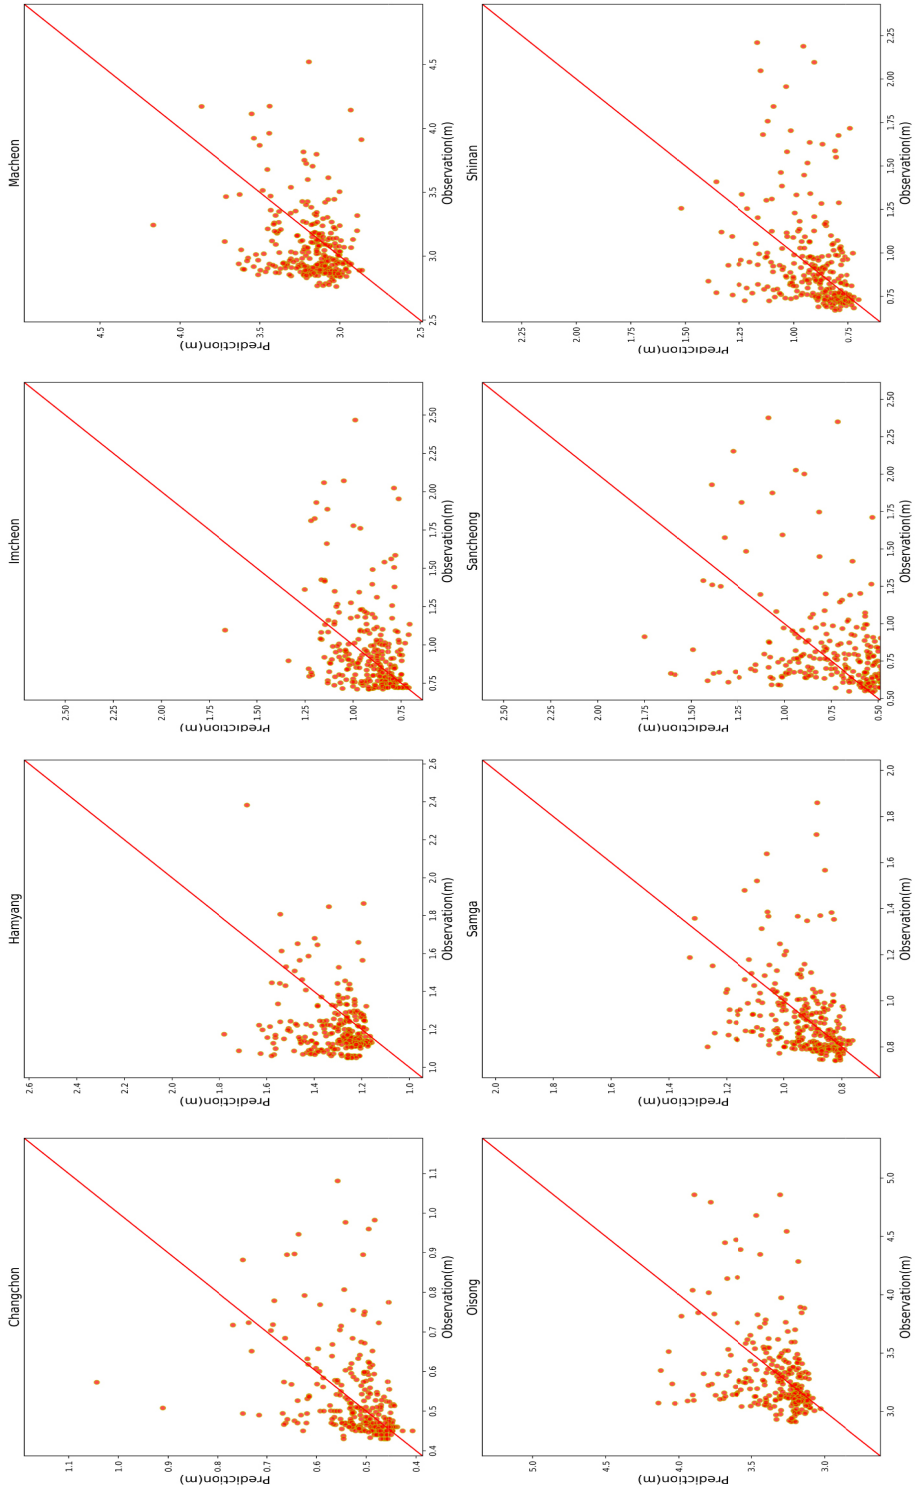
C-4-7. Comparison of 7 day prediction using 7 day interval S2S vs. measured water elevation data



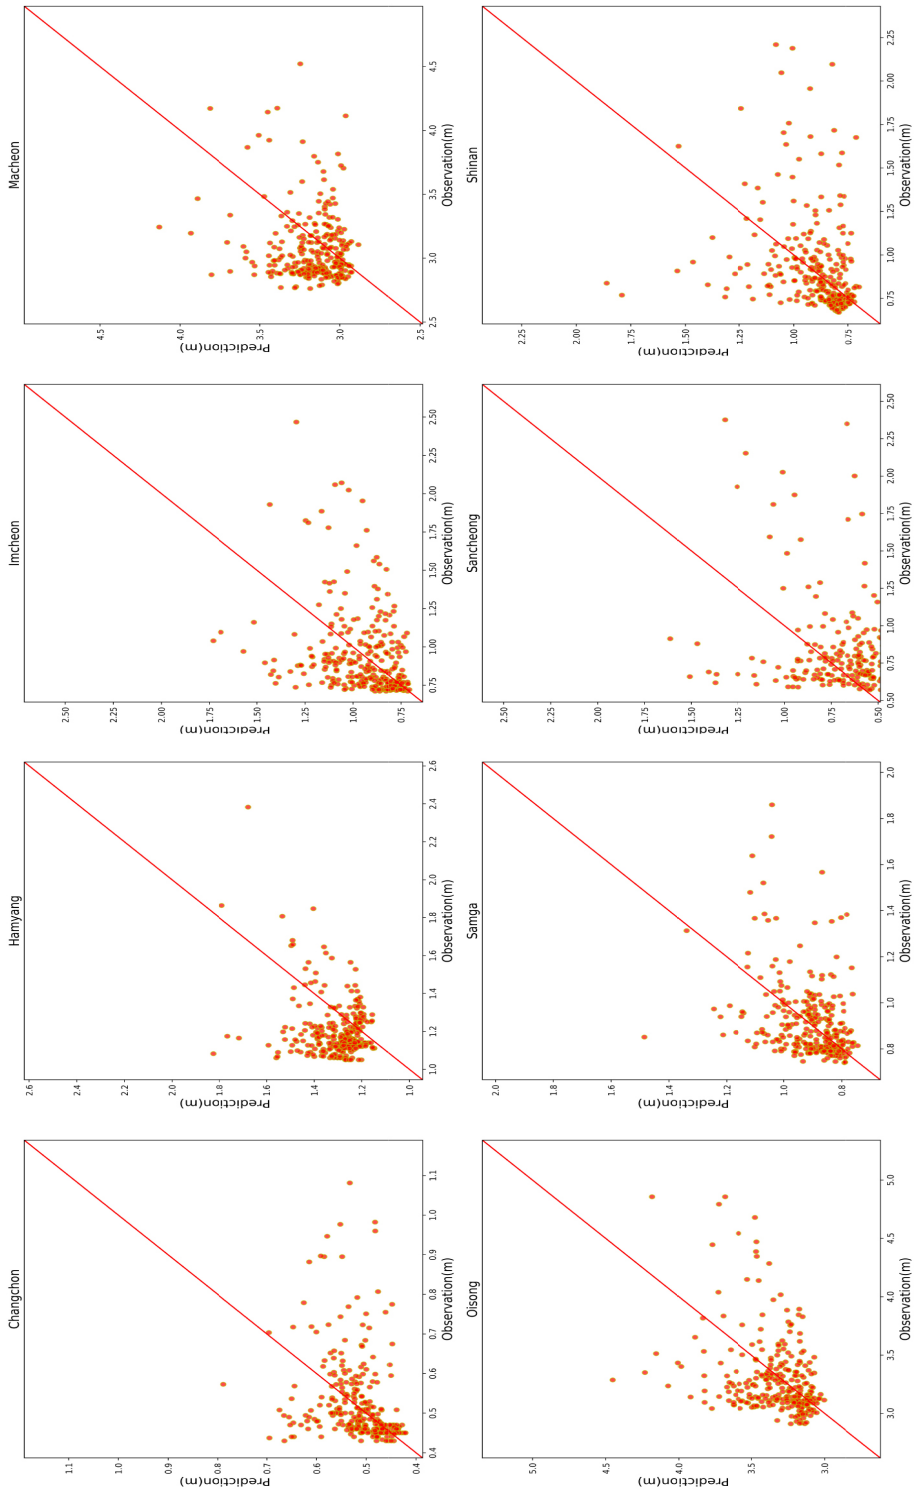
C-4-8. Comparison of scatter plot of LSTM 1 day prediction using 7 day interval S2S vs. measured water elevation data



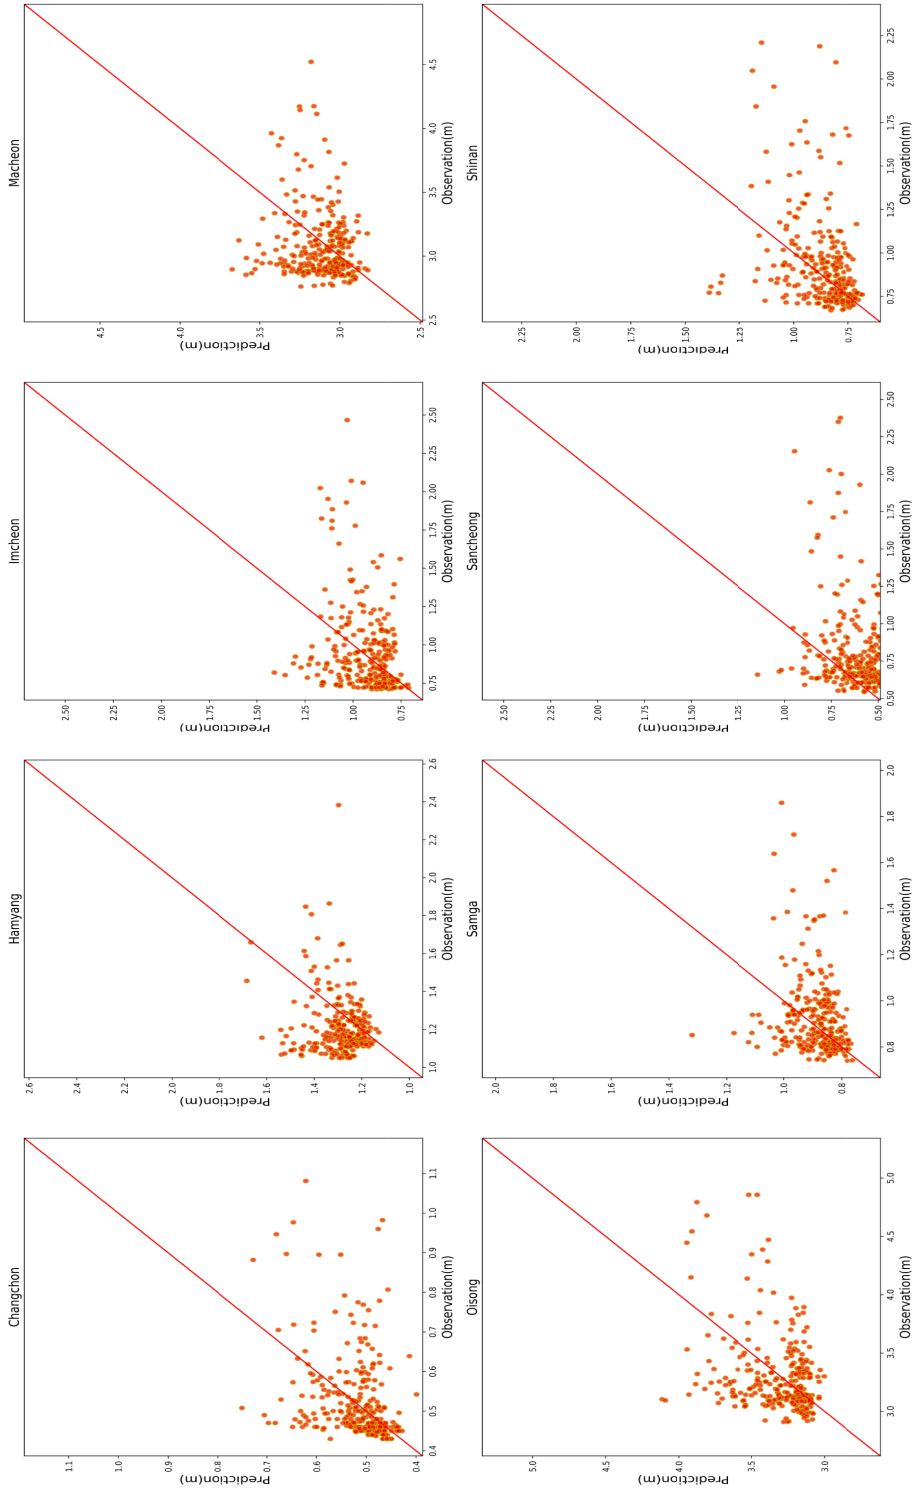
C-4-9. Comparison of scatter plot of LSTM 2 day prediction using 7 day interval S2S vs. measured water elevation data



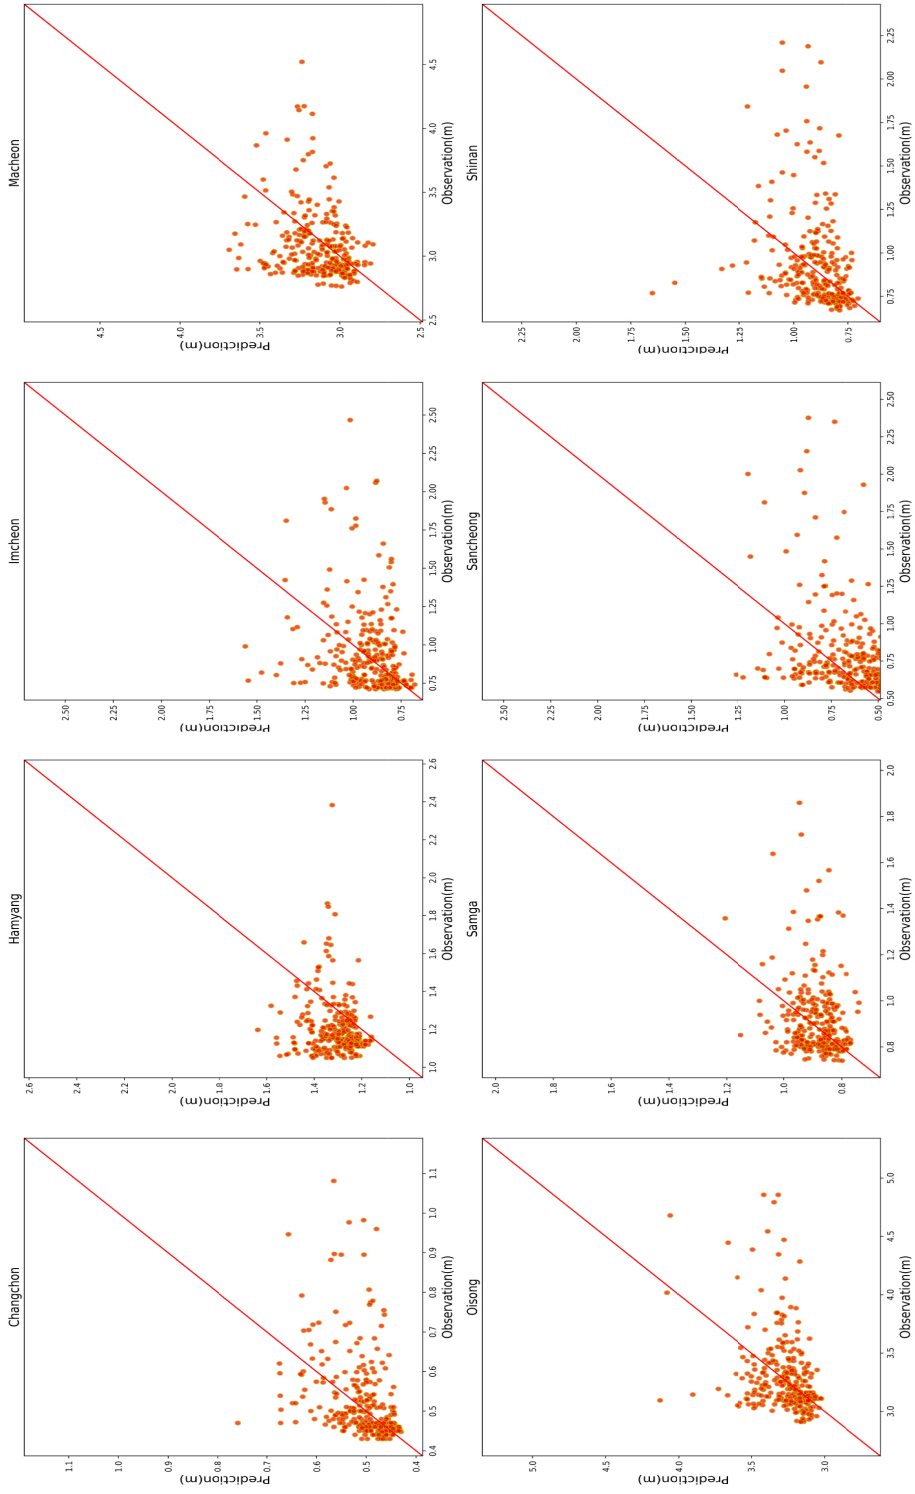
C-4-10. Comparison of scatter plot of LSTM 3 day prediction using 7 day interval S2S vs. measured water elevation data



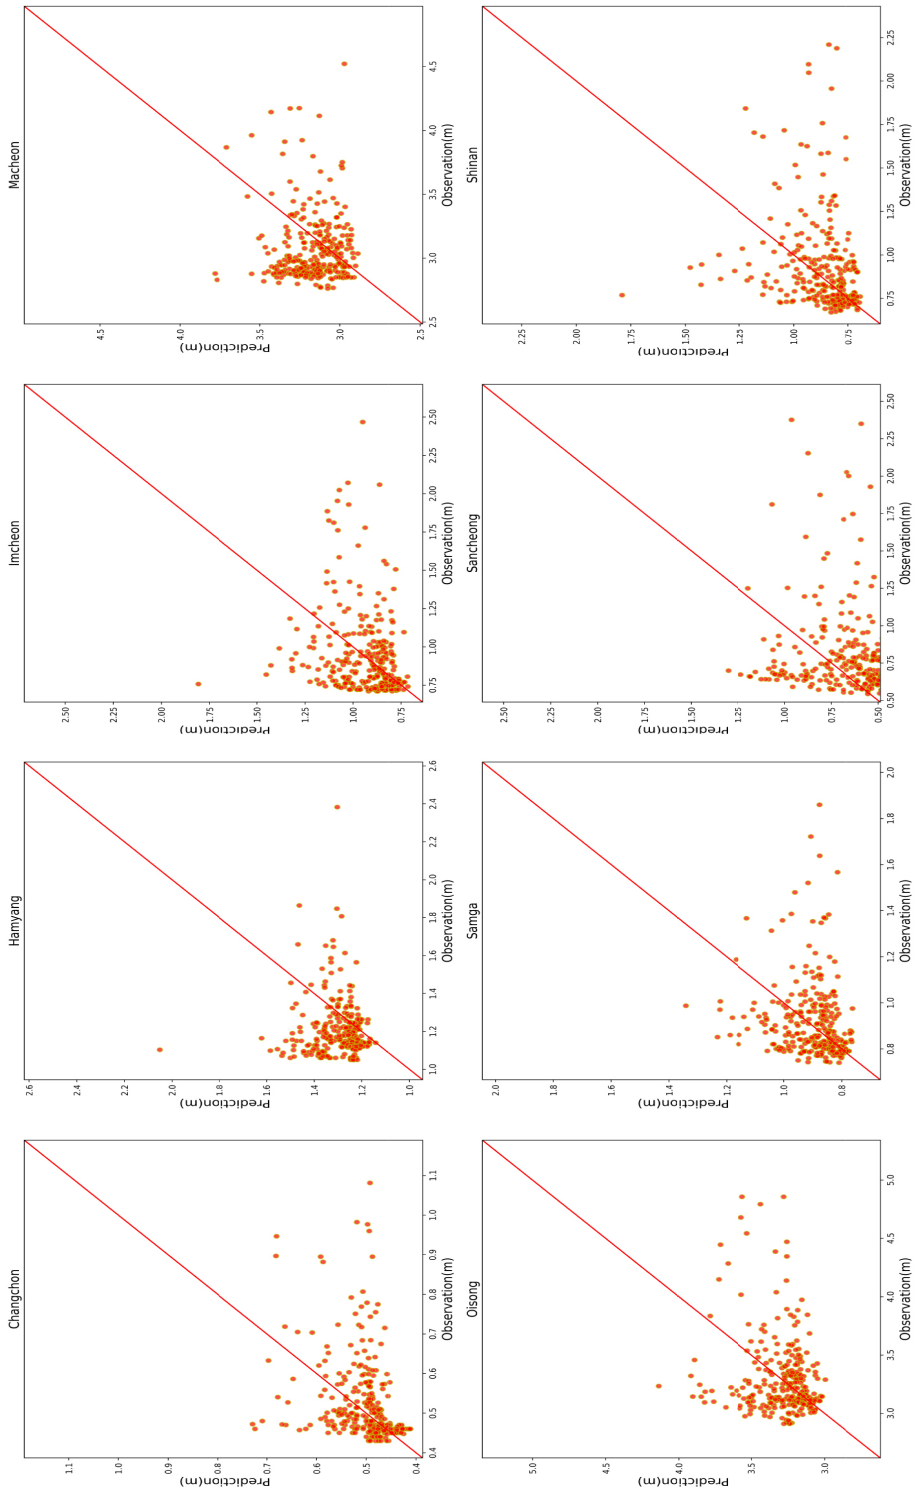
C-4-11. Comparison of scatter plot of LSTM 4 day prediction using 7 day interval S2S vs. measured water elevation data



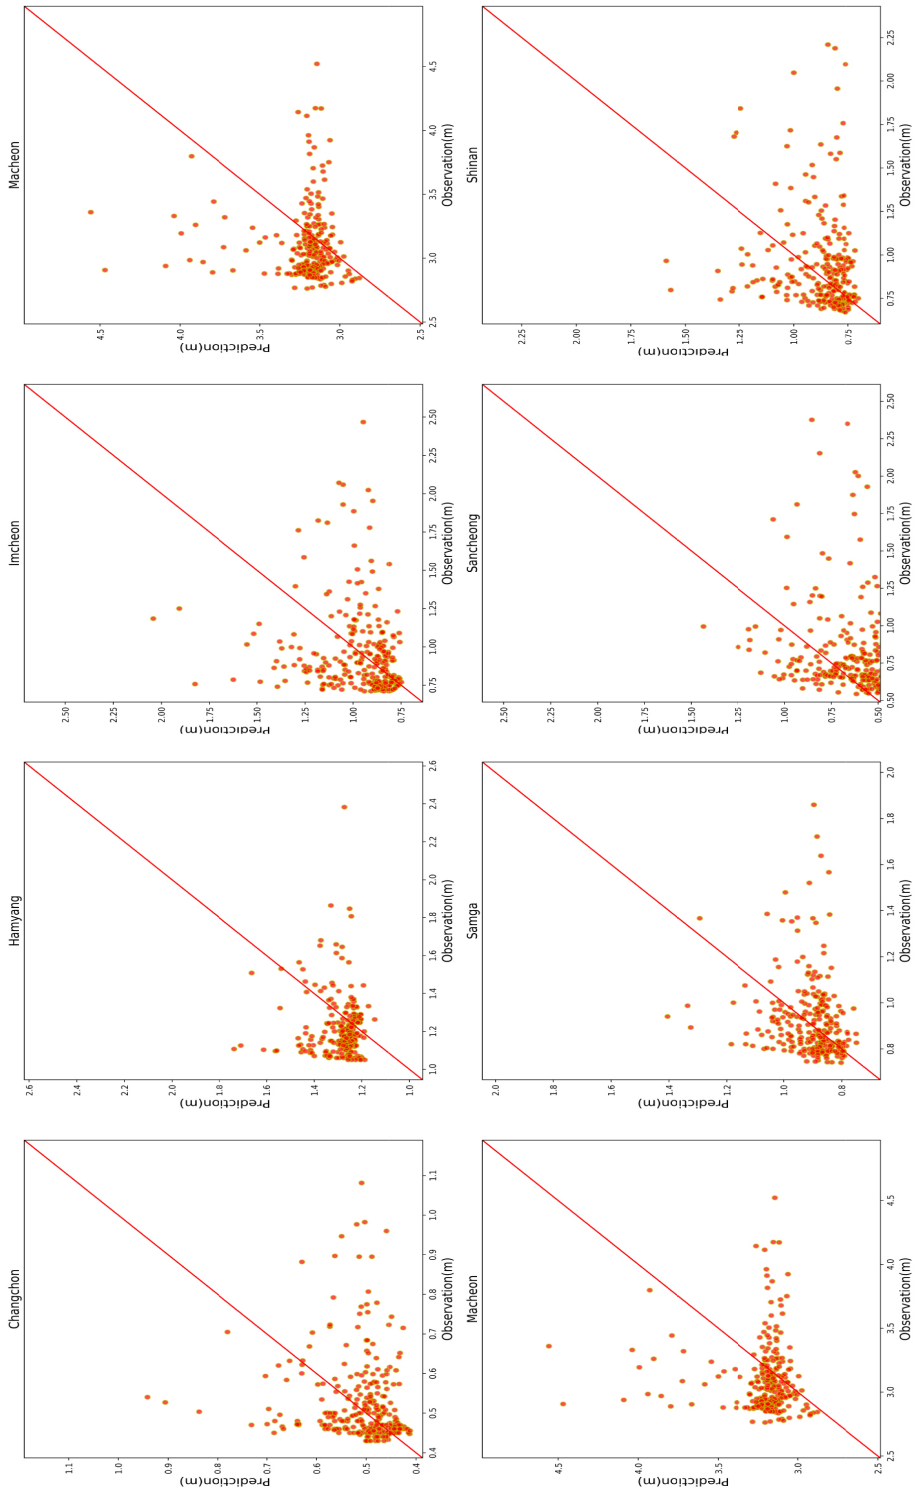
C-4-12. Comparison of scatter plot of LSTM 5 day prediction using 7 day interval S2S vs. measured water elevation data



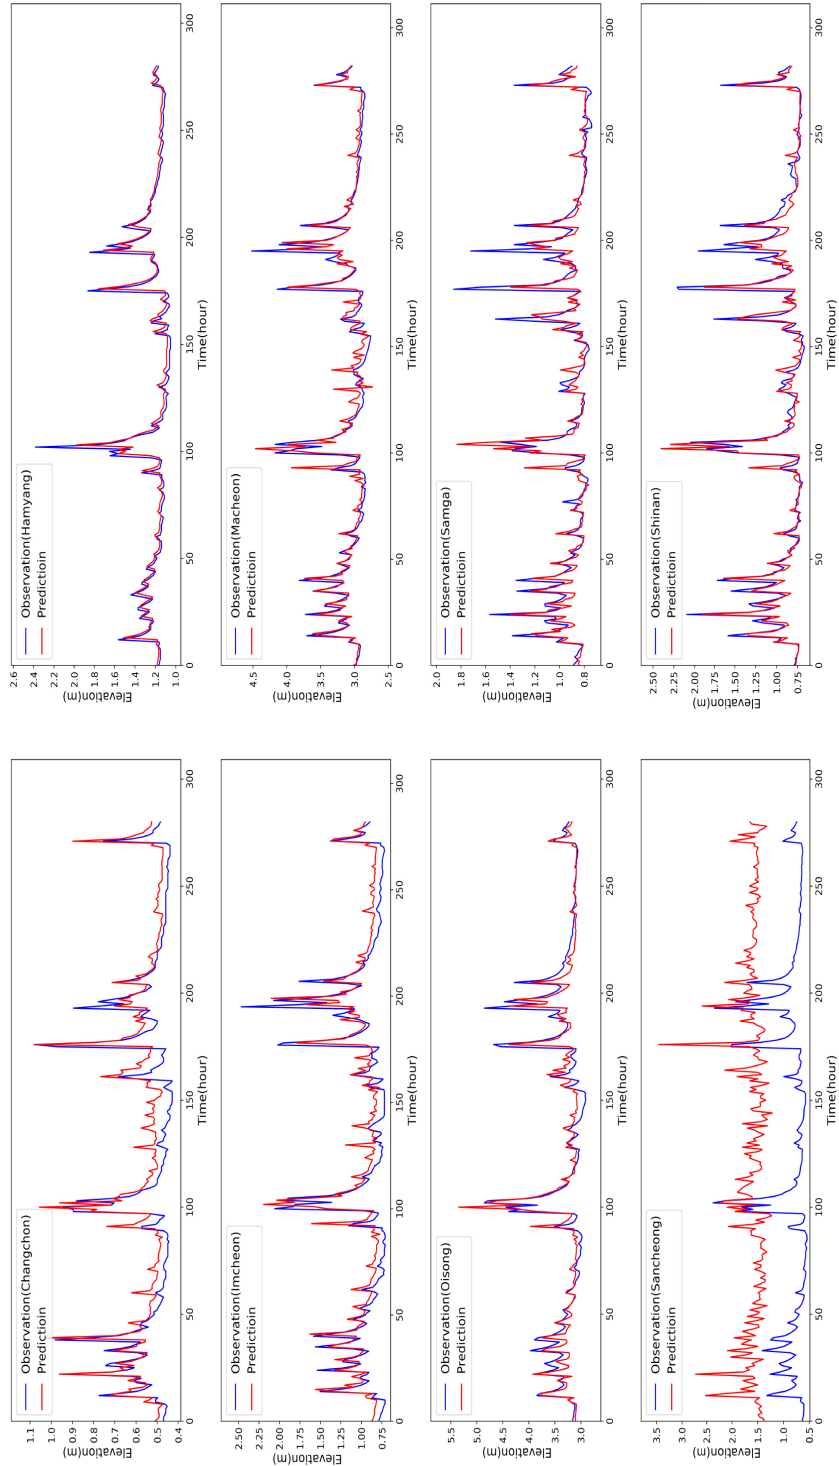
C-4-13. Comparison of scatter plot of LSTM 6 day prediction using 7 day interval S2S vs. measured water elevation data



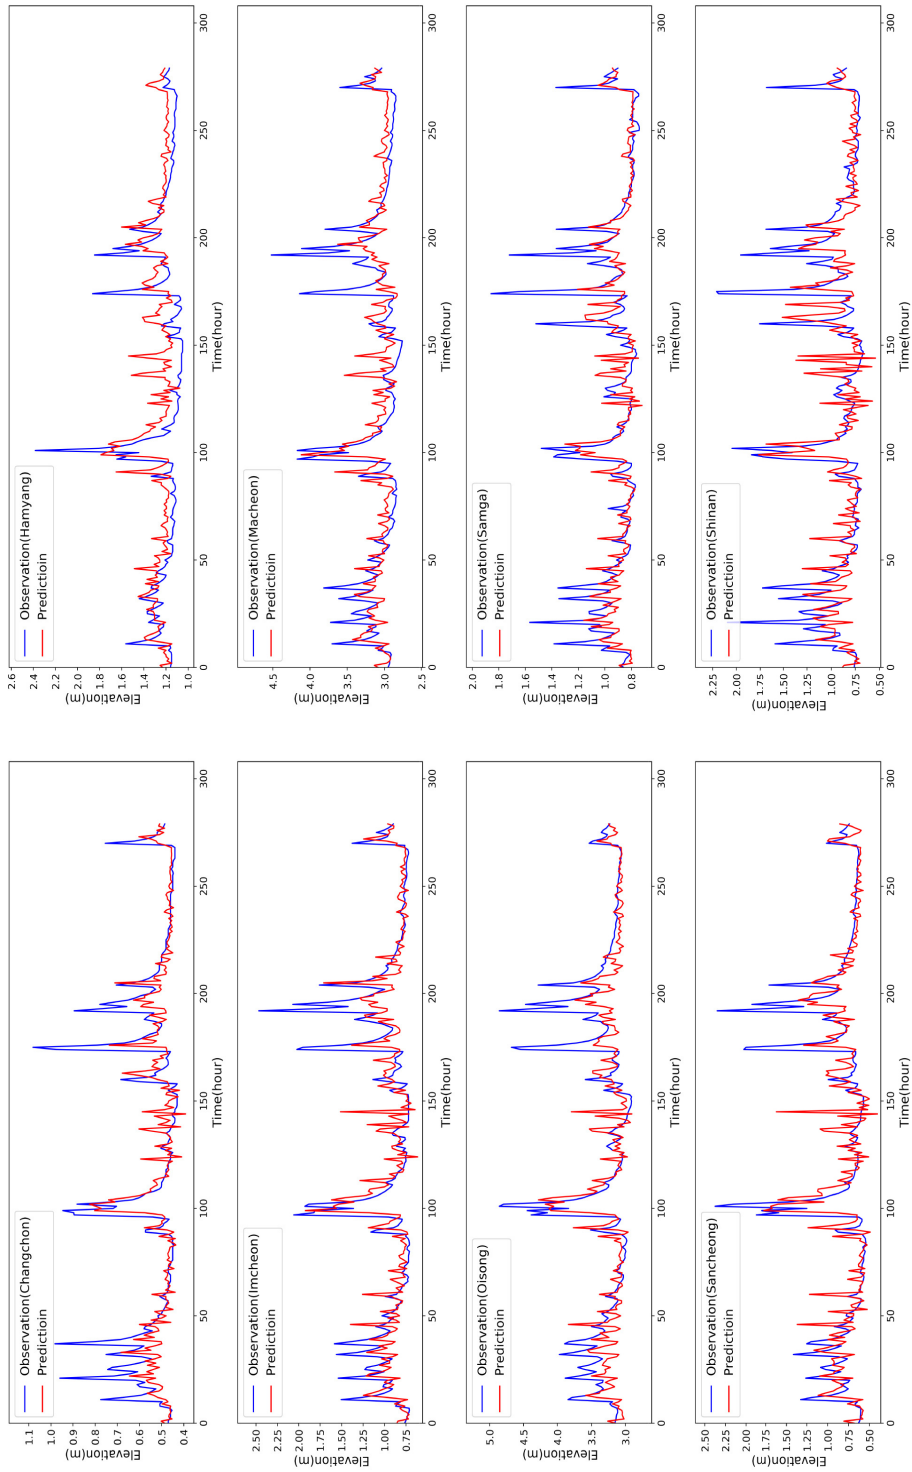
C-4-14. Comparison of scatter plot of LSTM 7 day prediction using S2S vs. measured water elevation data



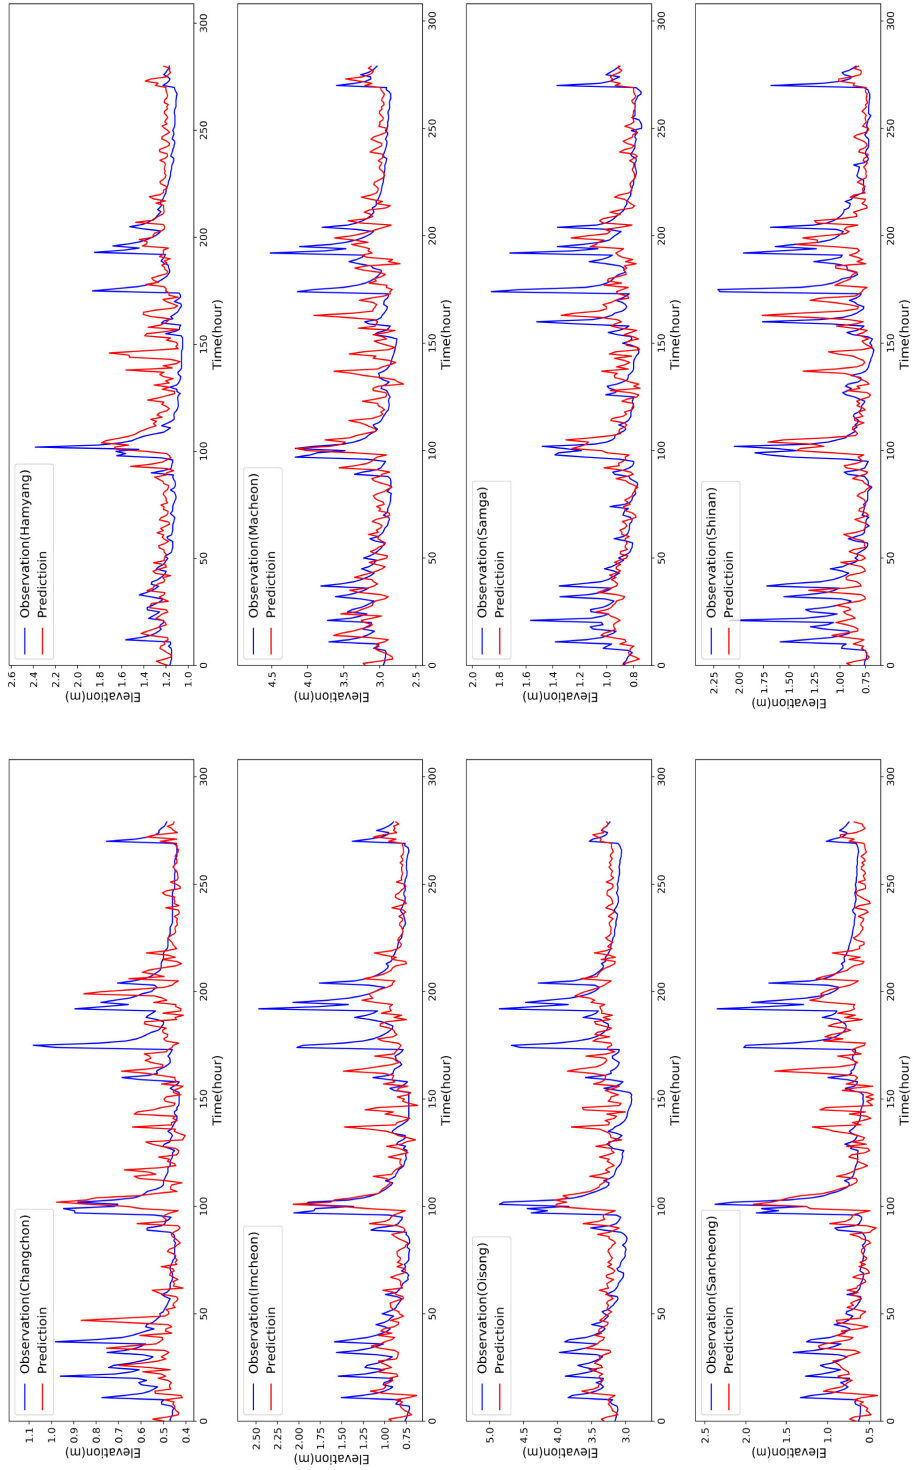
D-1-1. Comparison of 1 day prediction using rainfall with measured water elevation vs. measured water elevation data



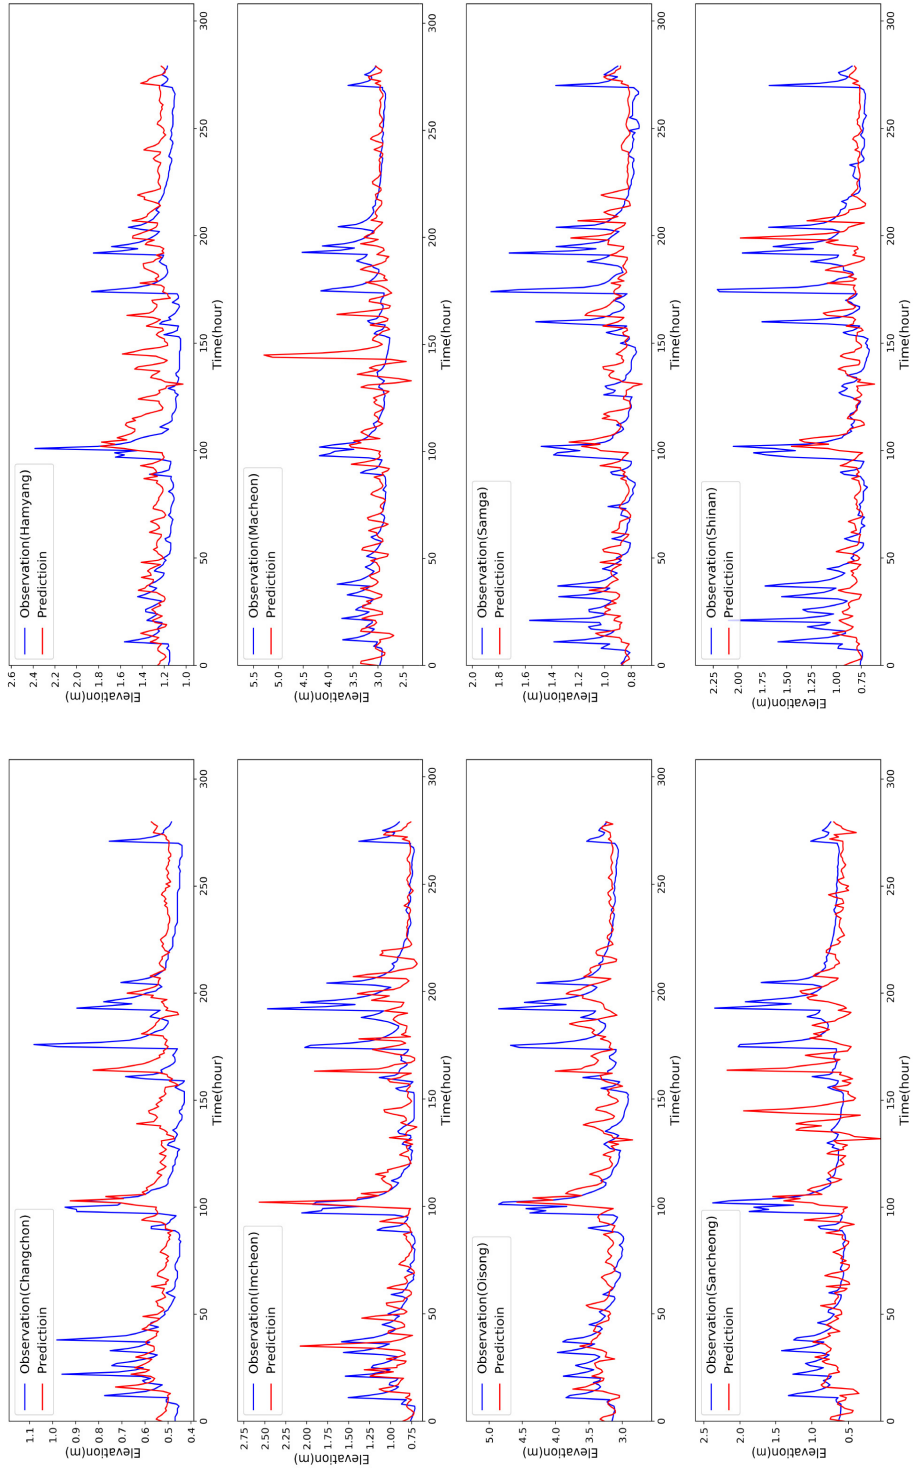
D-1-2. Comparison of 2 day prediction using rainfall with measured water elevation vs. measured water elevation data



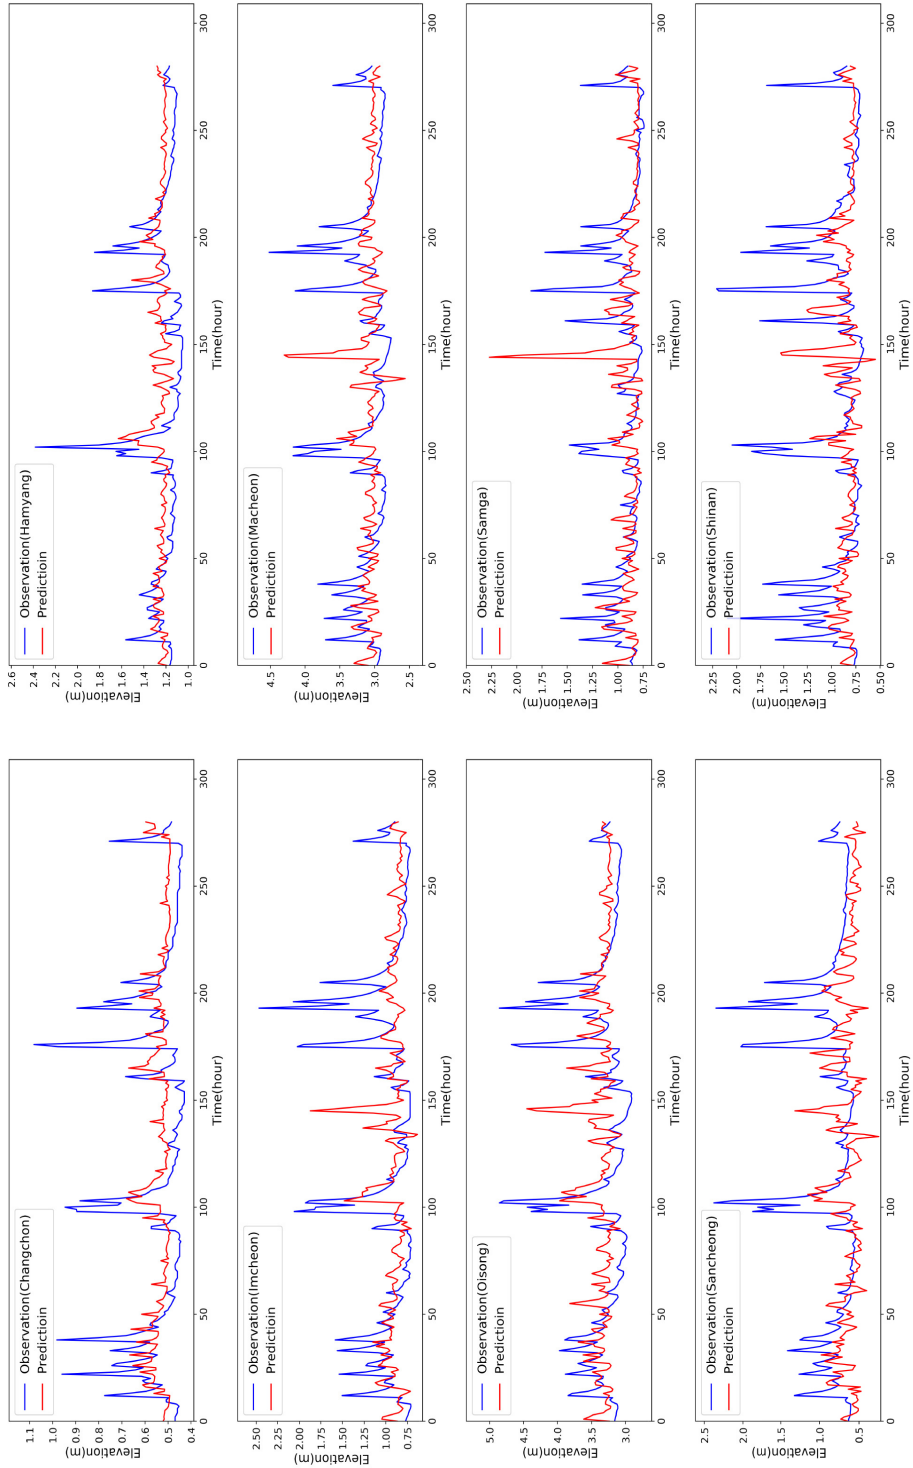
D-1-3. Comparison of 3 day prediction using rainfall with measured water elevation vs. measured water elevation data



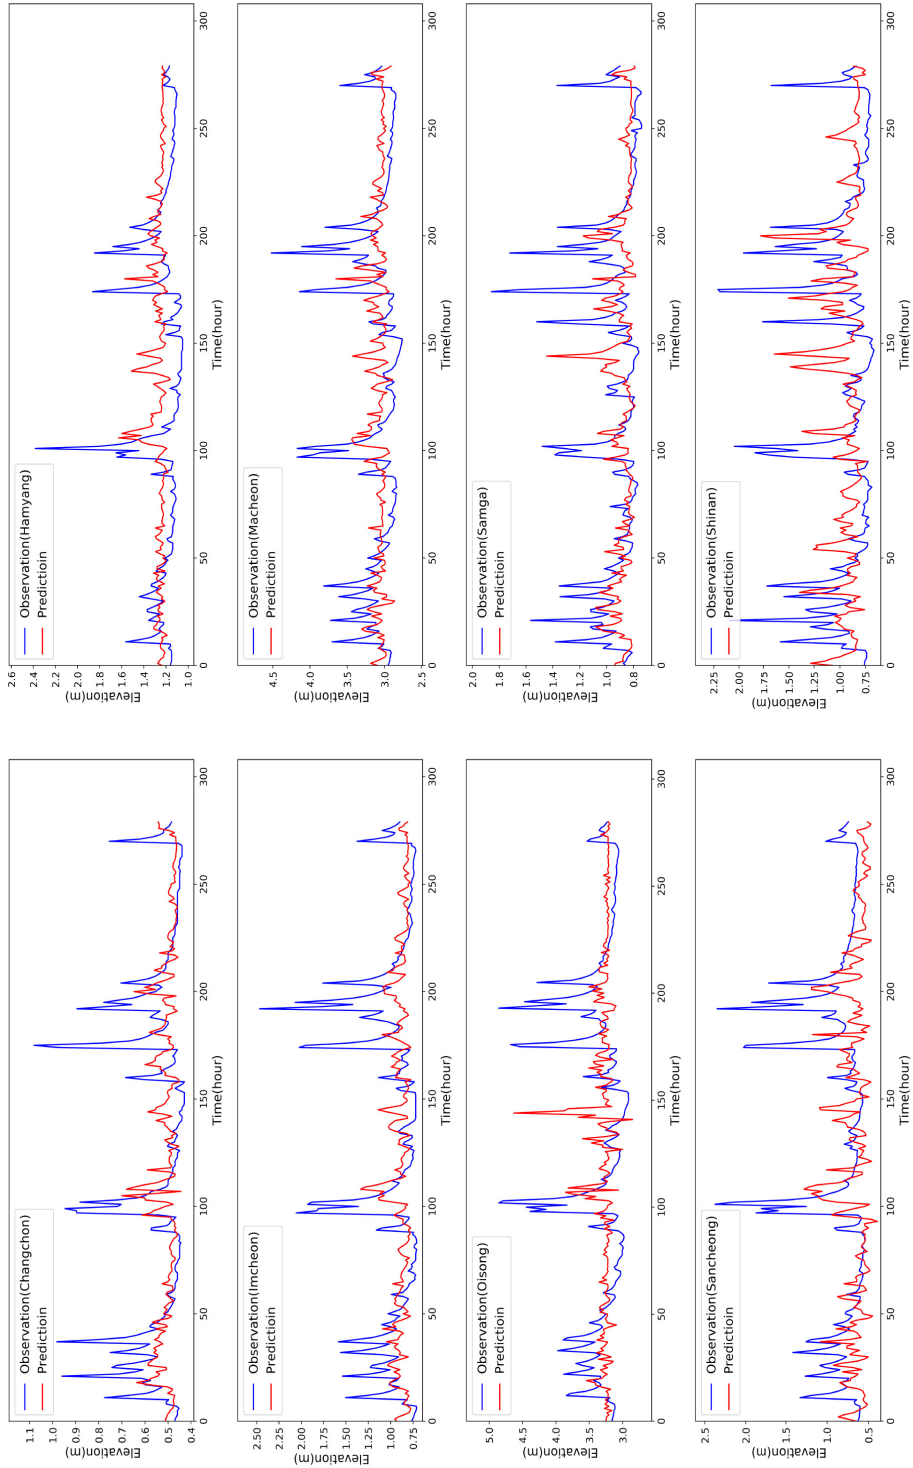
D-1-4. Comparison of 4 day prediction using rainfall with measured water elevation vs. measured water elevation data



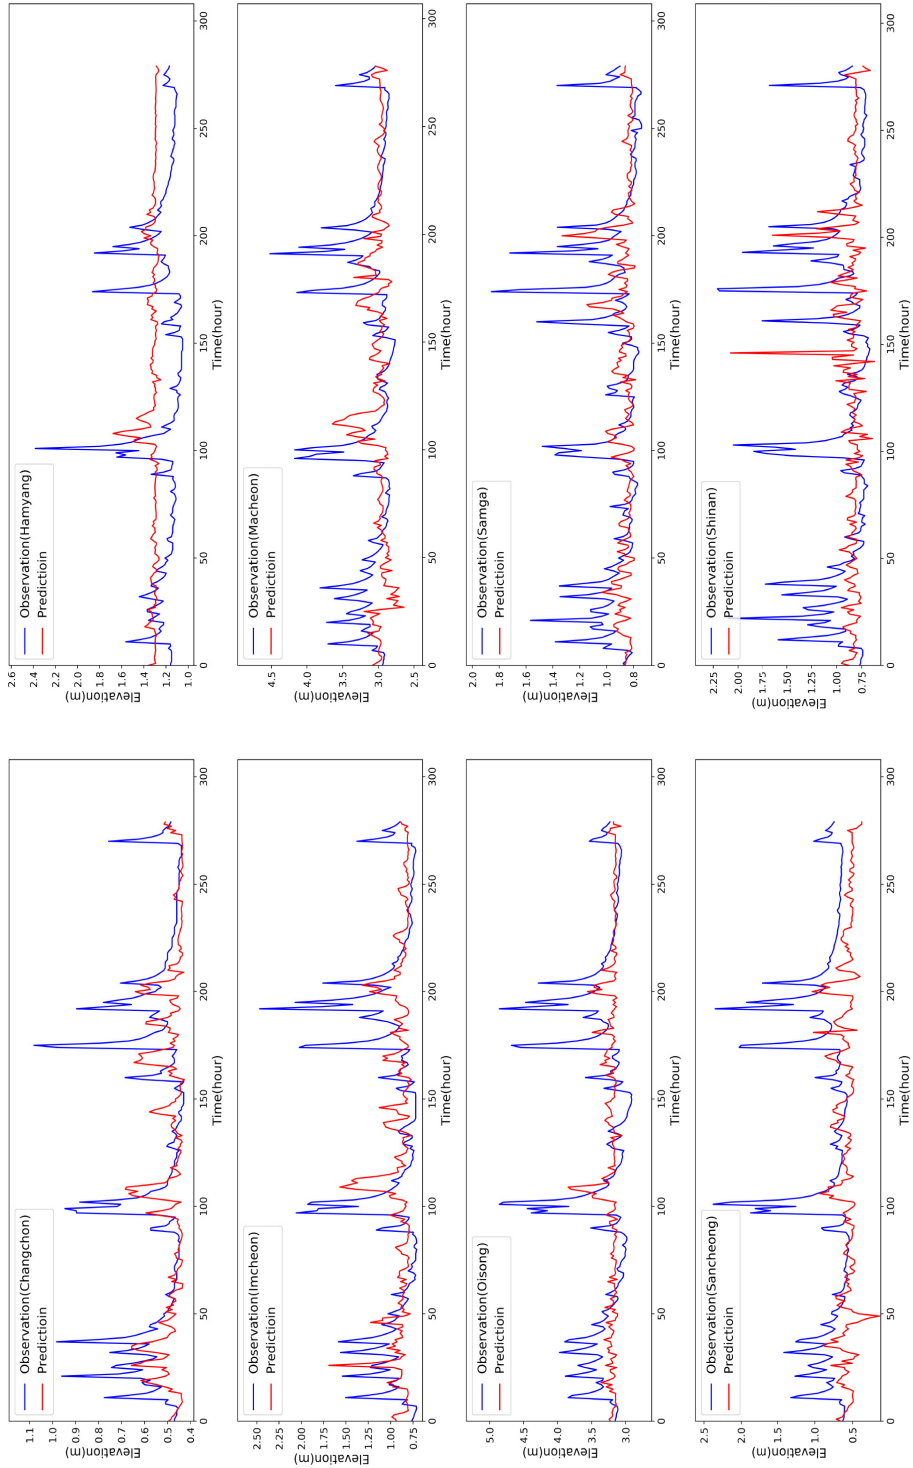
D-1-5. Comparison of 5 day prediction using rainfall with measured water elevation vs. measured water elevation data



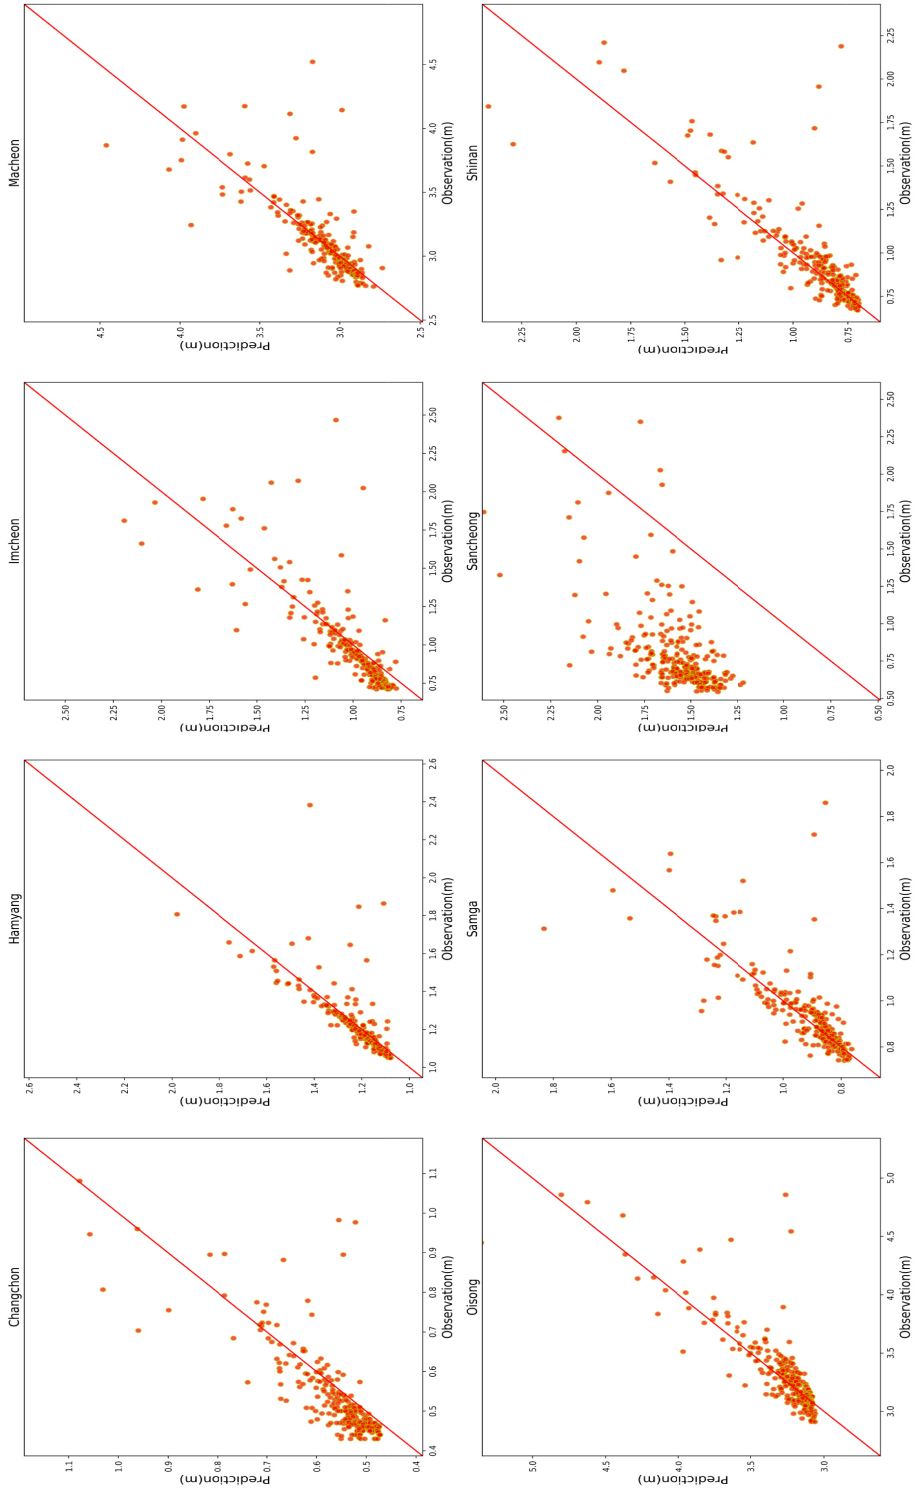
D-1-6. Comparison of 6 day prediction using rainfall with measured water elevation vs. measured water elevation data



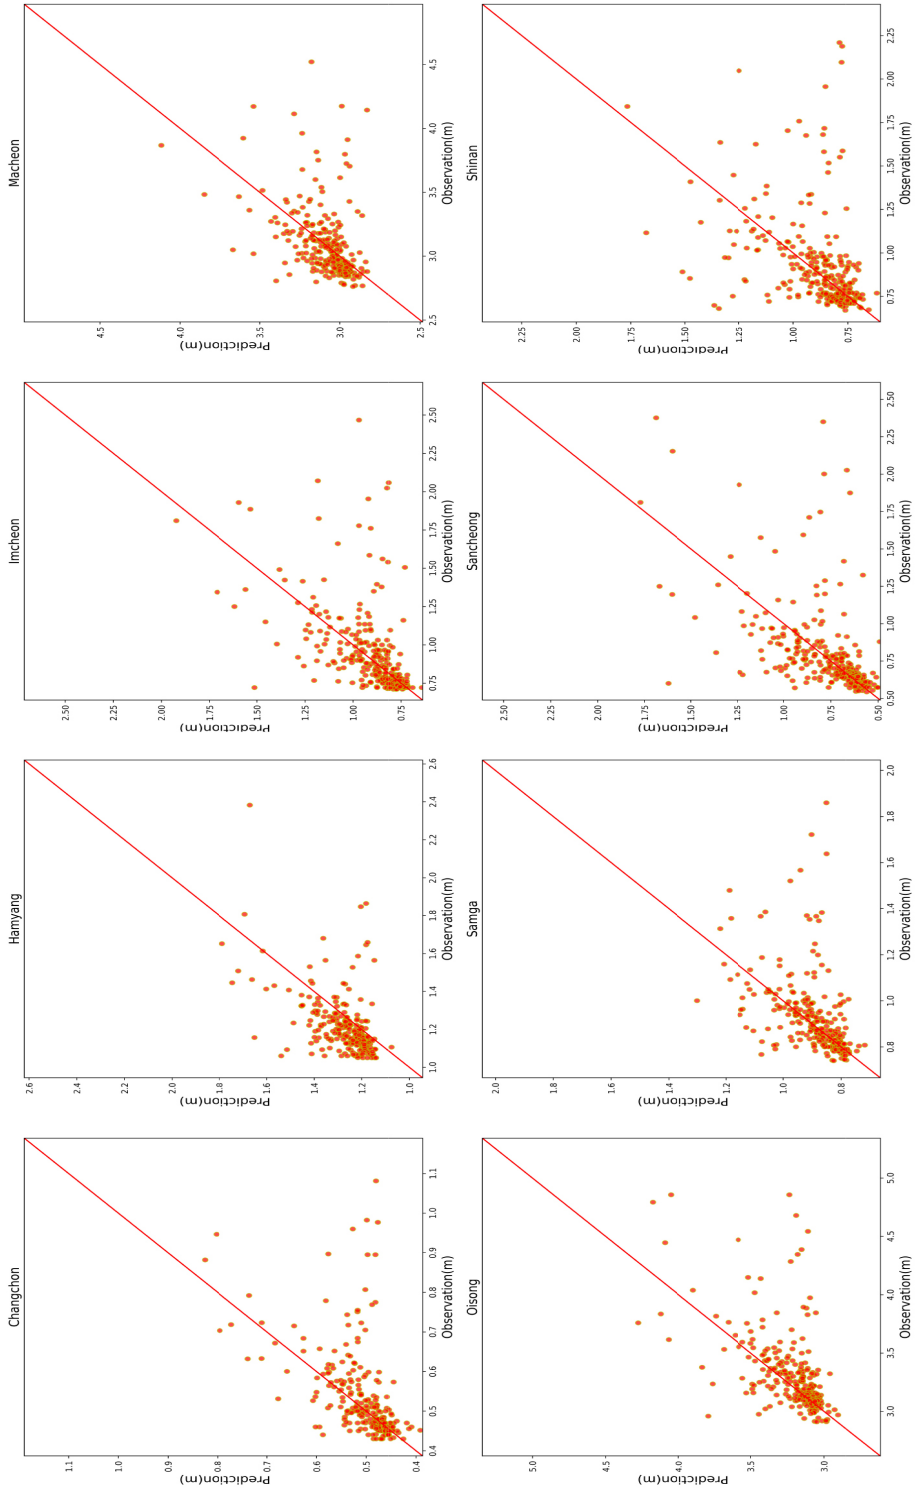
D-1-7. Comparison of 7 day prediction using rainfall with measured water elevation vs. measured water elevation data



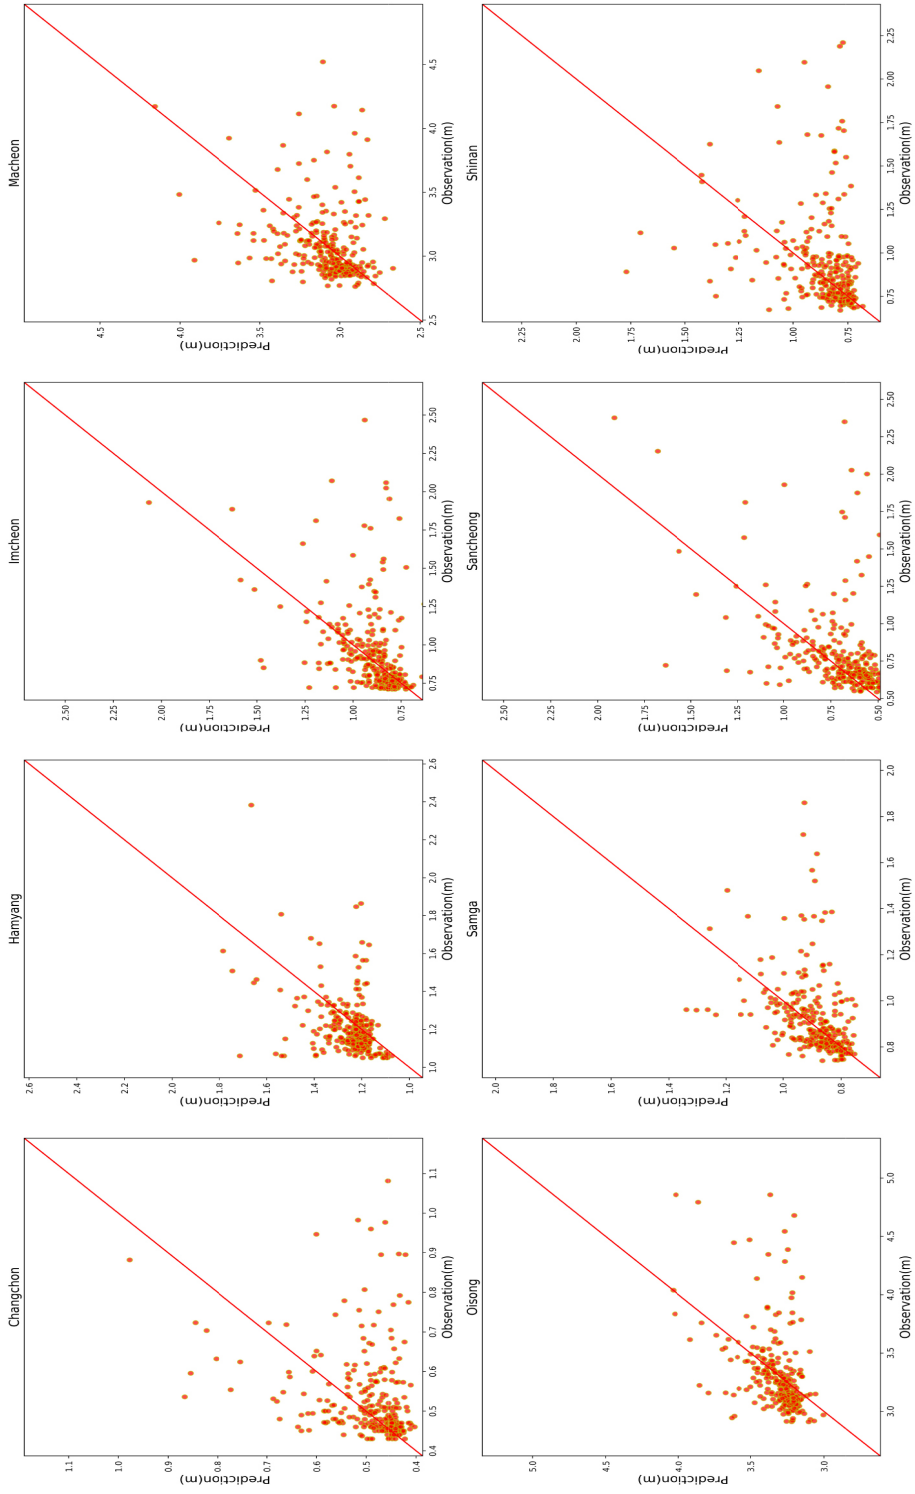
D-1-8. Comparison of scatter plot of 1 day prediction with measured water elevation vs. measured water elevation data



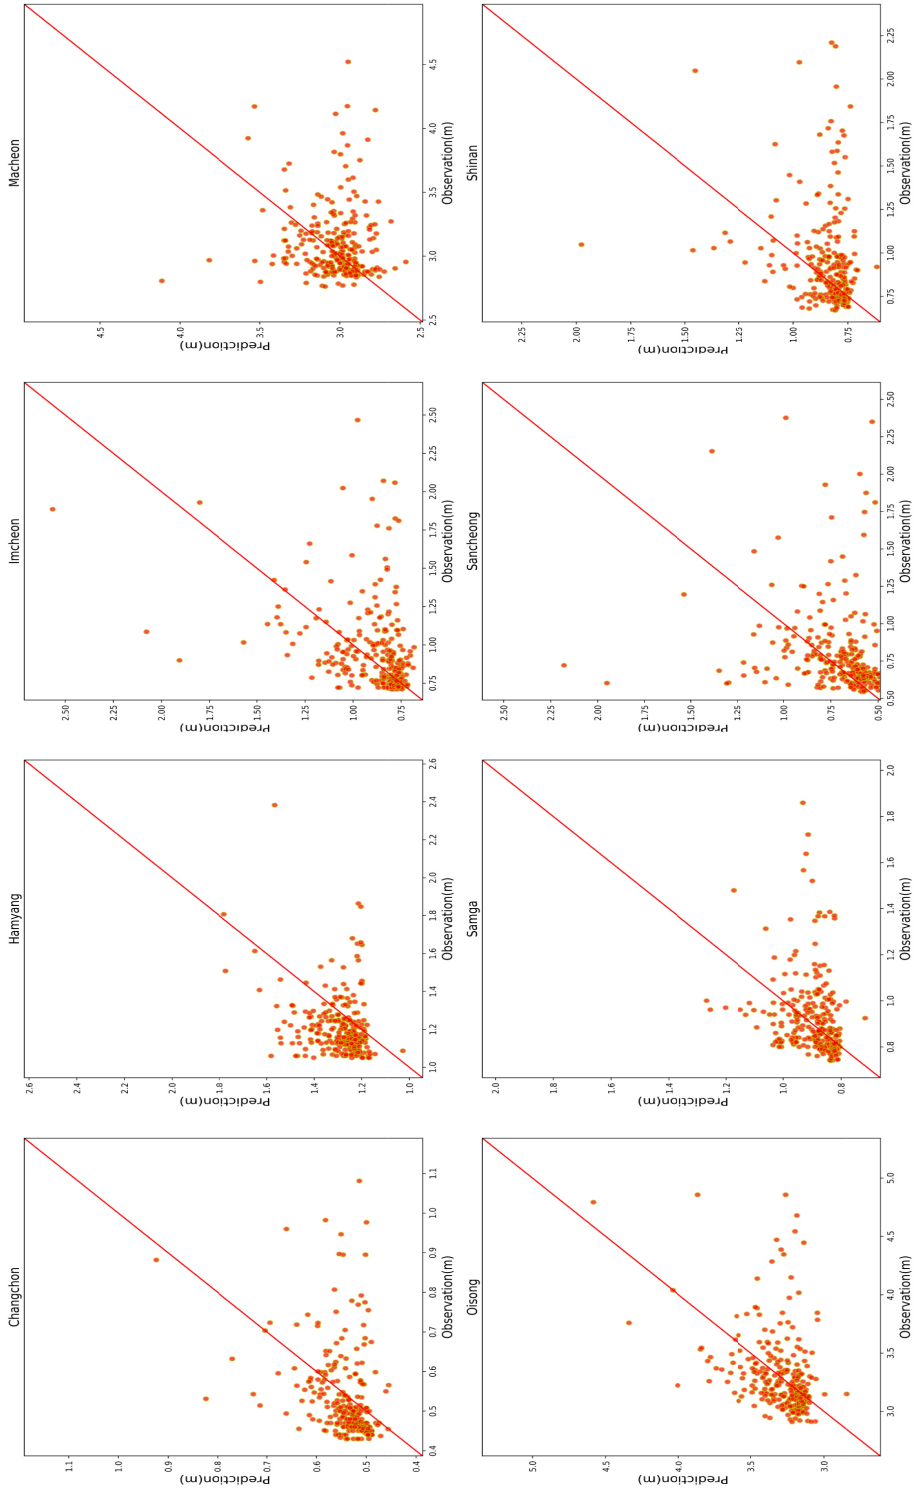
D-1-9. Comparison of scatter plot of 2 day prediction using rainfall with measured water elevation vs. measured water elevation data



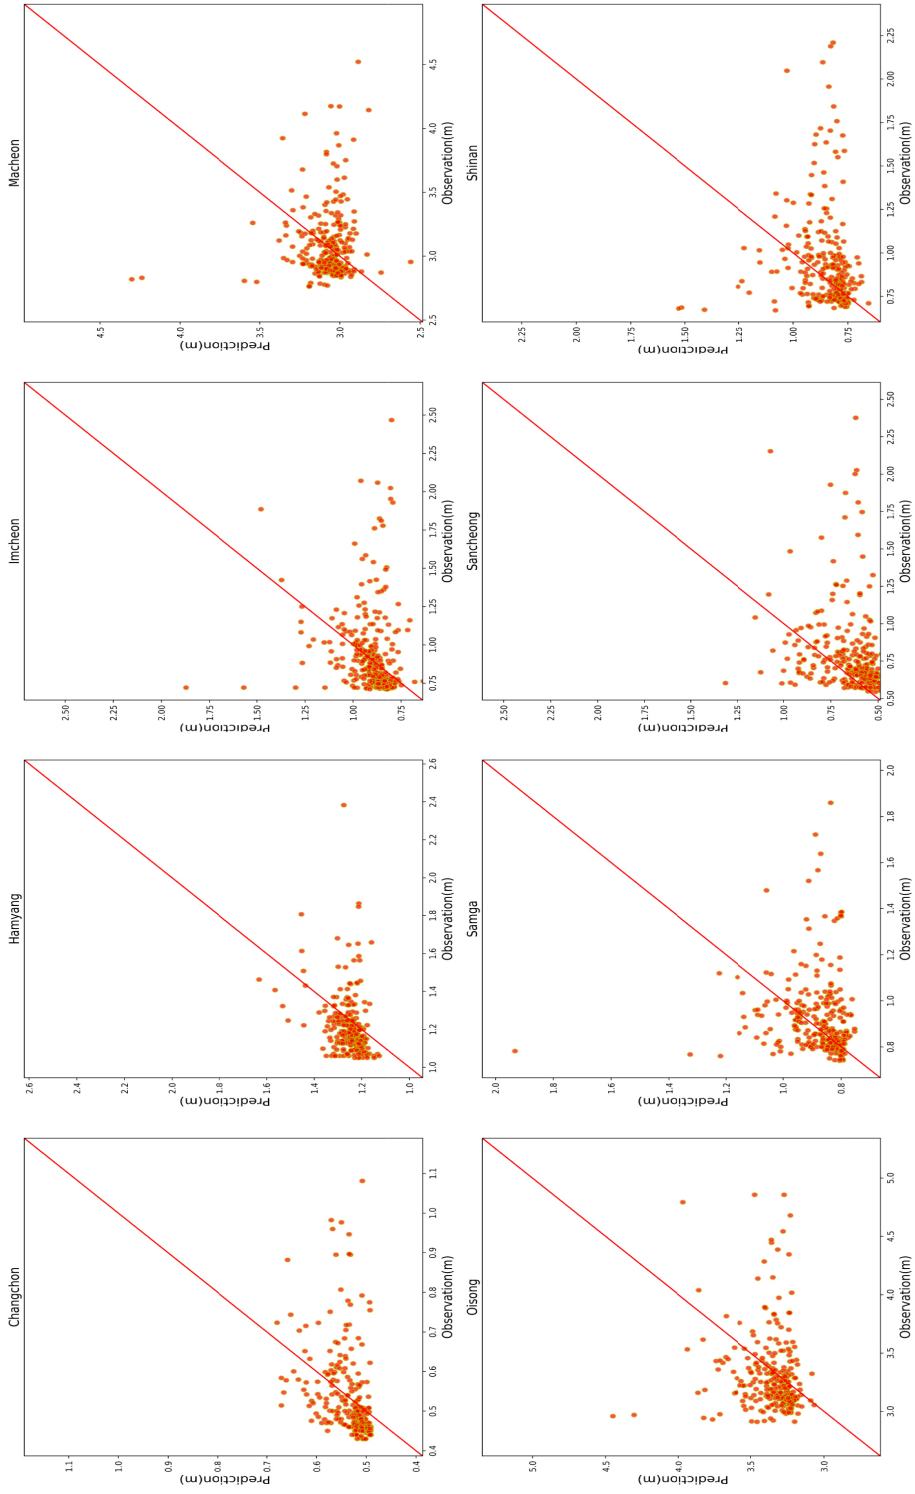
D-1-10. Comparison of scatter plot of 3 day prediction using rainfall with measured water elevation vs. measured water elevation data



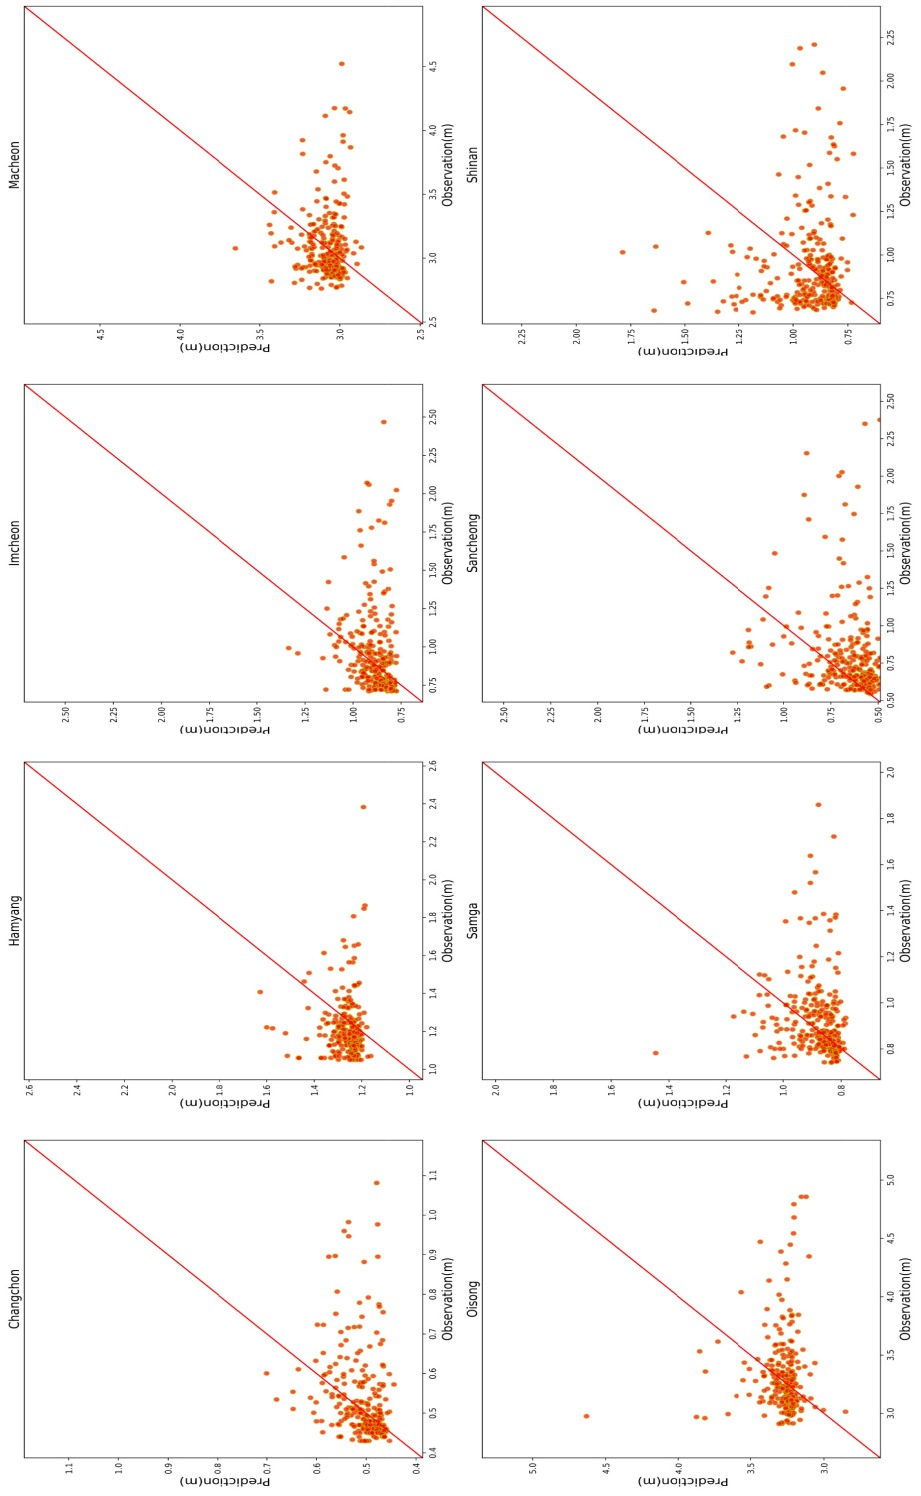
D-1-11. Comparison of scatter plot of 4 day prediction using rainfall with measured water elevation vs. measured water elevation data



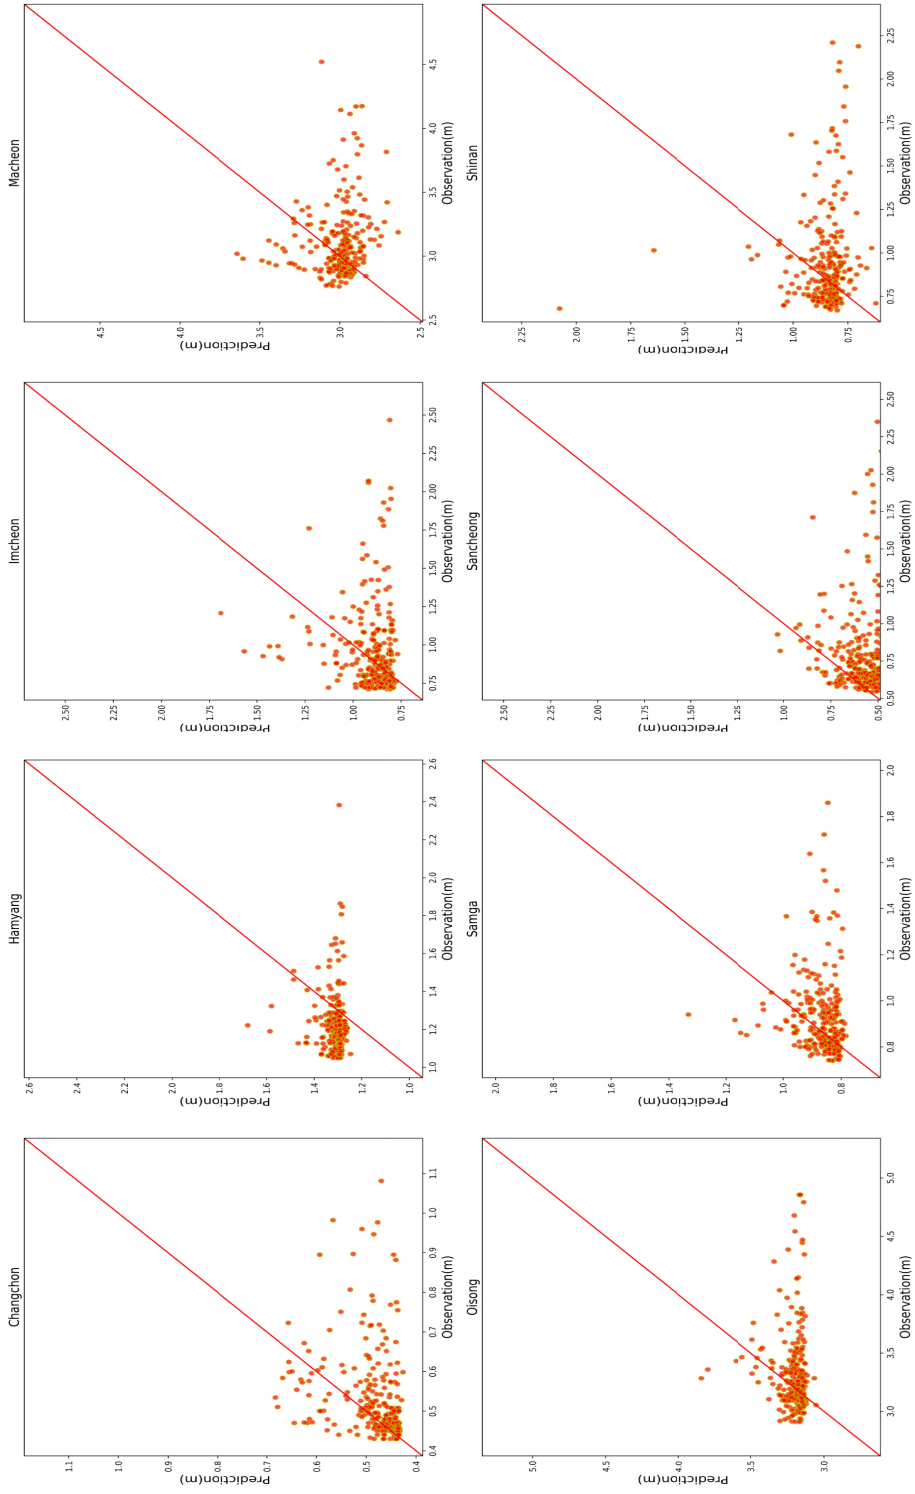
D-1-12. Comparison of scatter plot of 5 day prediction using rainfall with measured water elevation vs. measured water elevation data



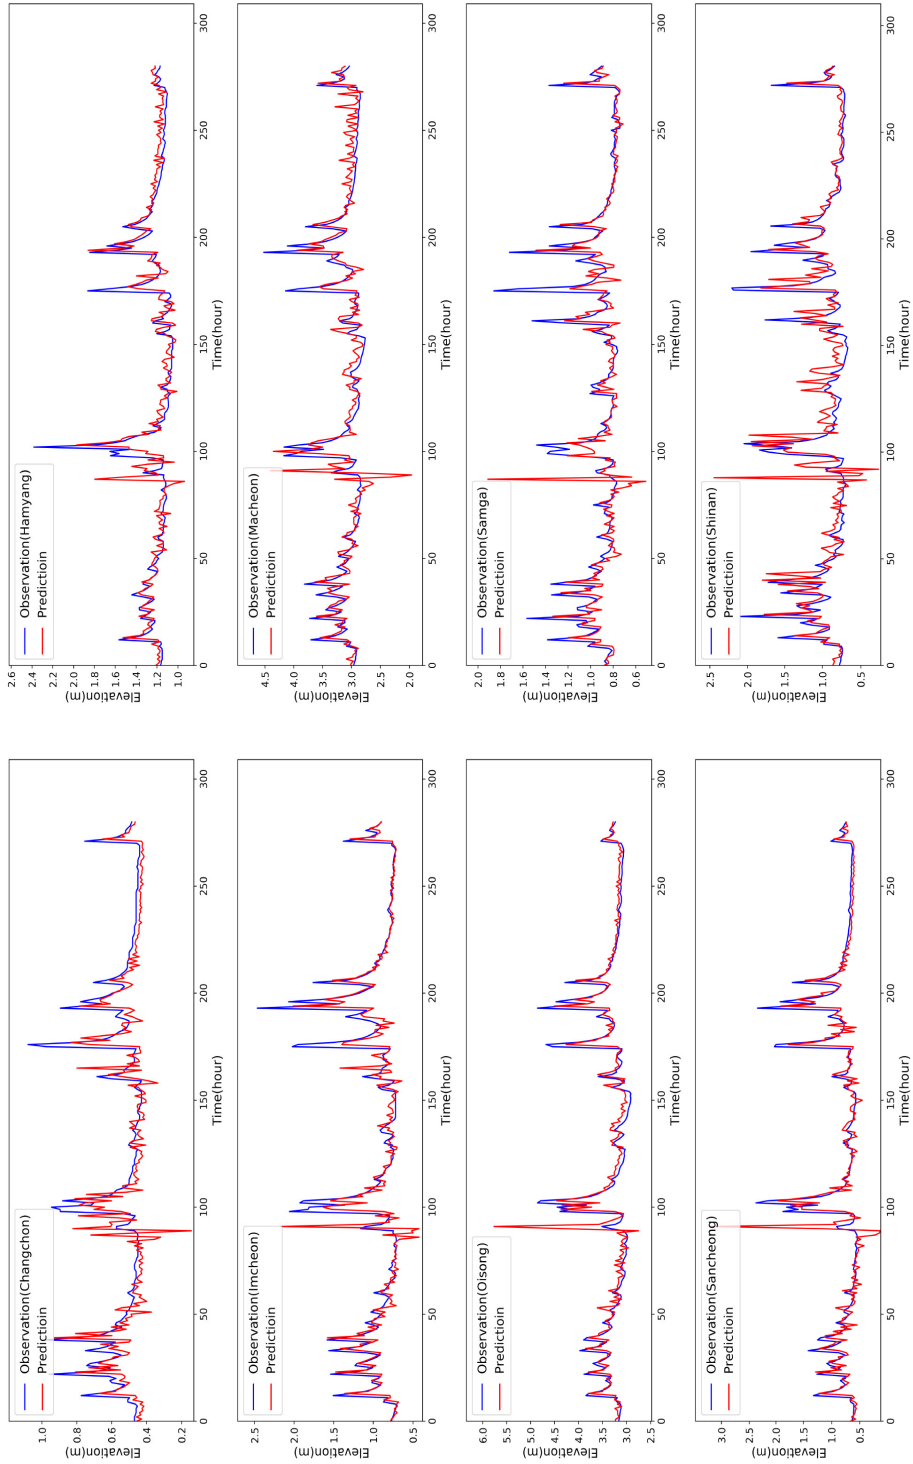
D-1-13. Comparison of scatter plot of 6 day prediction using rainfall with measured water elevation vs. measured water elevation data



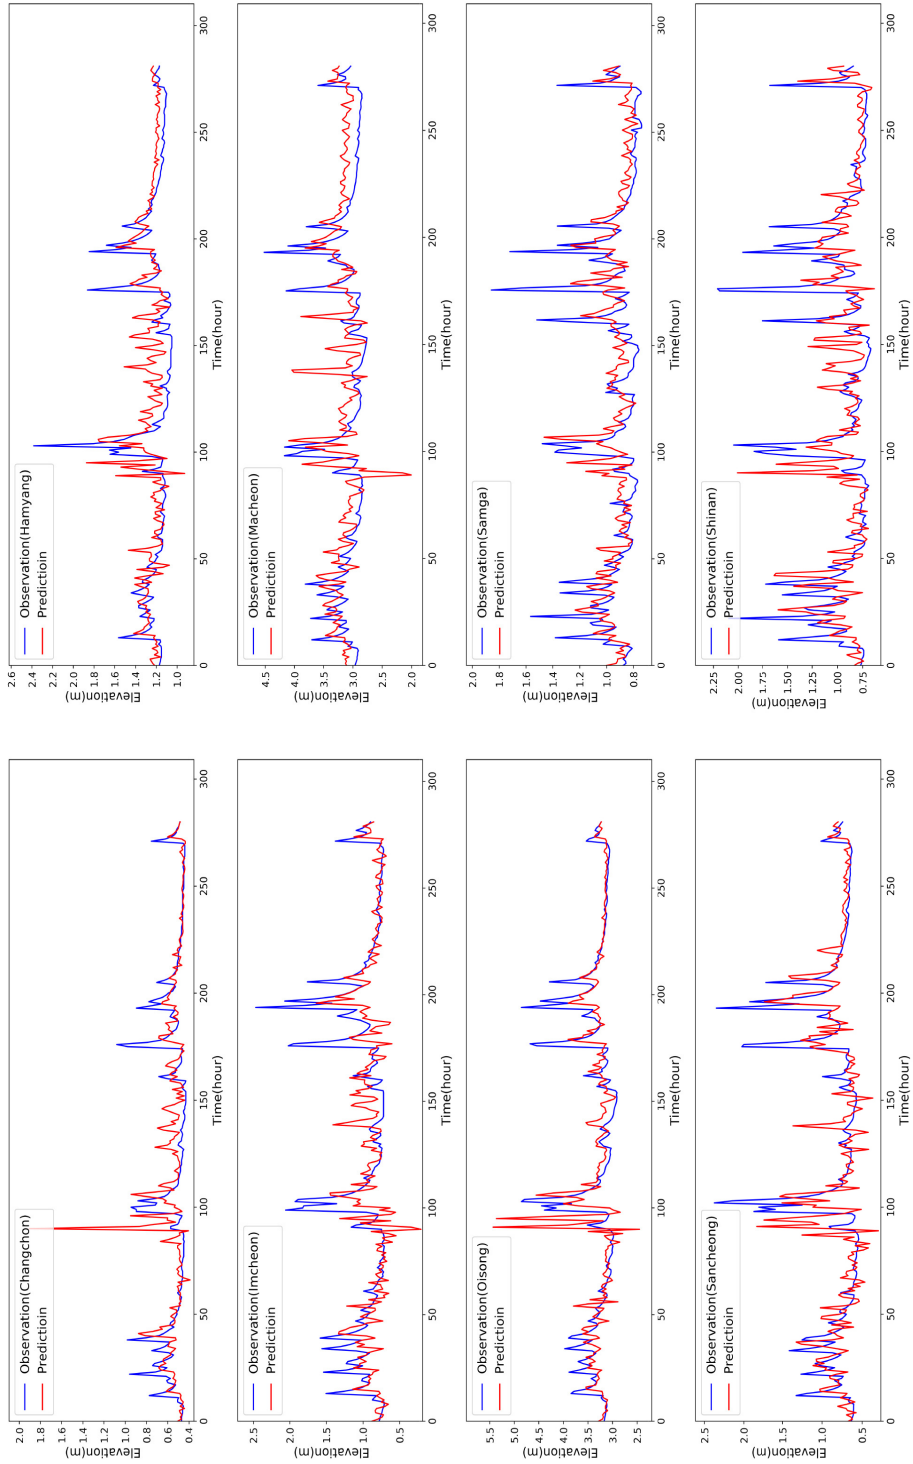
D-1-14. Comparison of scatter plot of 7 day prediction using rainfall with measured water elevation vs. measured water elevation data



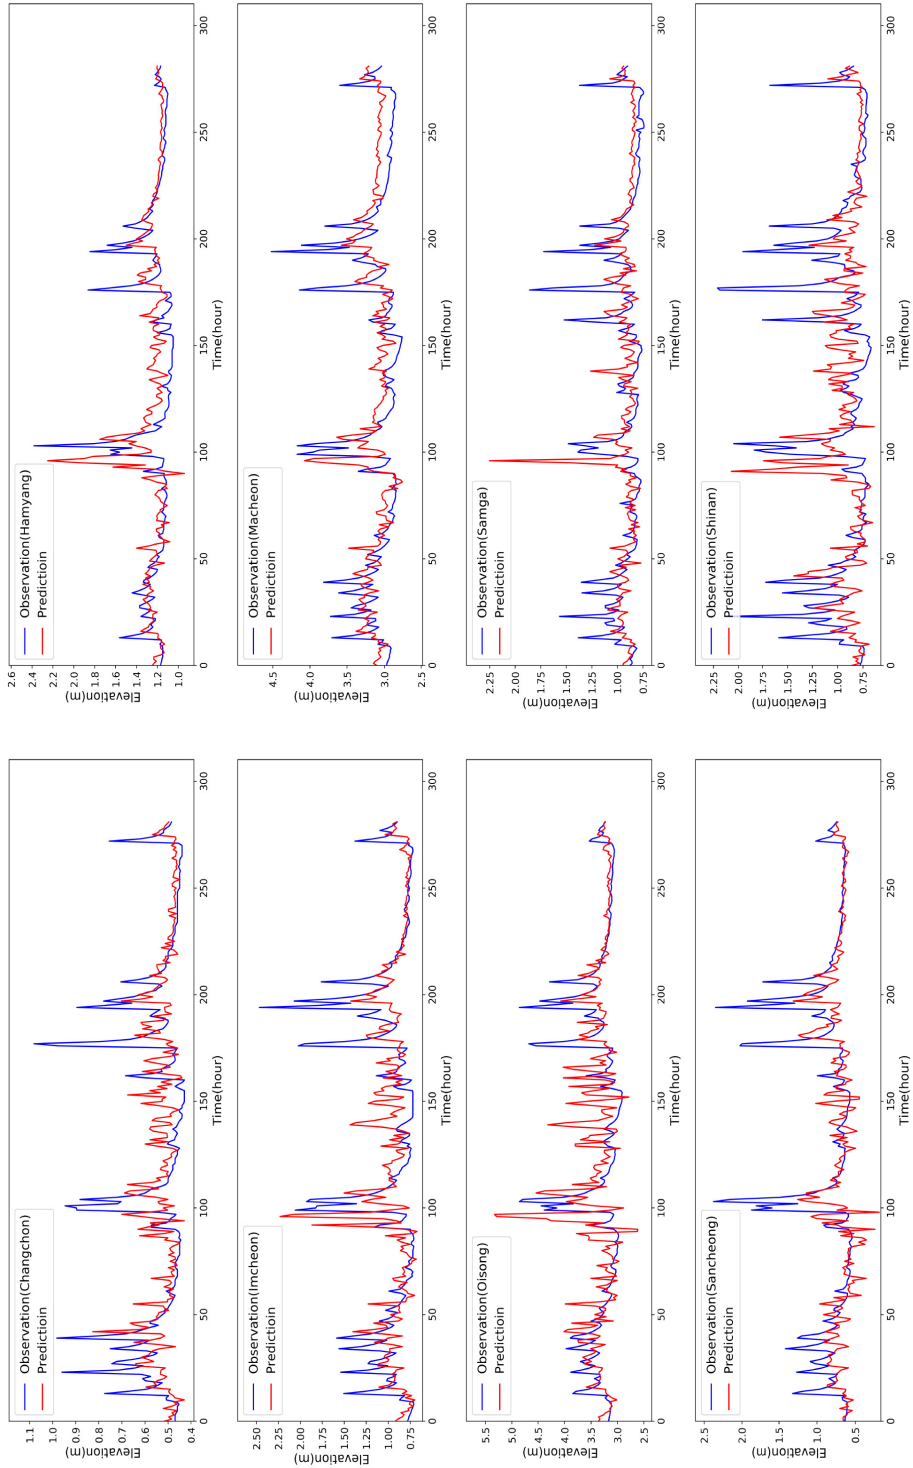
D-2-1. Comparison of 1 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



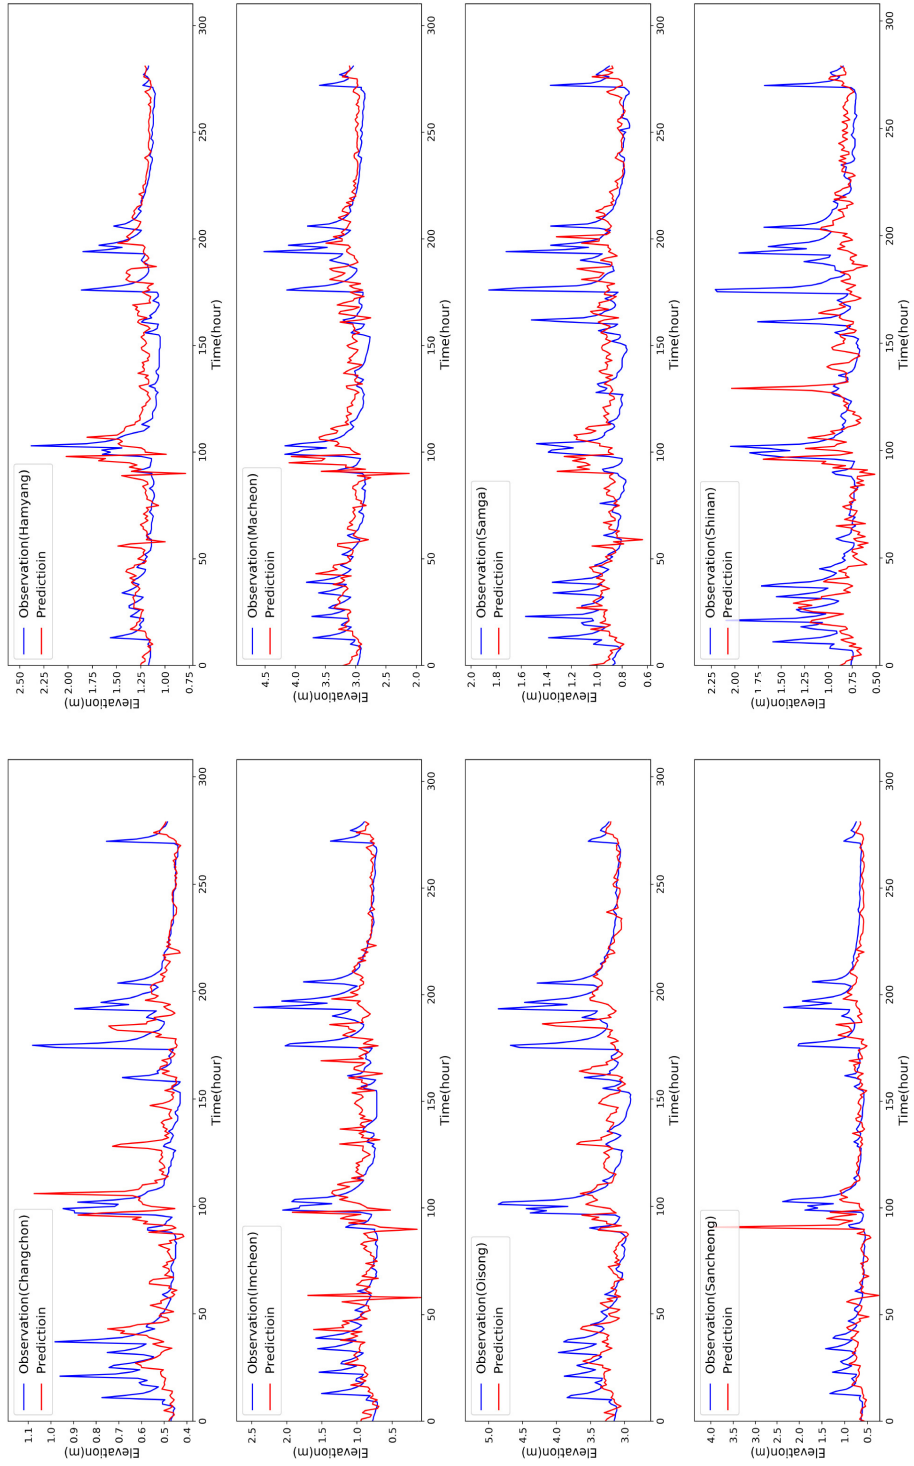
D-2-2. Comparison of 2 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



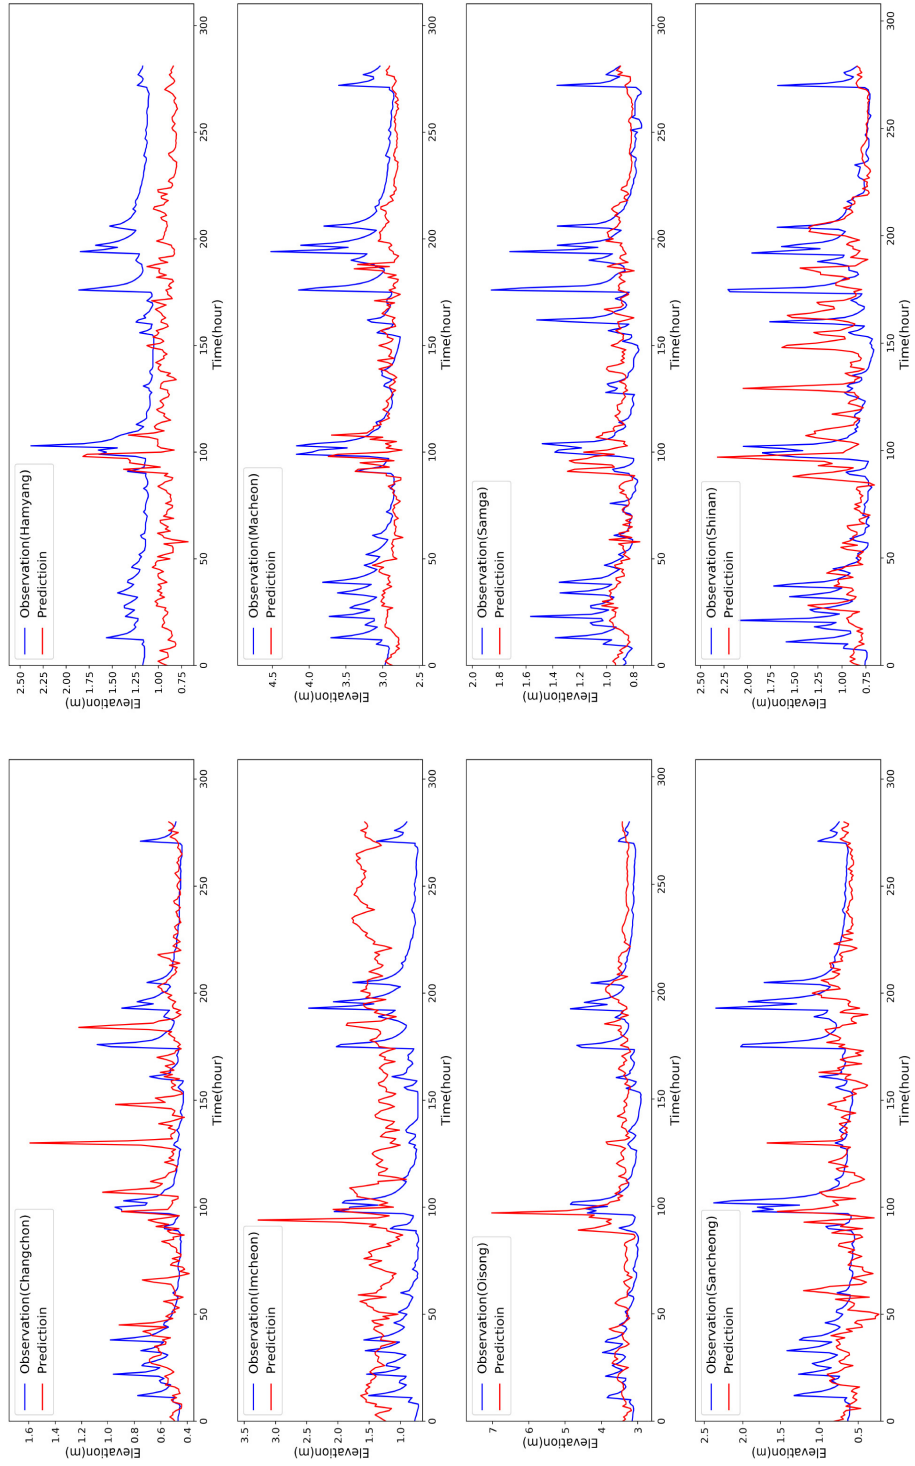
D-2-3. Comparison of 3 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



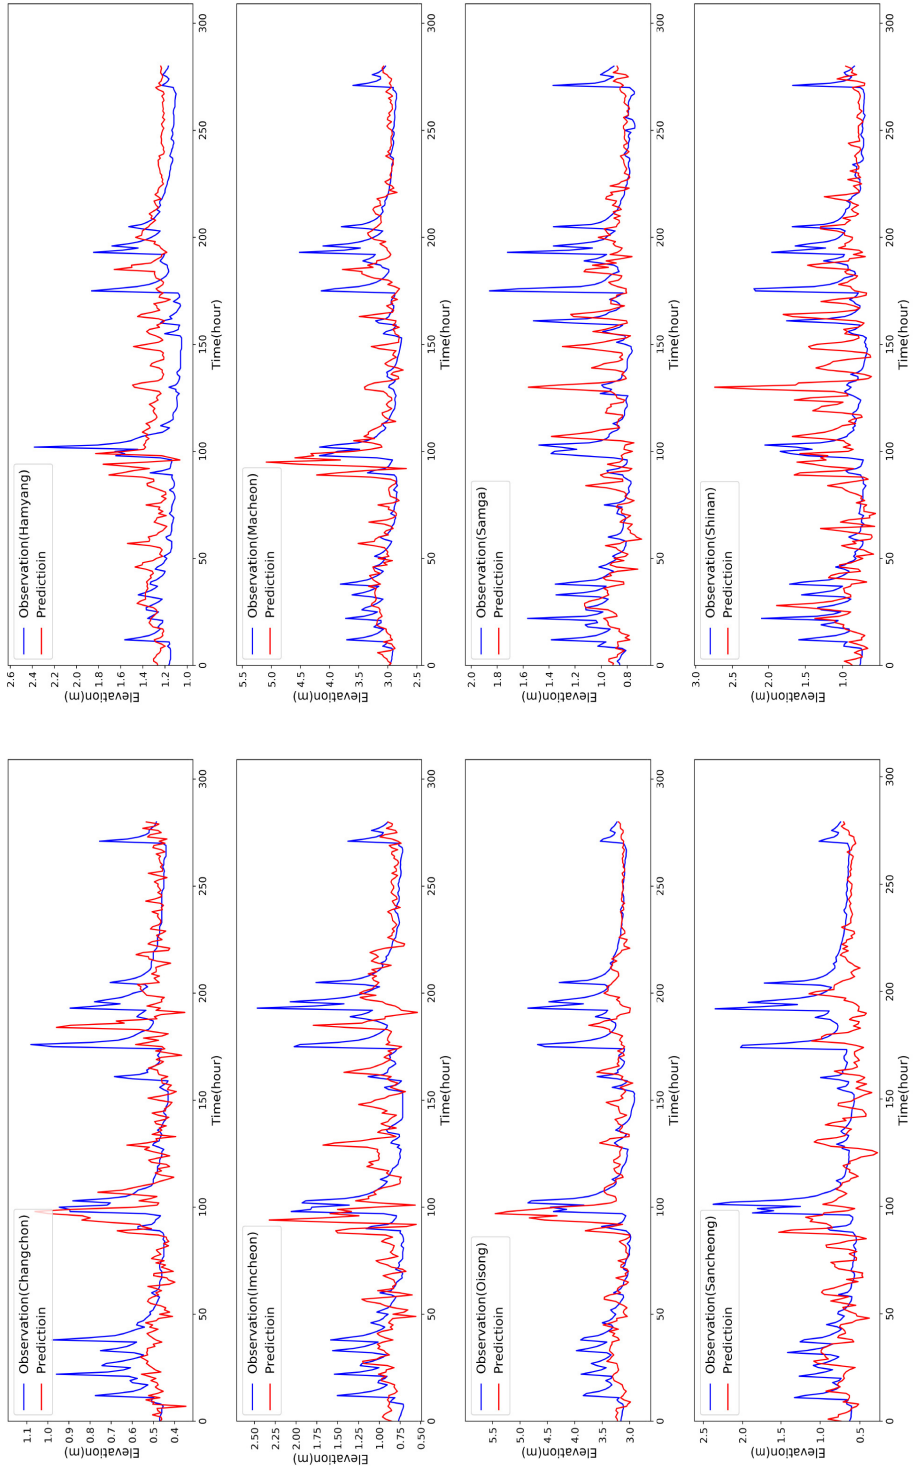
D-2-4. Comparison of 4 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



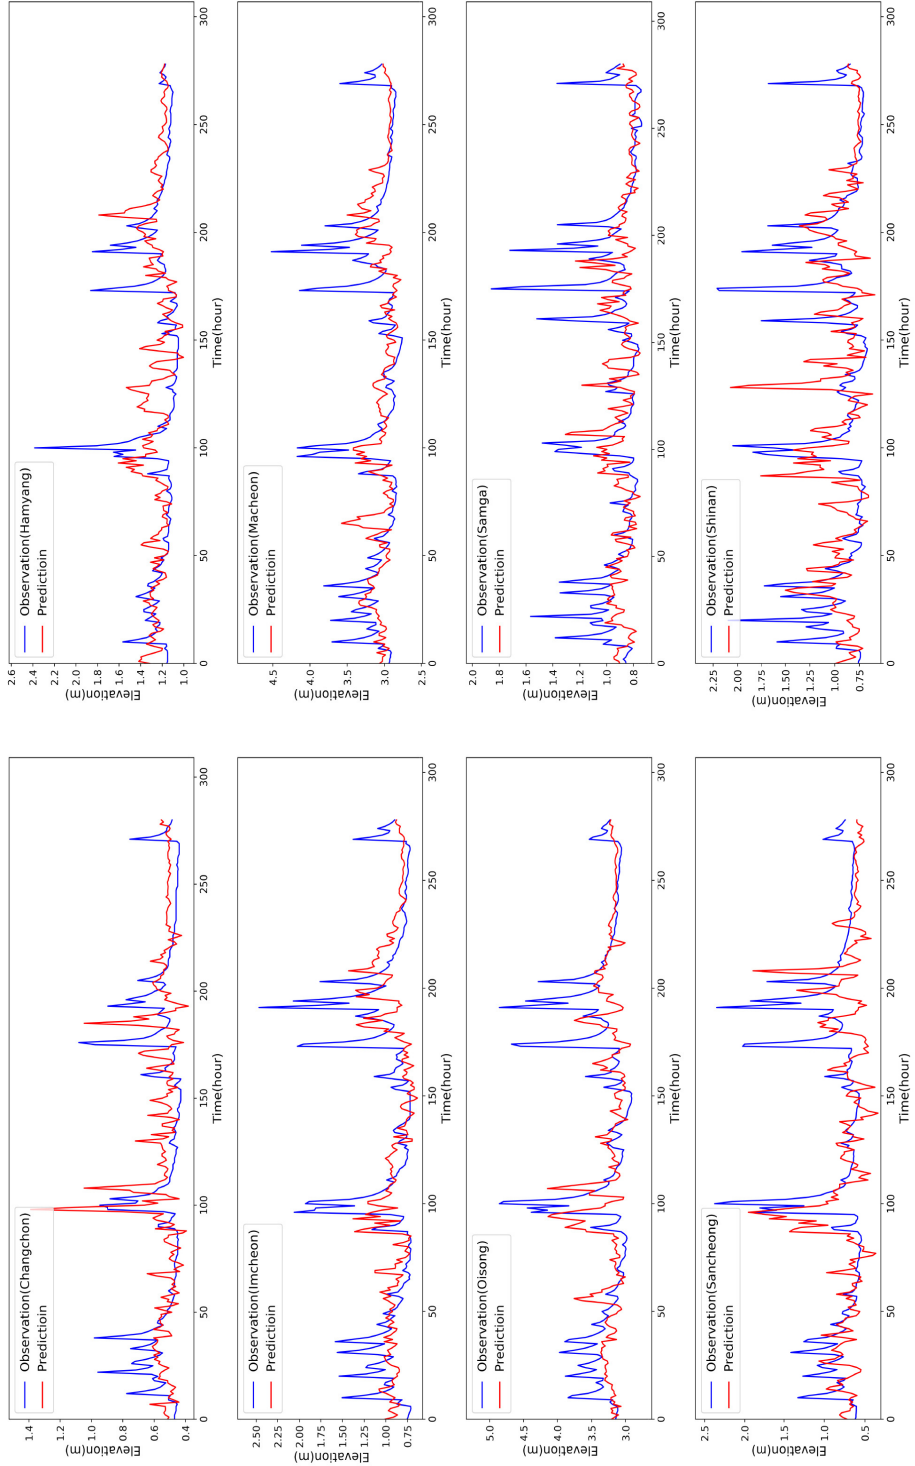
D-2-5. Comparison of 5 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



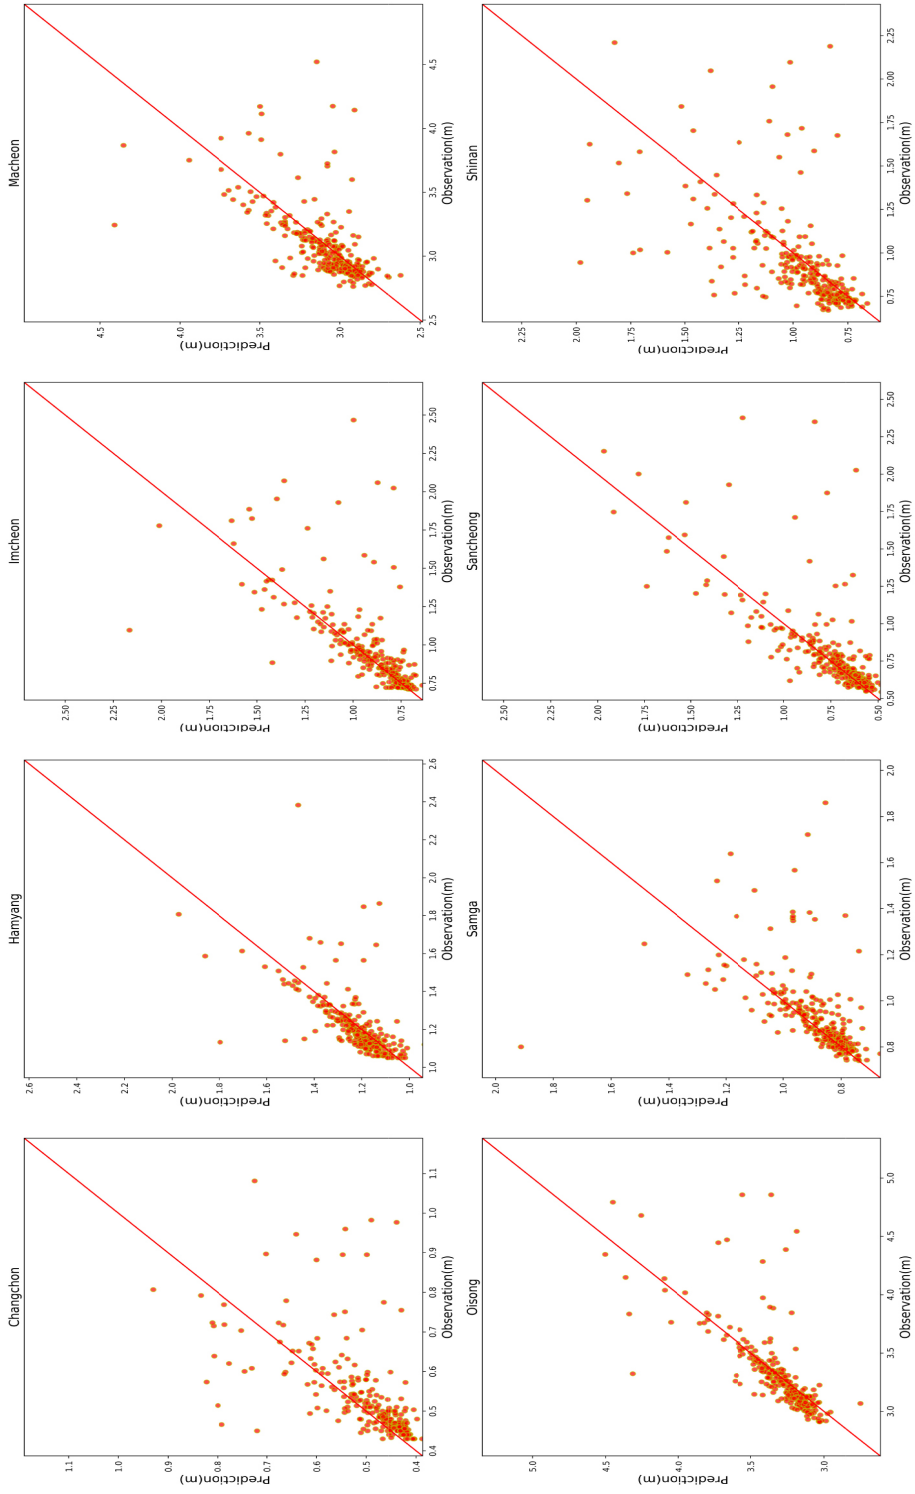
D-2-6. Comparison of 6 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



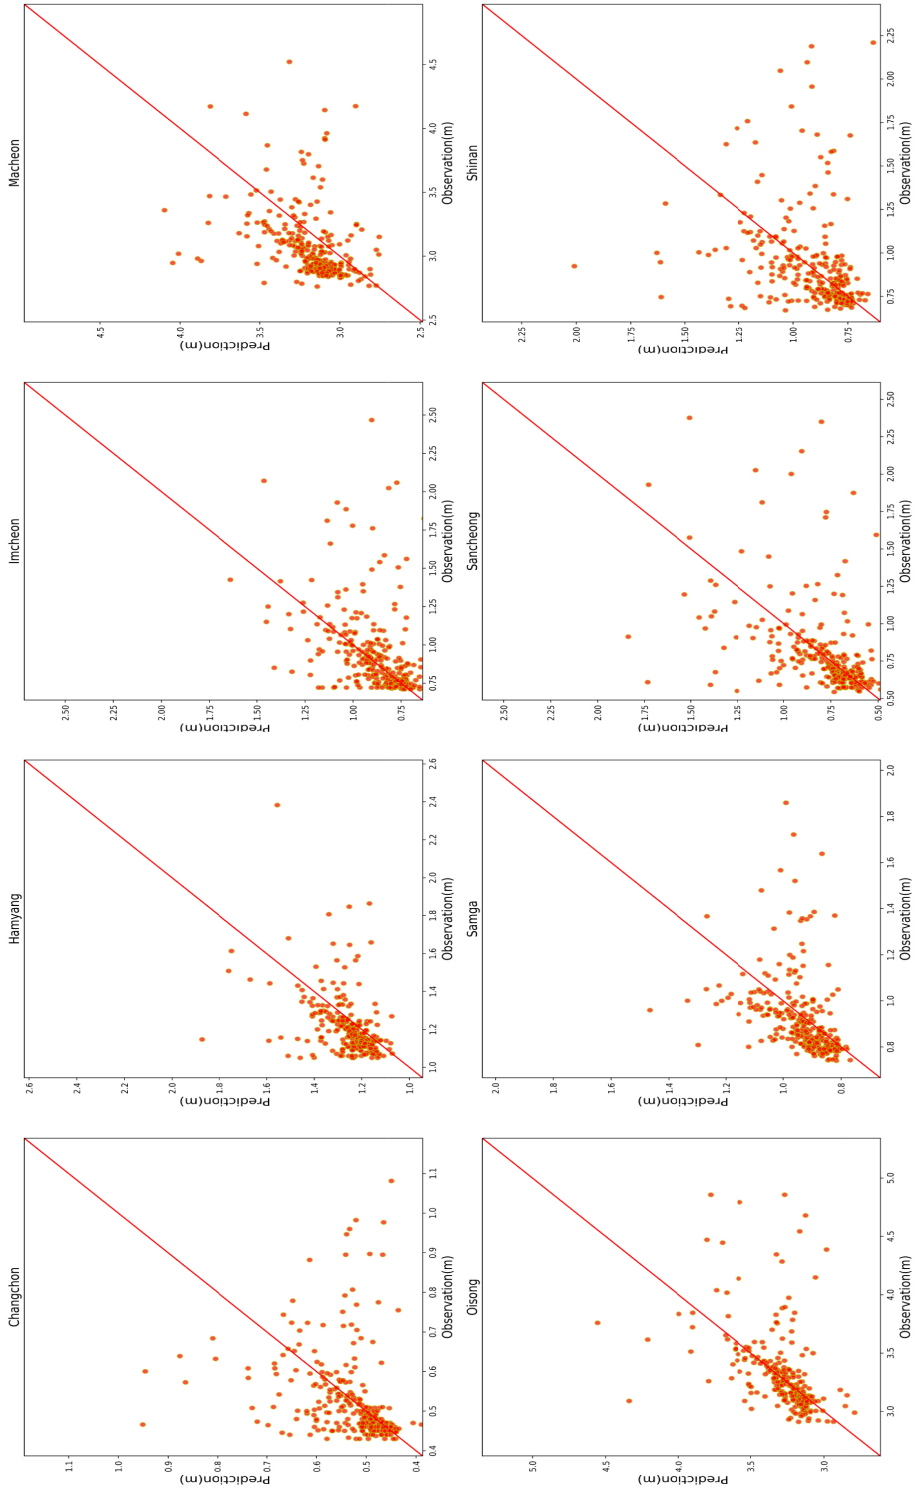
D-2-7. Comparison of 7 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



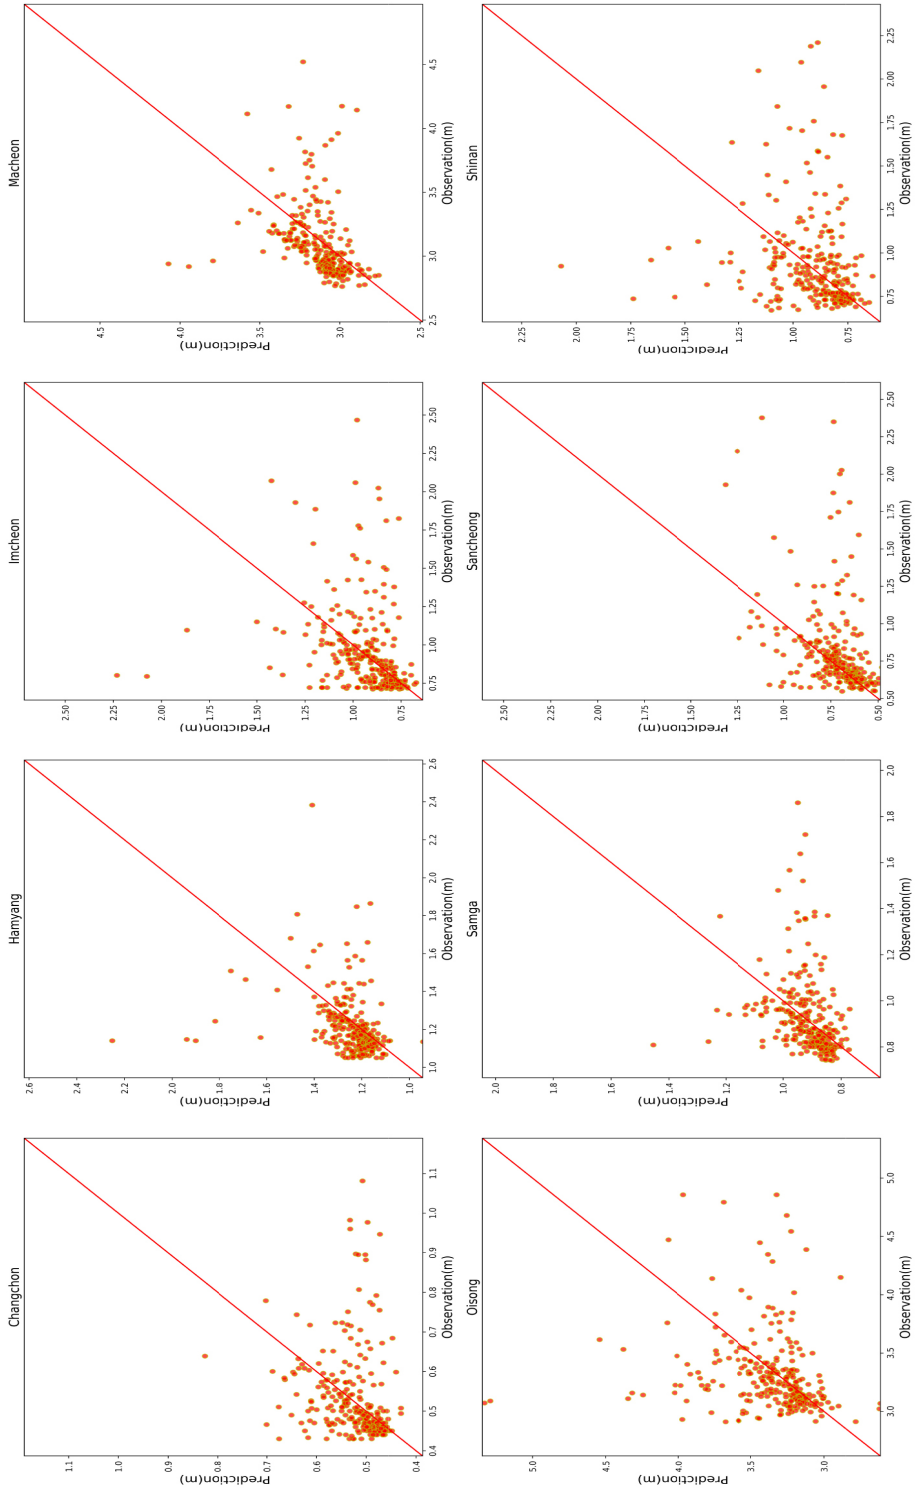
D-2-8. Comparison of scatter plot of 1 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



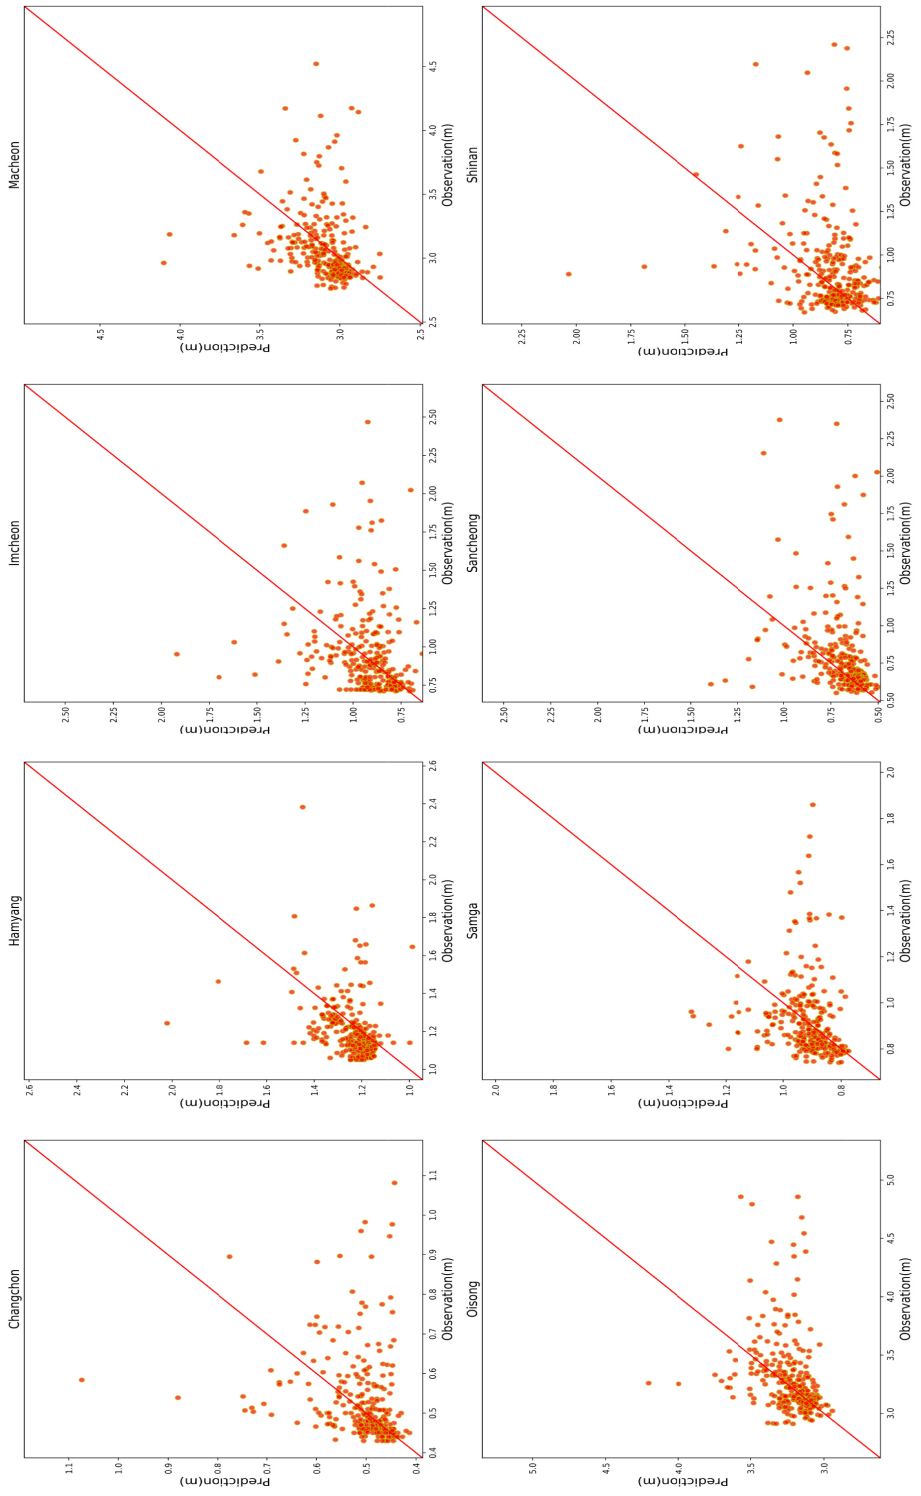
D-2-9. Comparison of scatter plot of 2 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



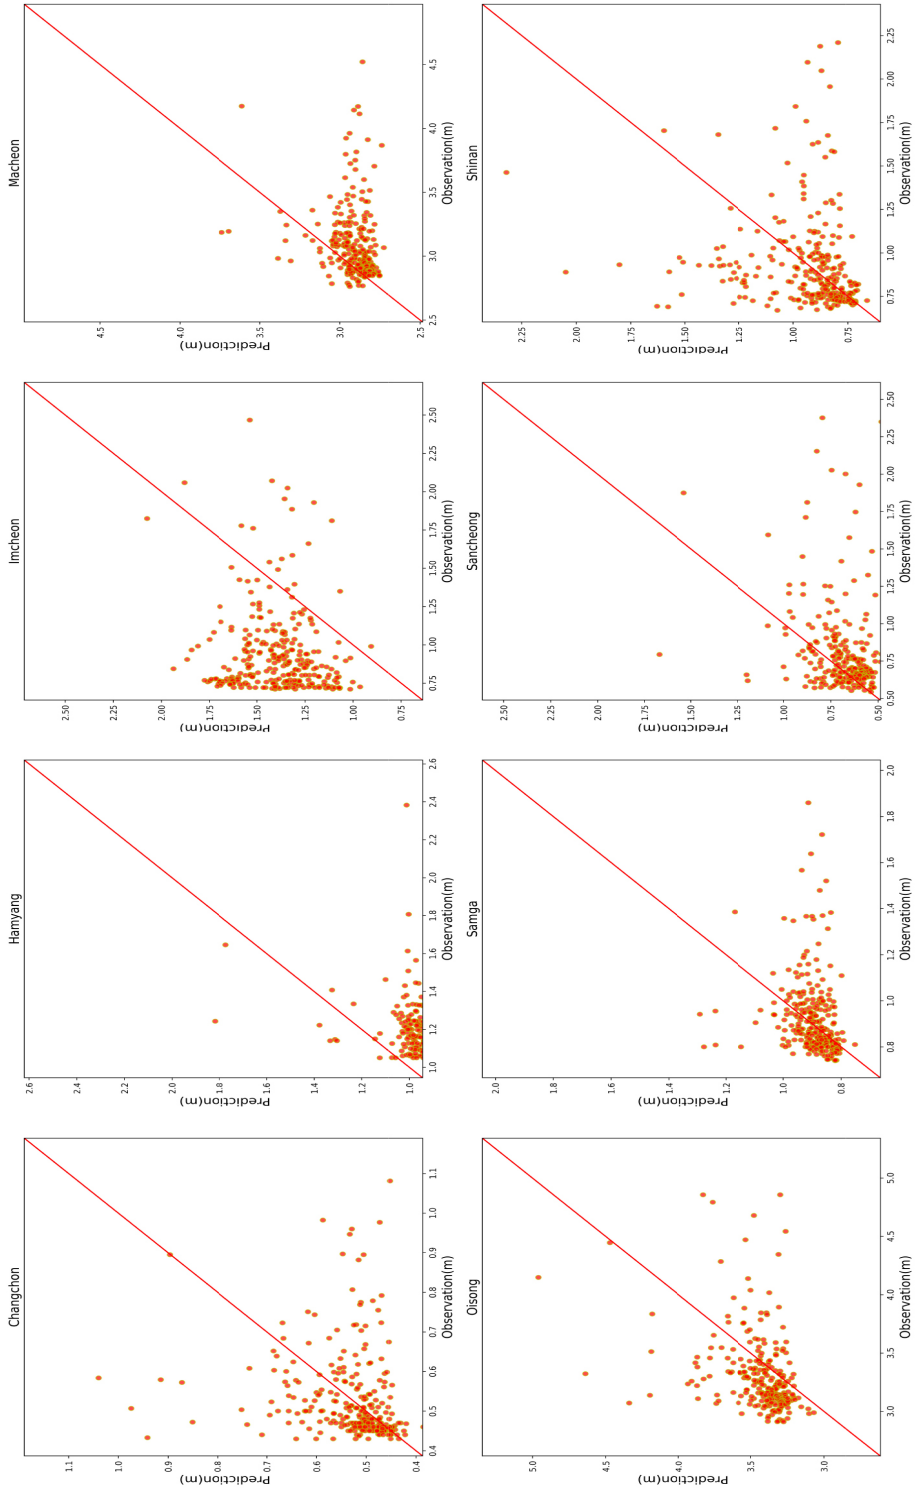
D-2-10. Comparison of scatter plot of 3 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



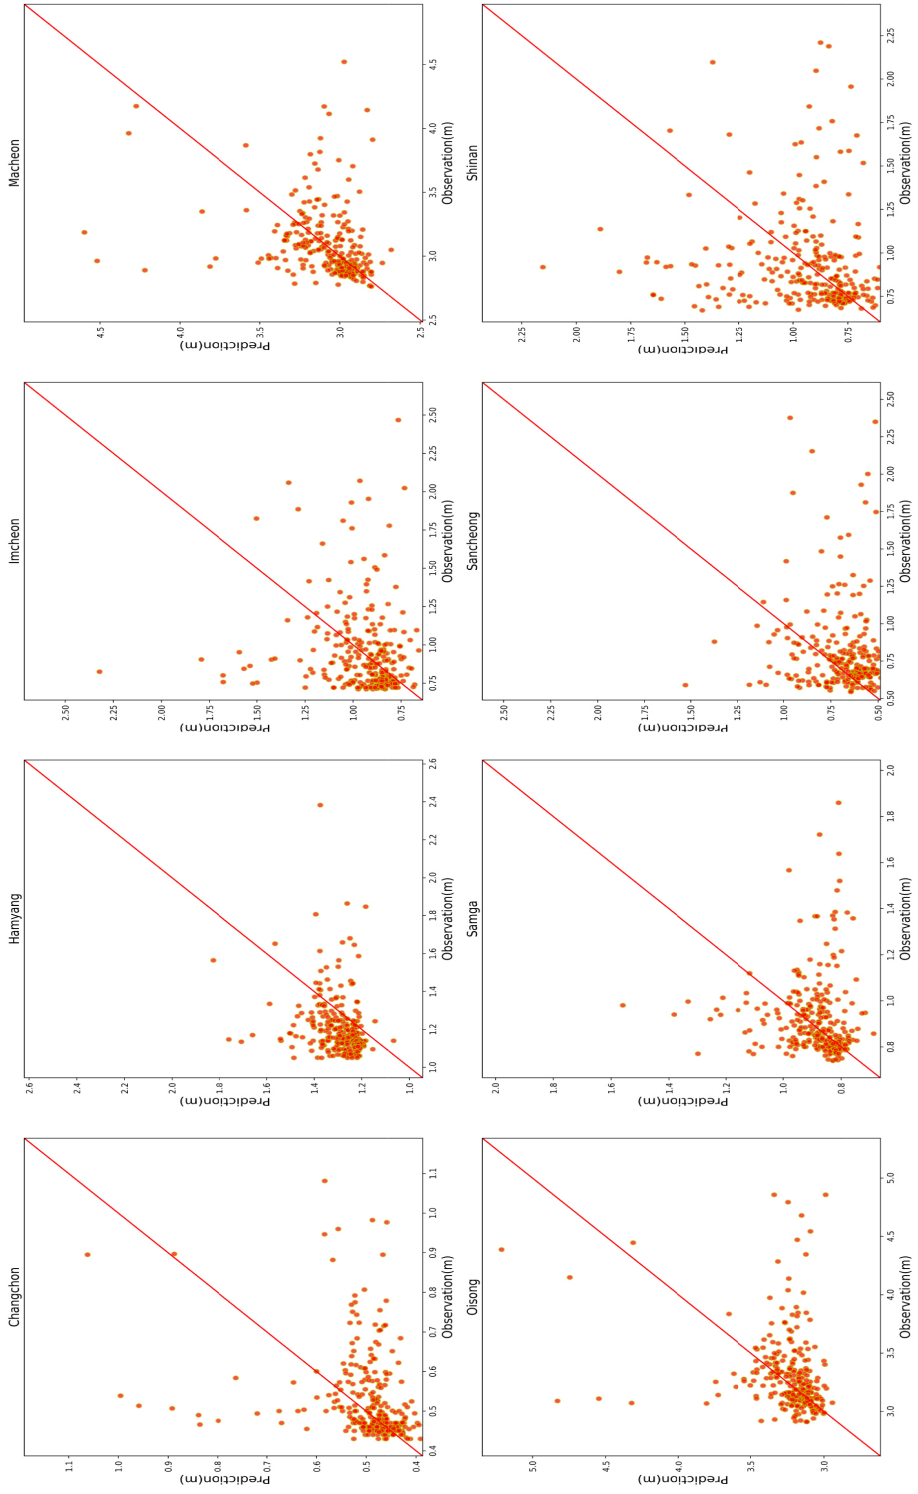
D-2-11. Comparison of scatter plot of 4 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



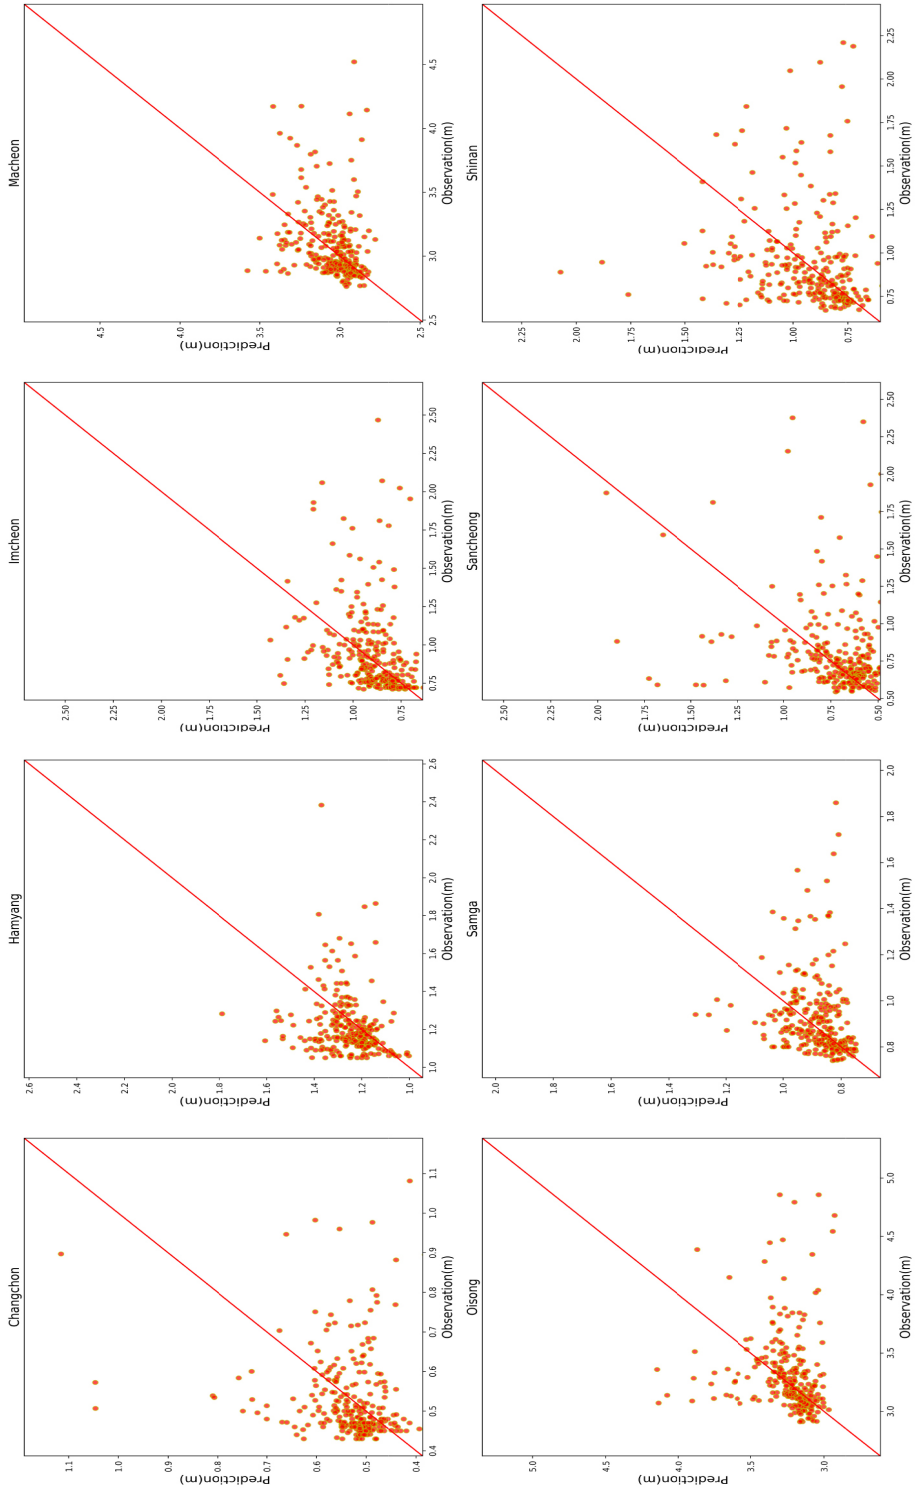
D-2-12. Comparison of scatter plot of 5 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



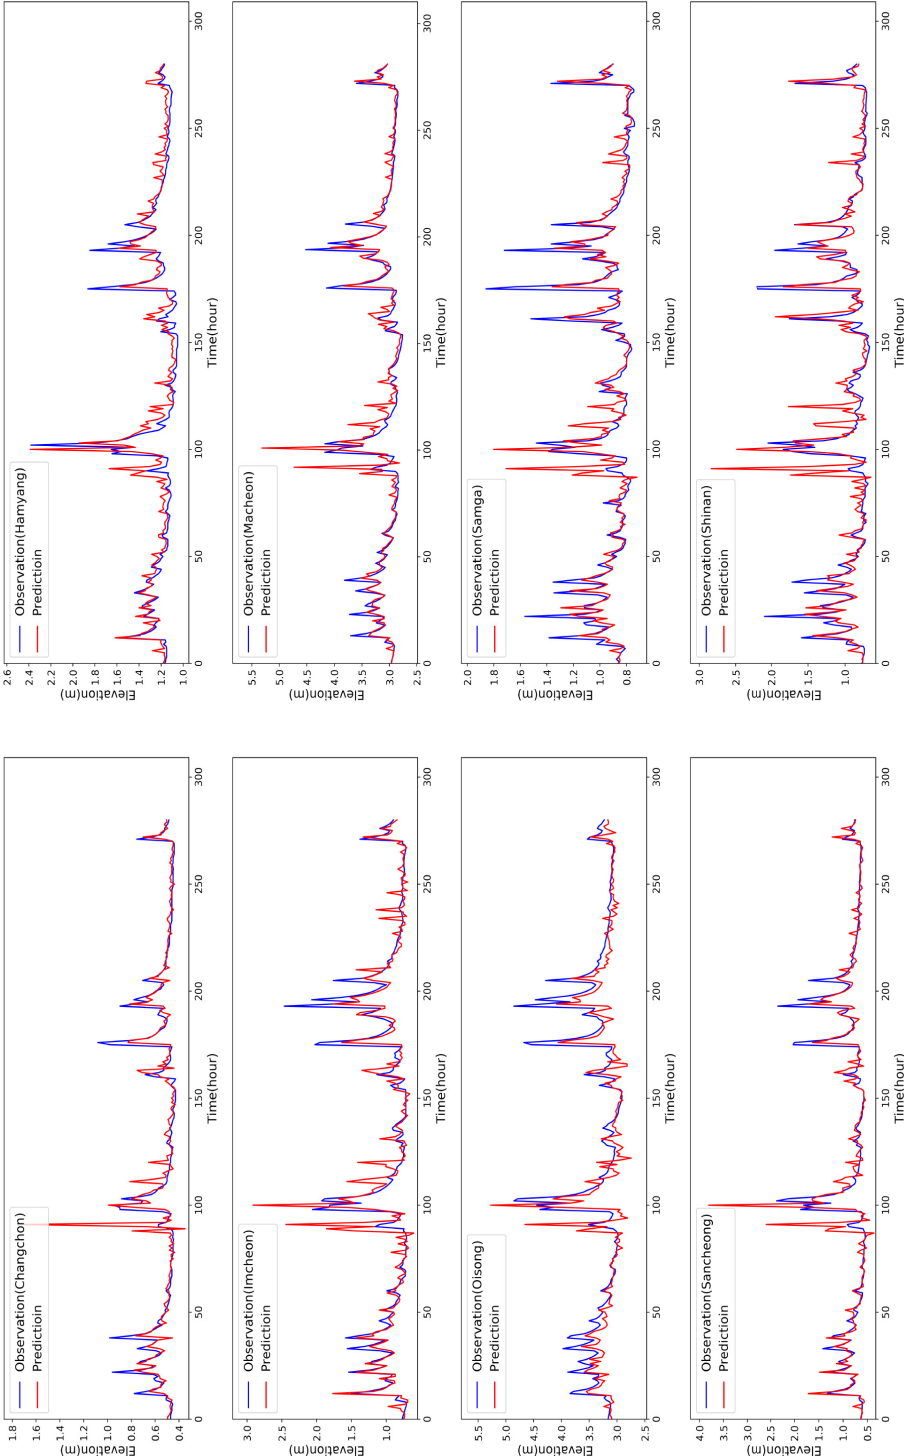
D-2-13. Comparison of scatter plot of 6 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data



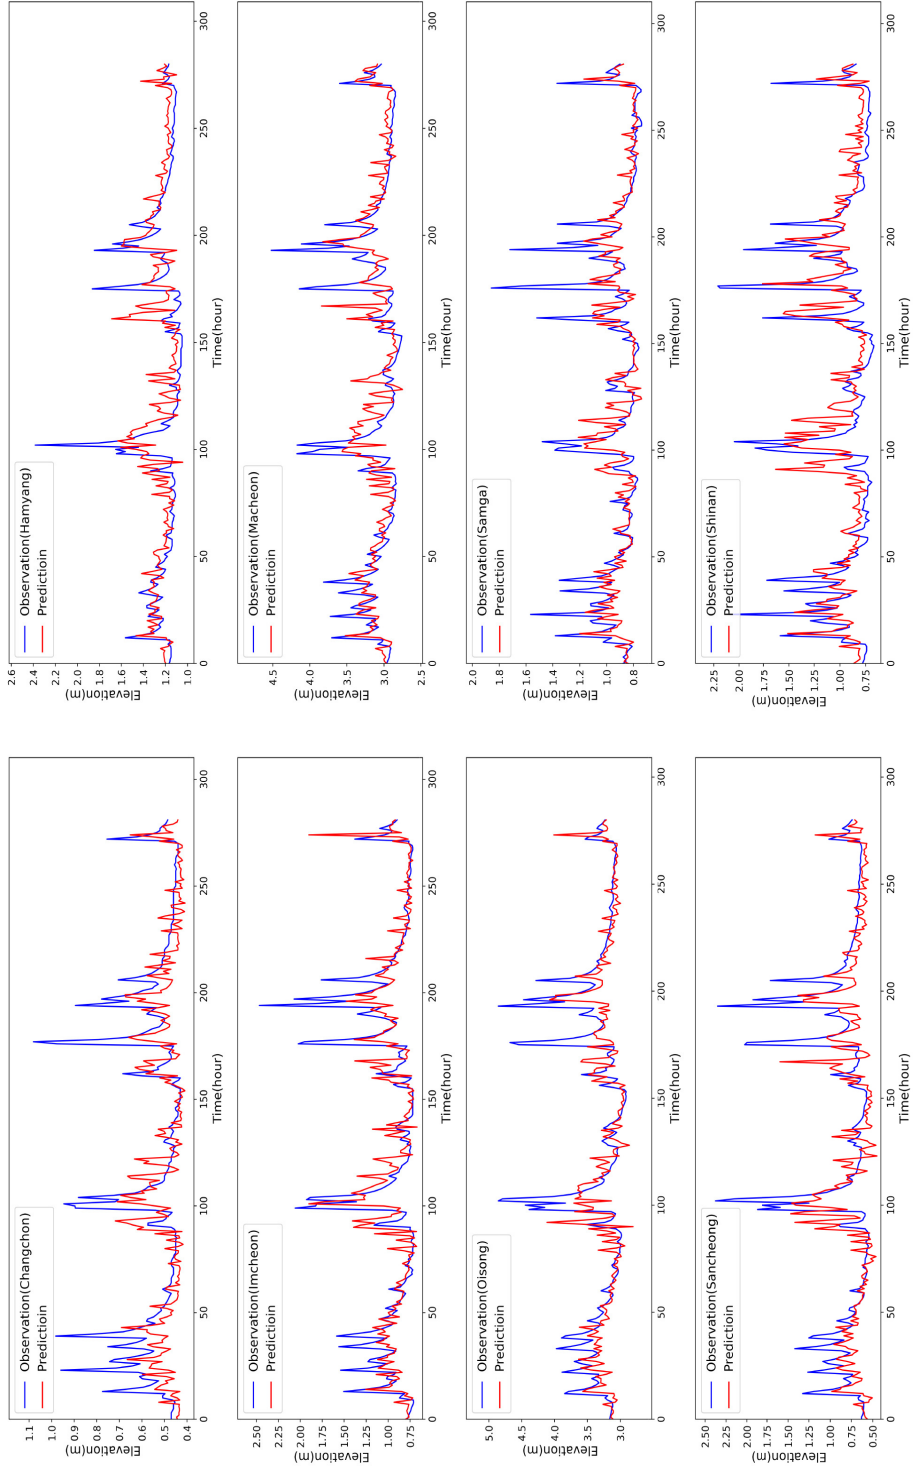
D-2-14. Comparison of scatter plot of 7 day prediction using S2S (40 day interval) with measured water elevation vs. measured water elevation data











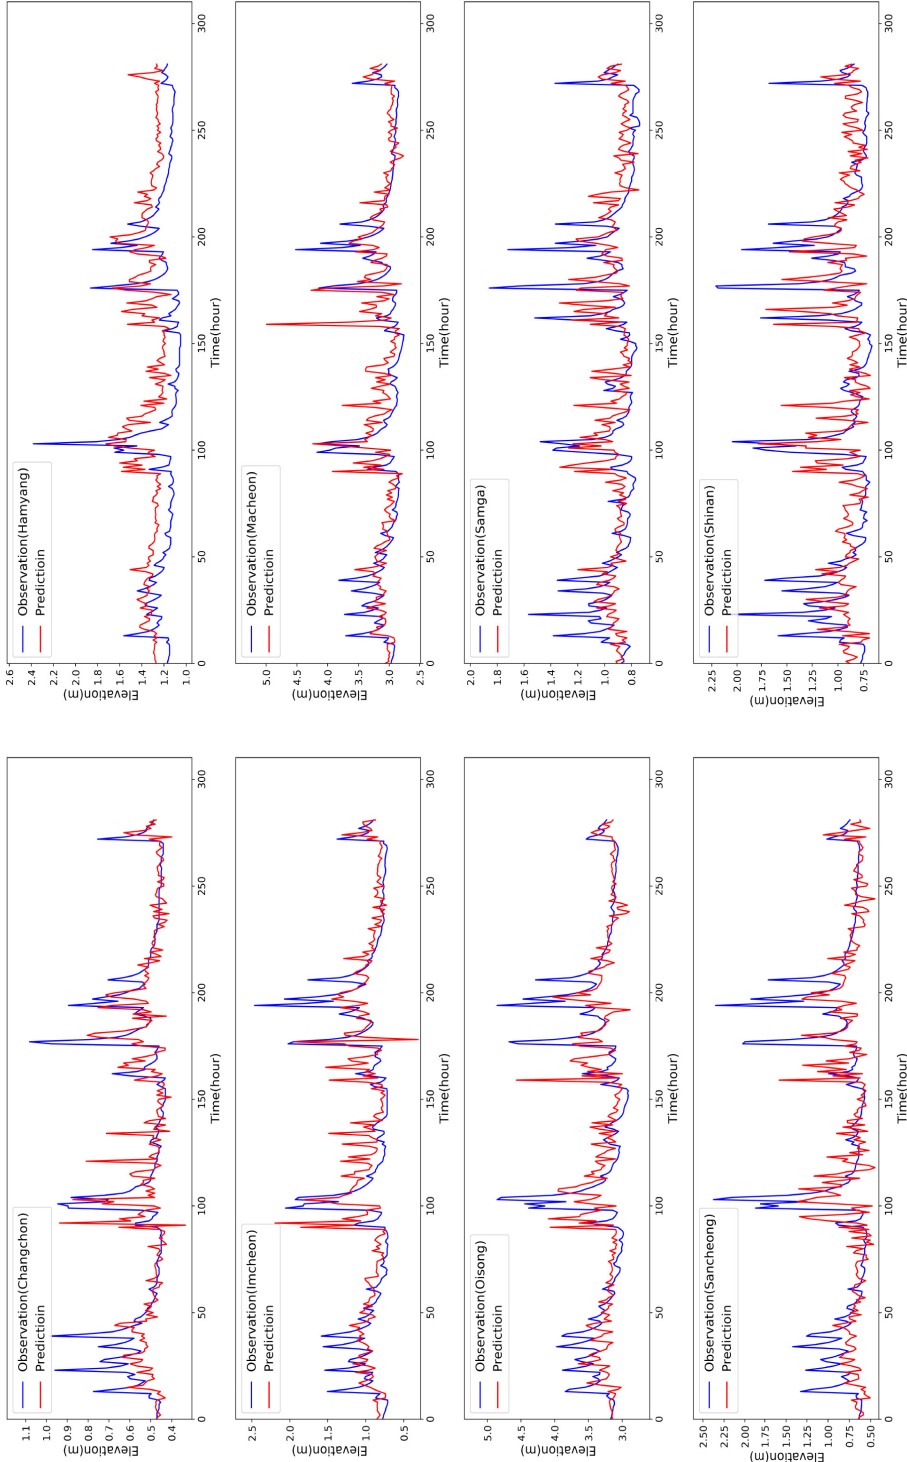
D-3-1. Comparison of 1 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



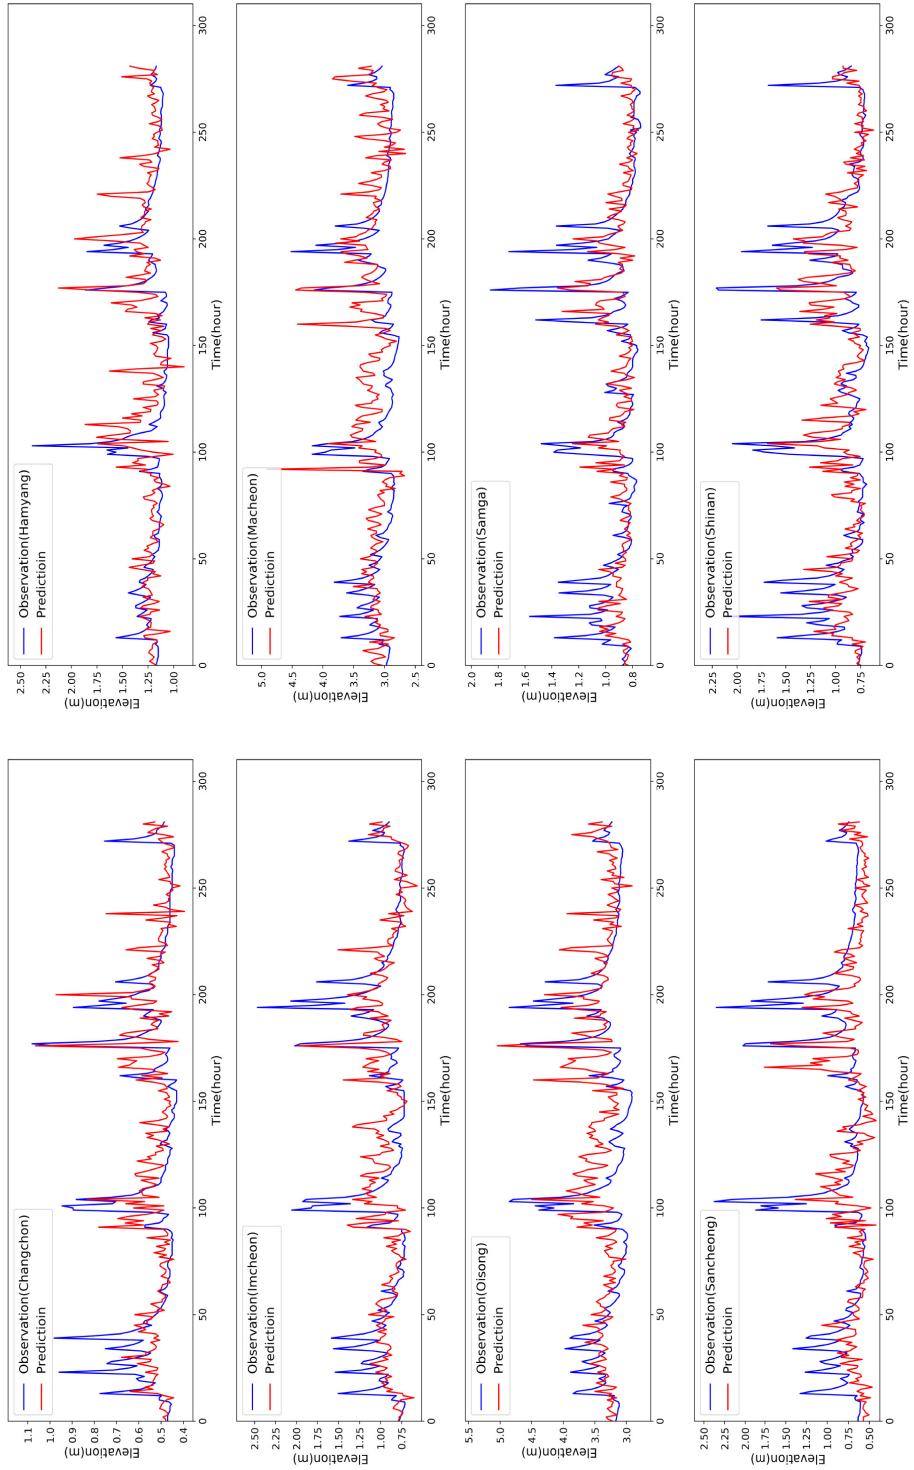
D-3-2. Comparison of 2 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data











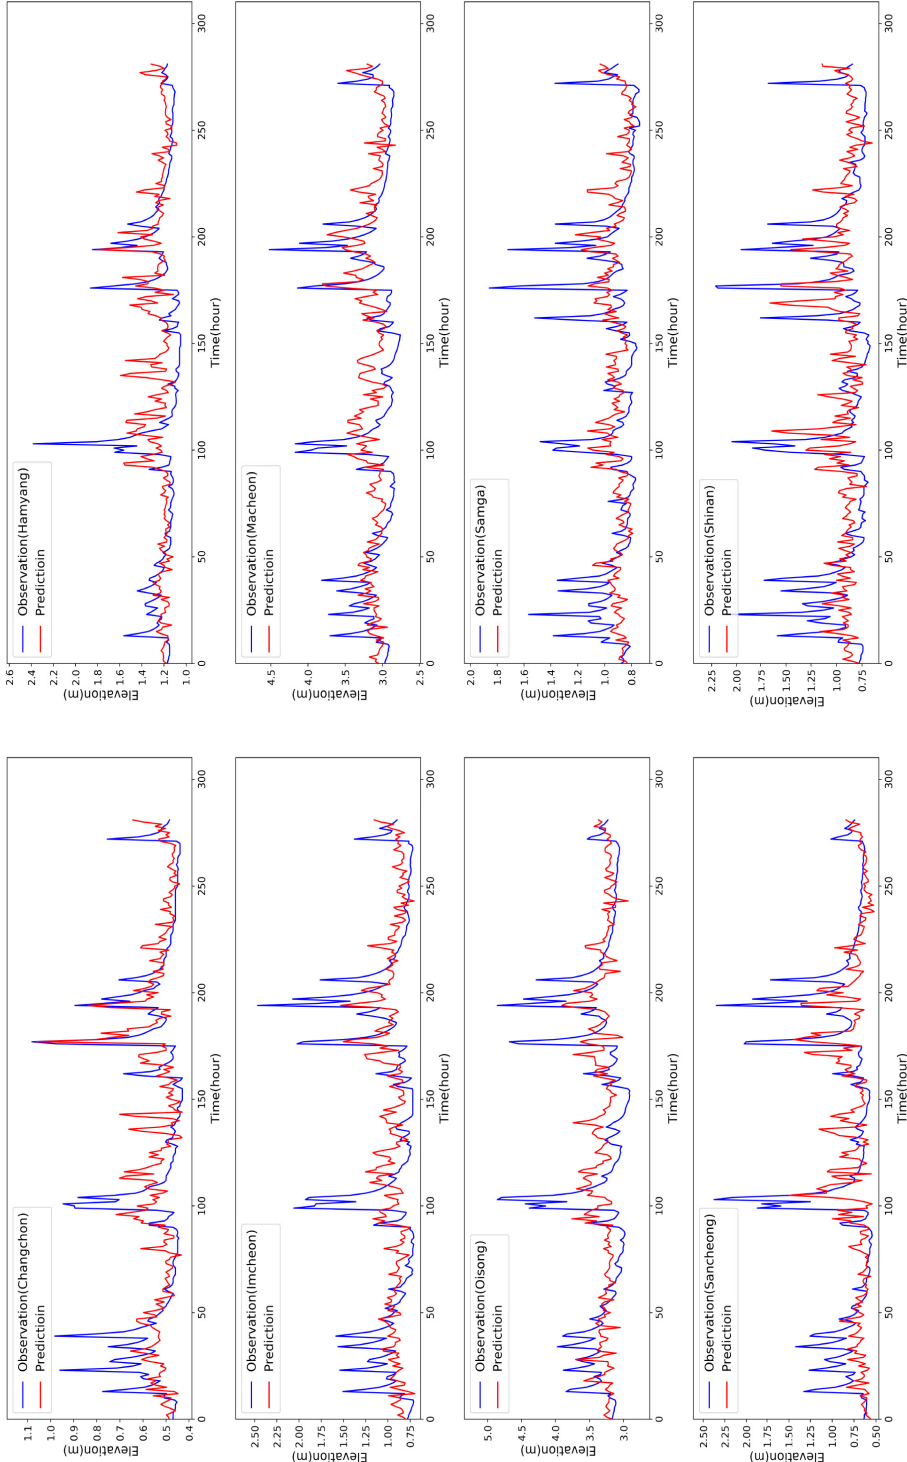
D-3-3. Comparison of 3 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



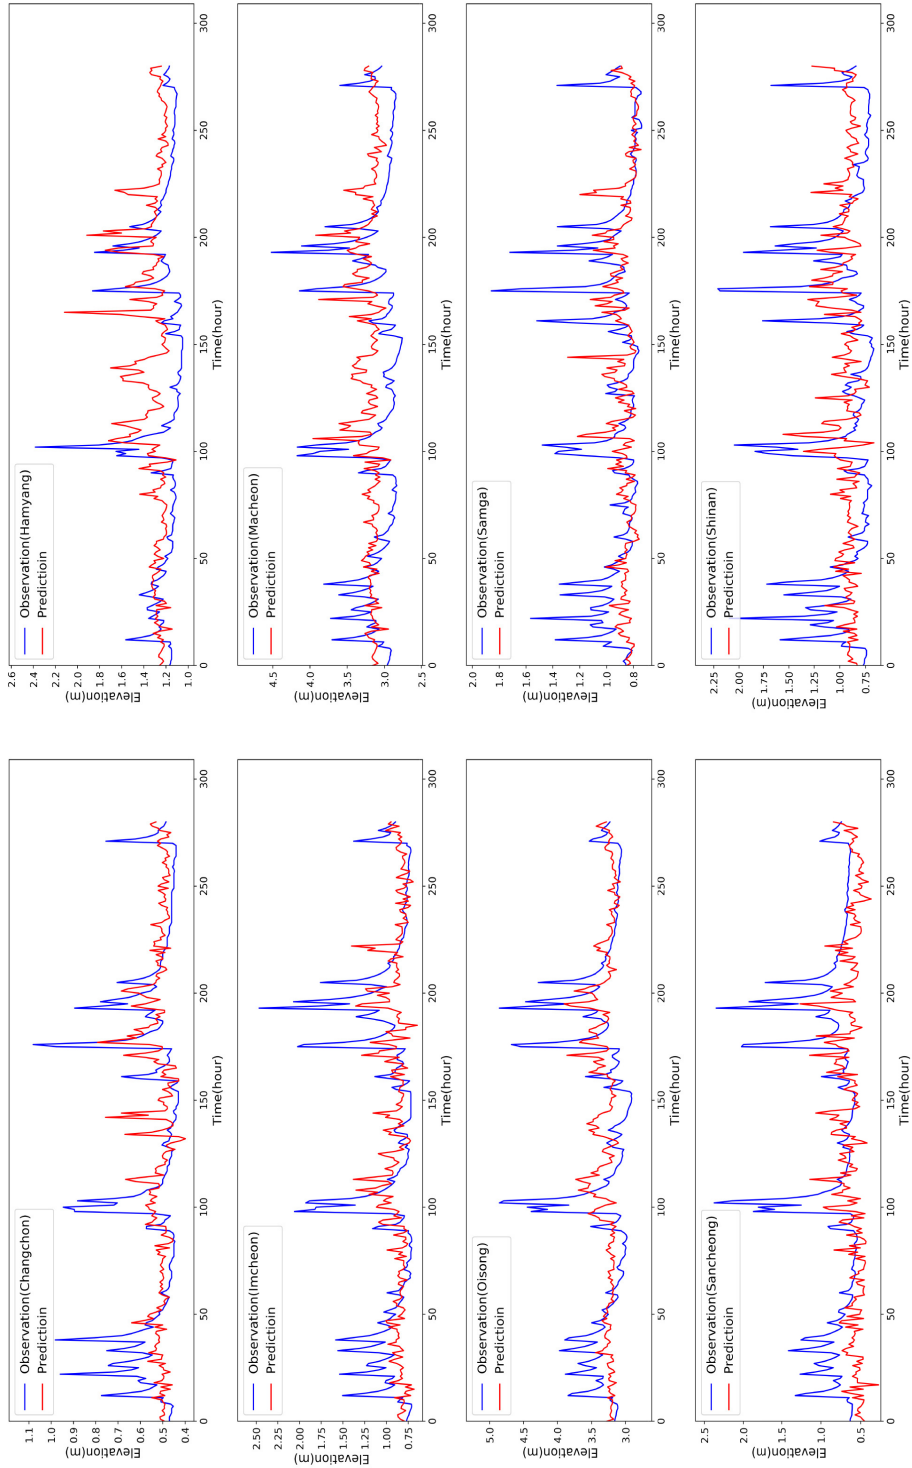
D-3-4. Comparison of 4 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



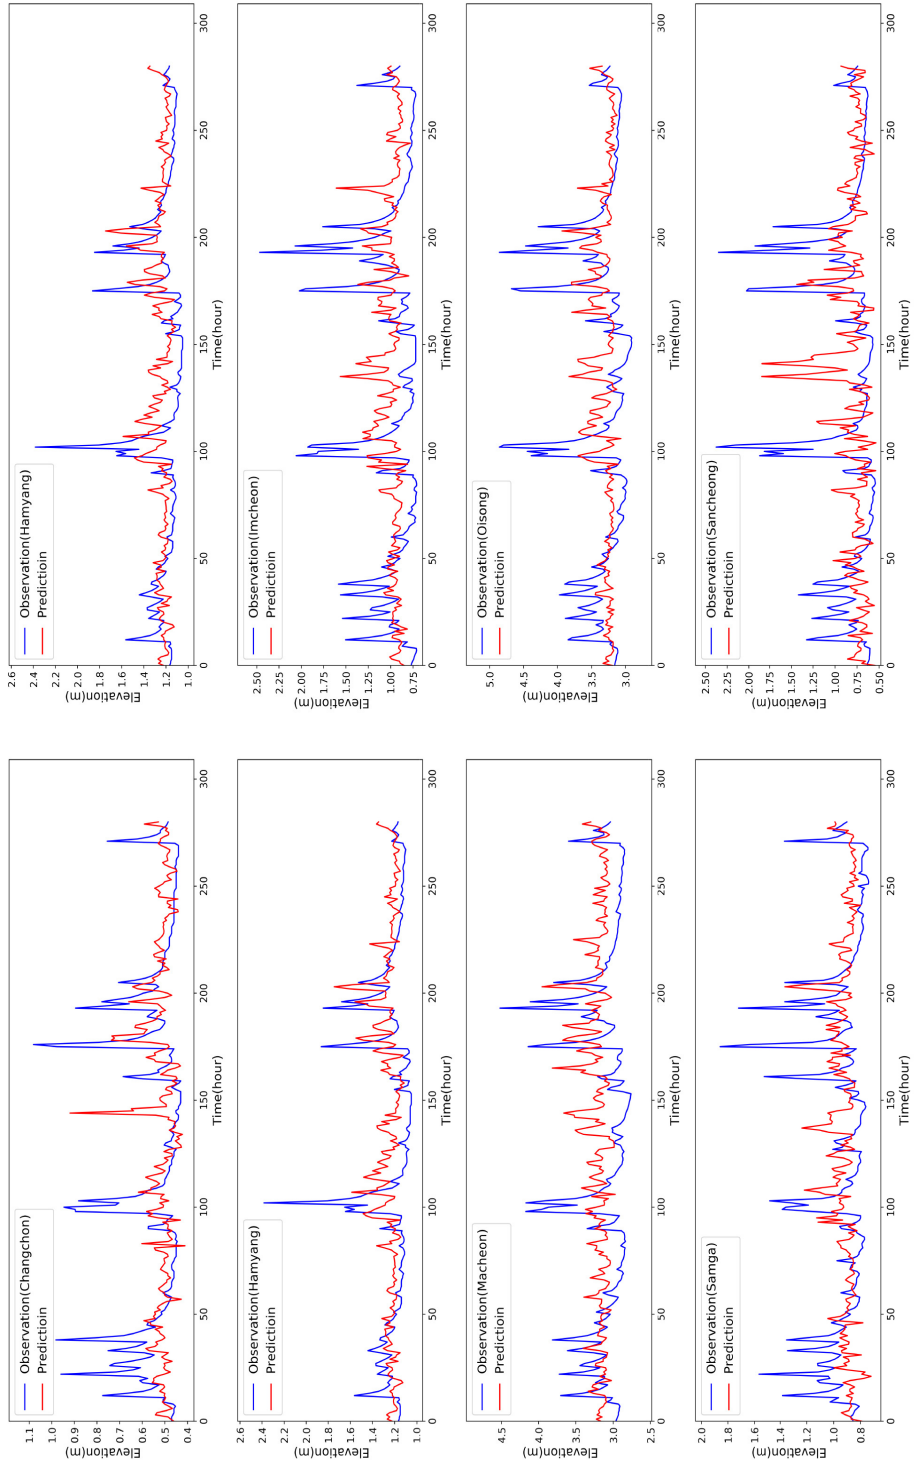
D-3-5. Comparison of 5 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



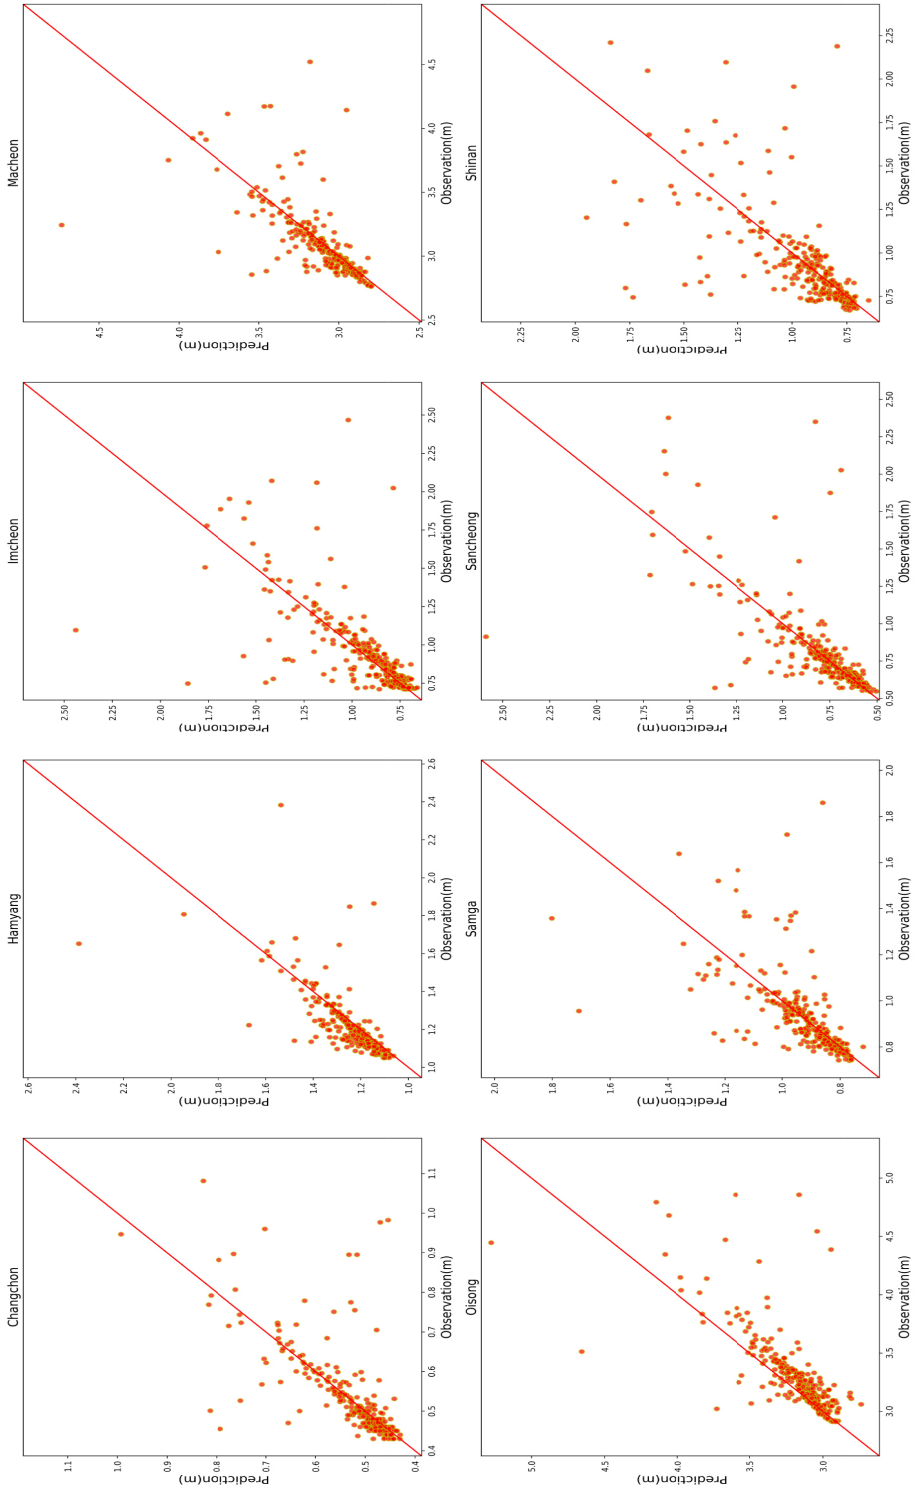
D-3-6. Comparison of 6 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



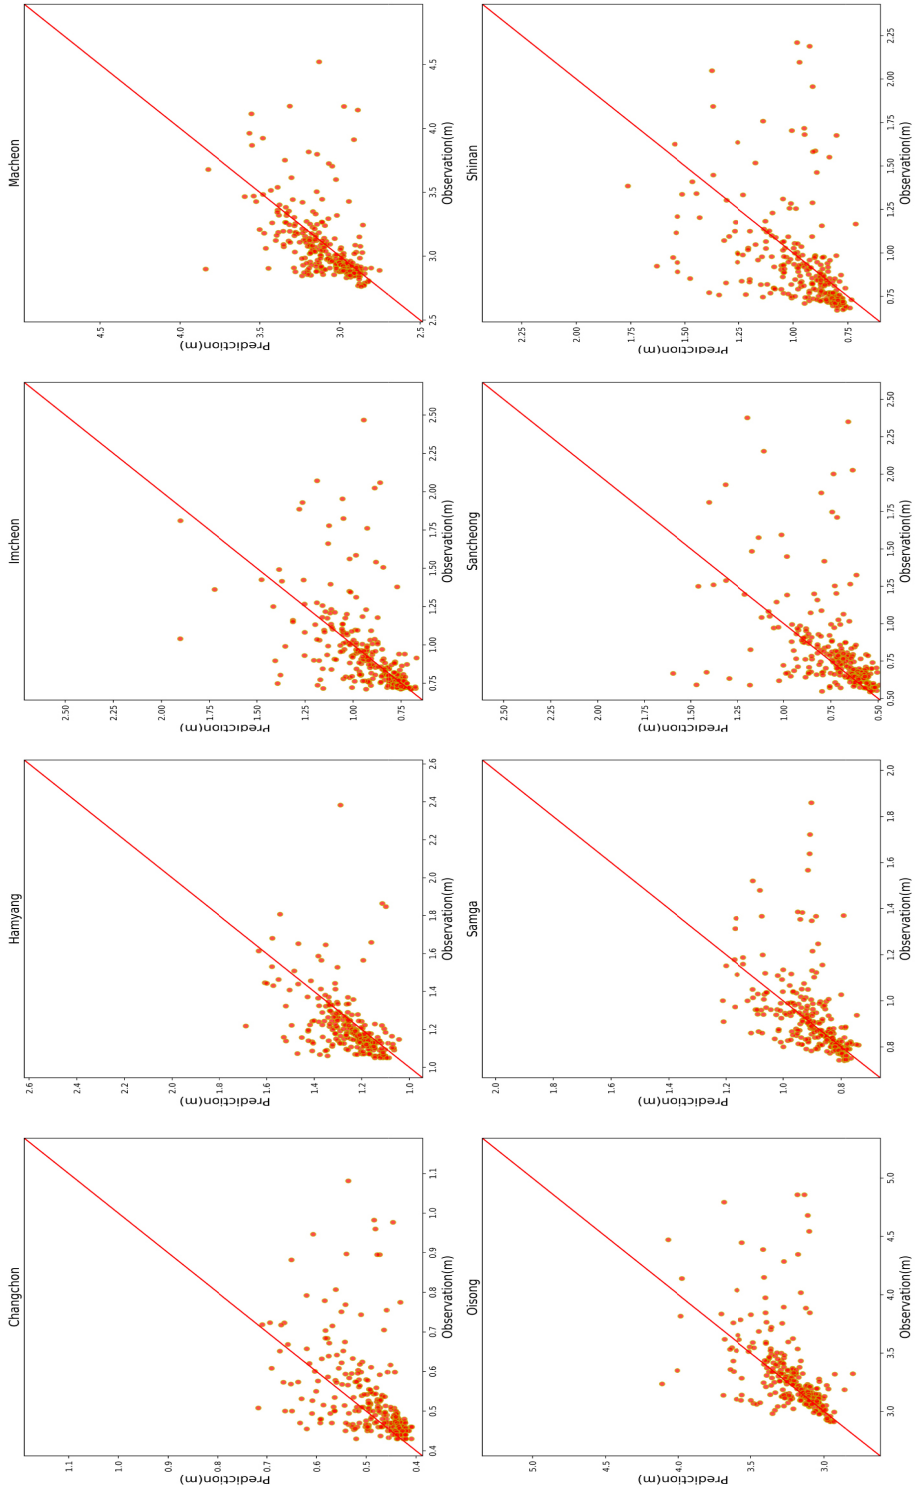
D-3-7. Comparison of 7 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



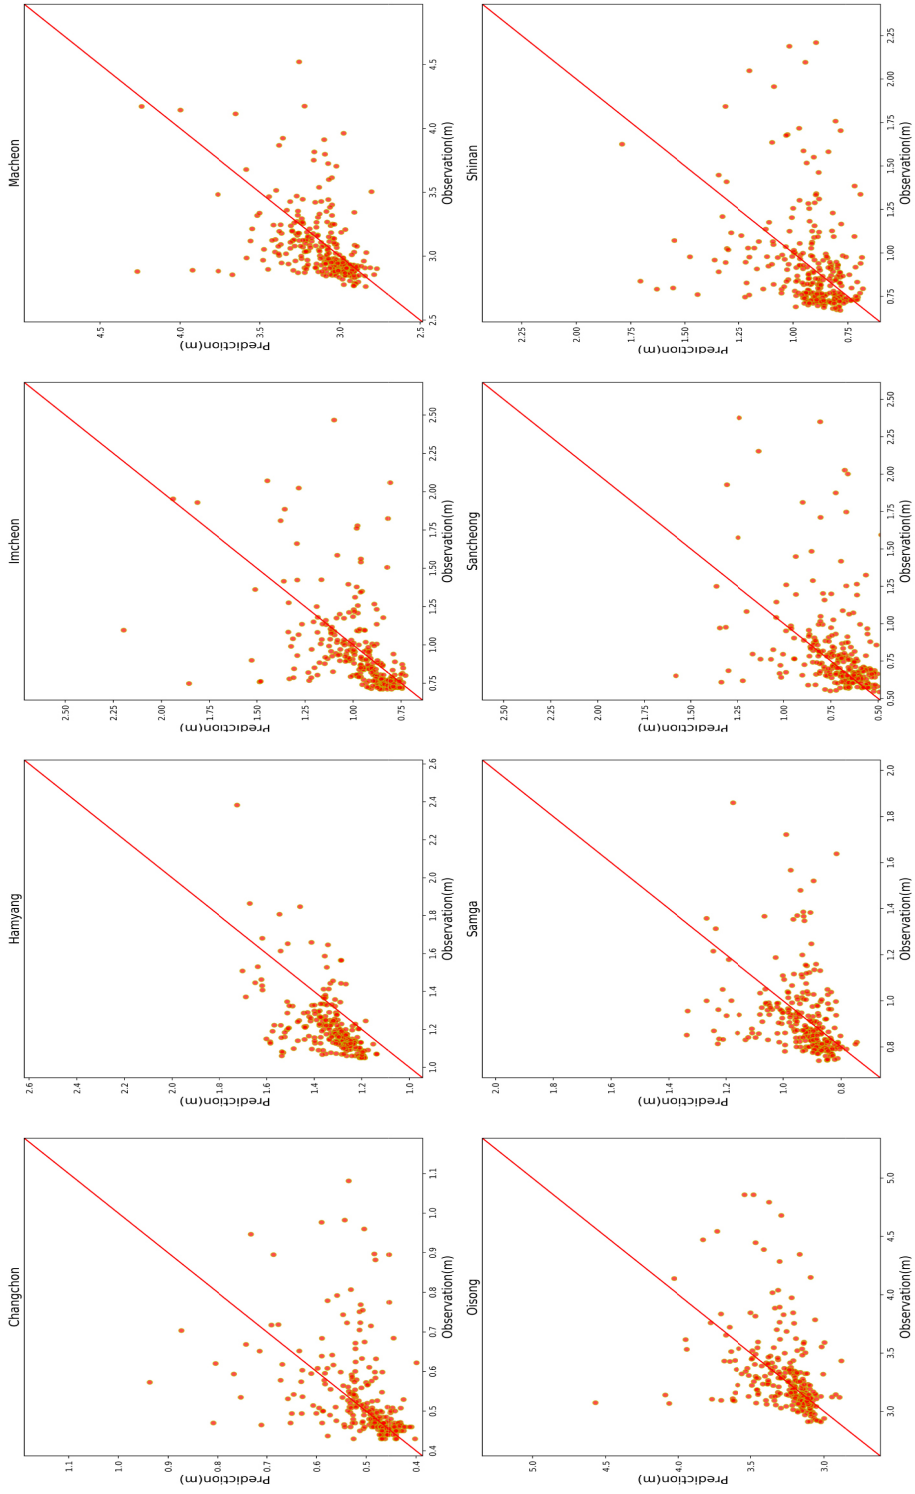
D-3-8. Comparison of scatter plot of 1 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



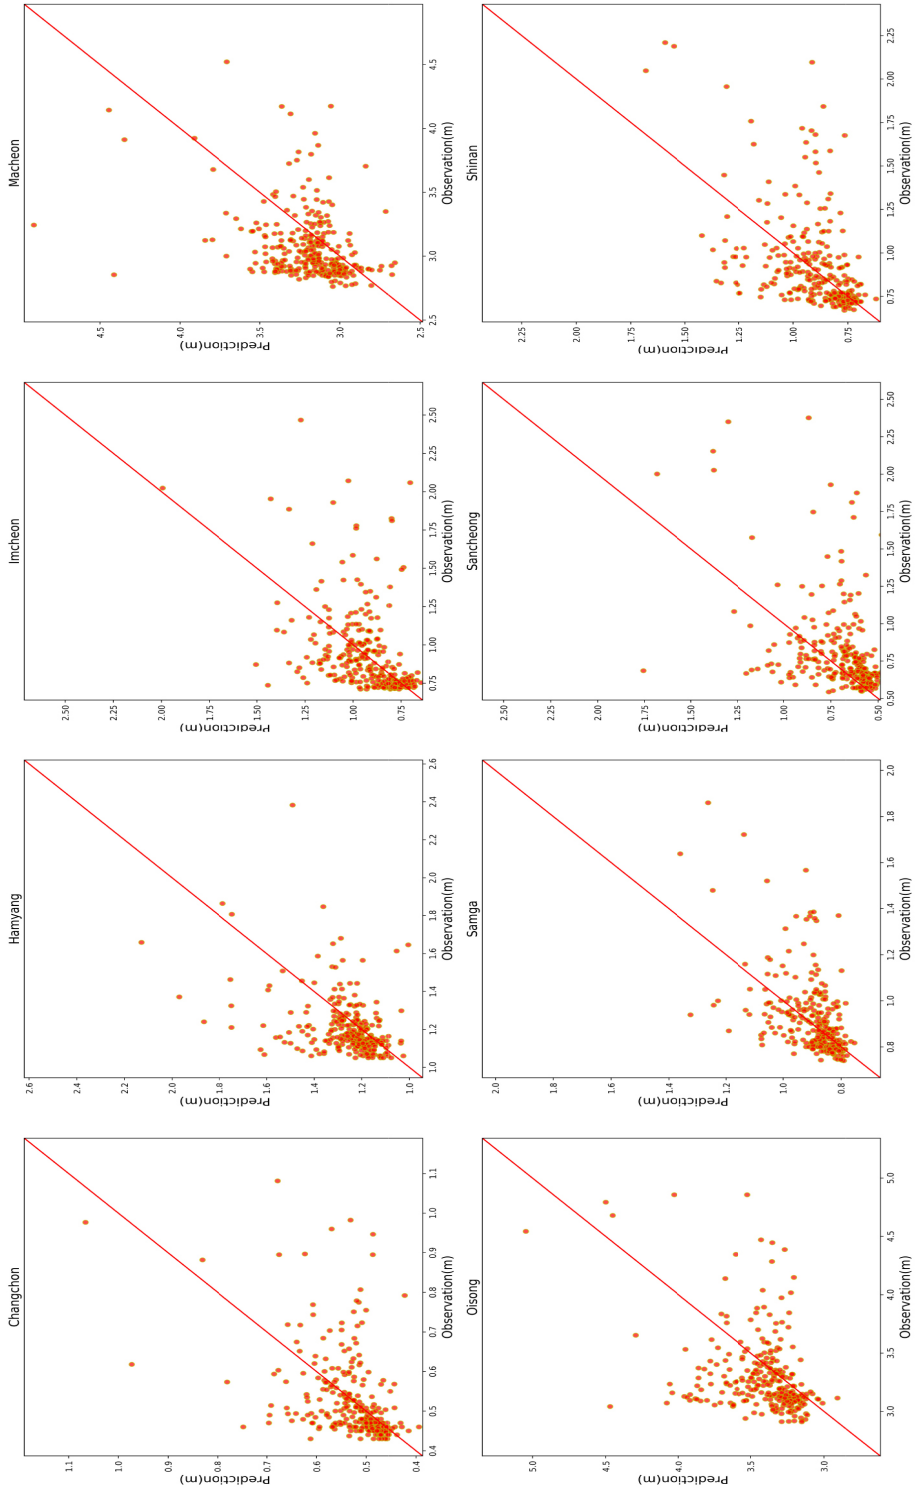
D-3-9. Comparison of scatter plot of 2 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



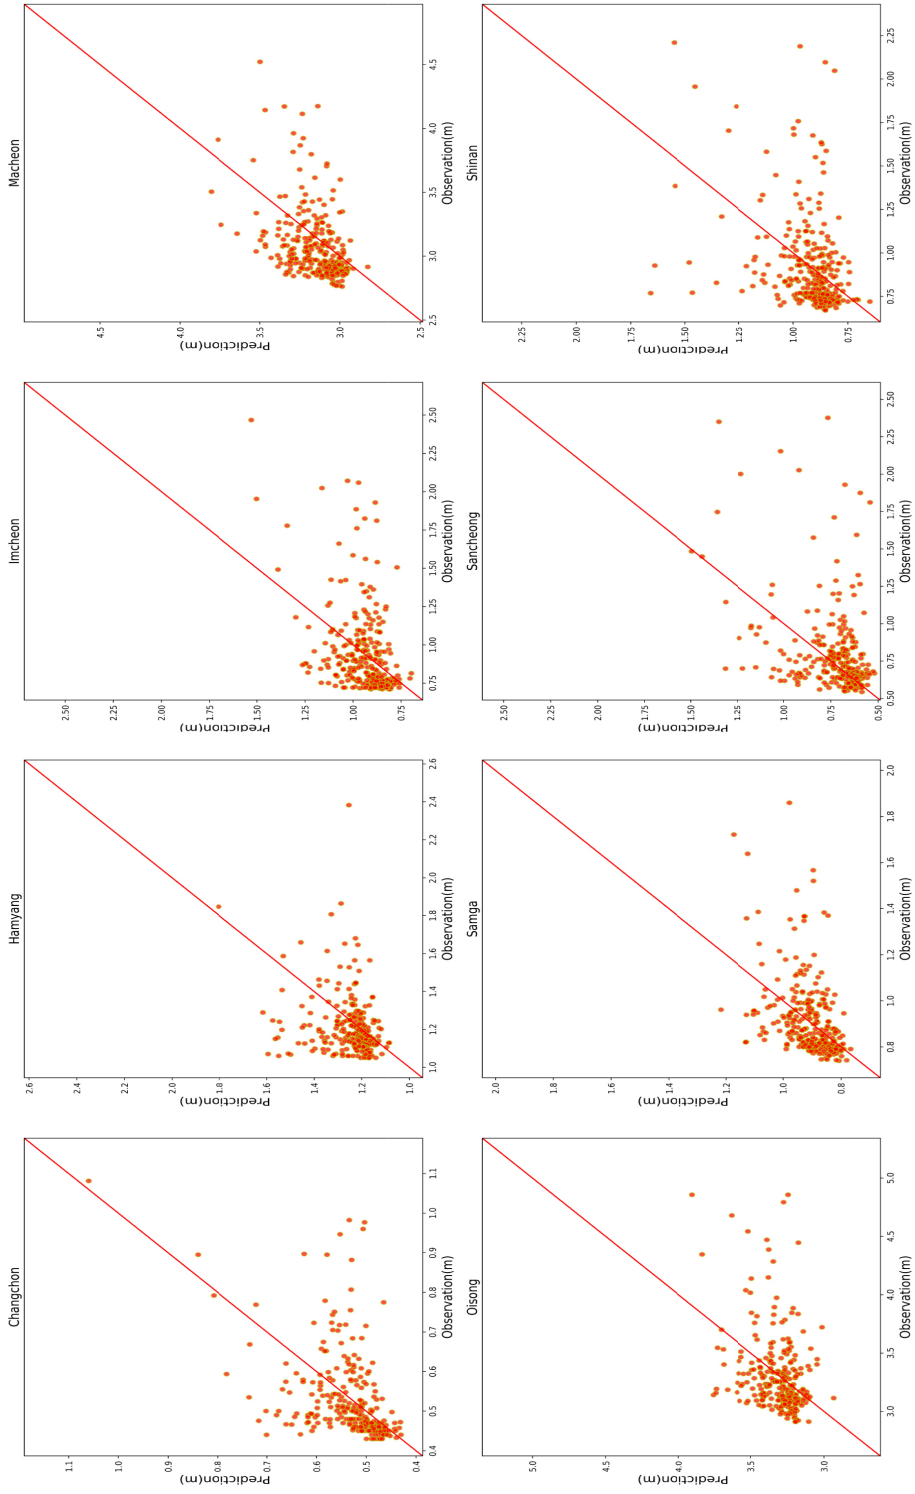
D-3-10. Comparison of scatter plot of 3 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



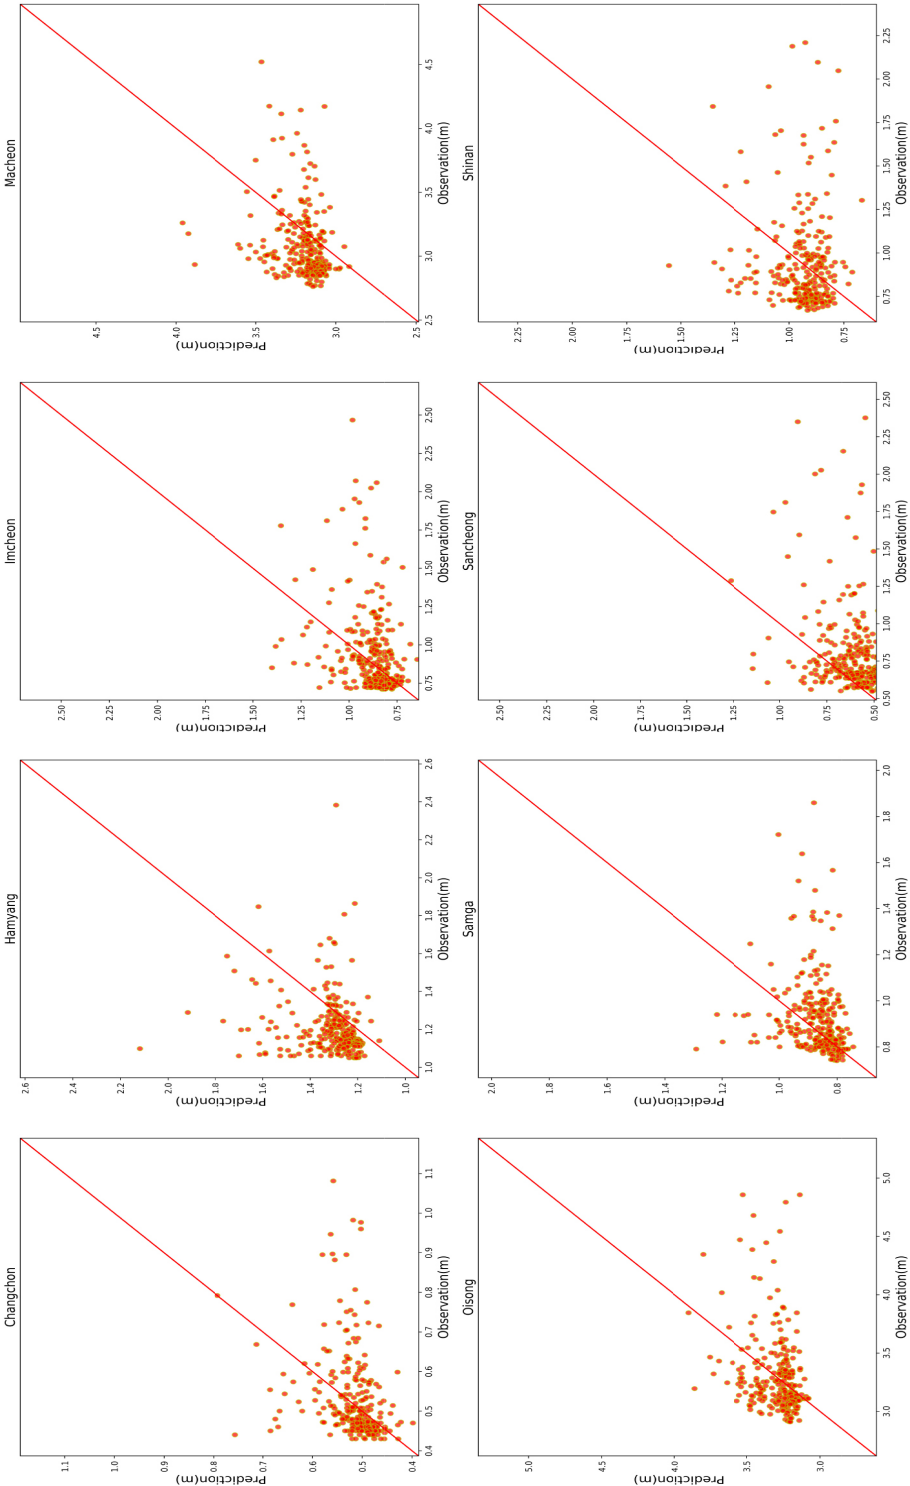
D-3-11. Comparison of scatter plot of 4 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



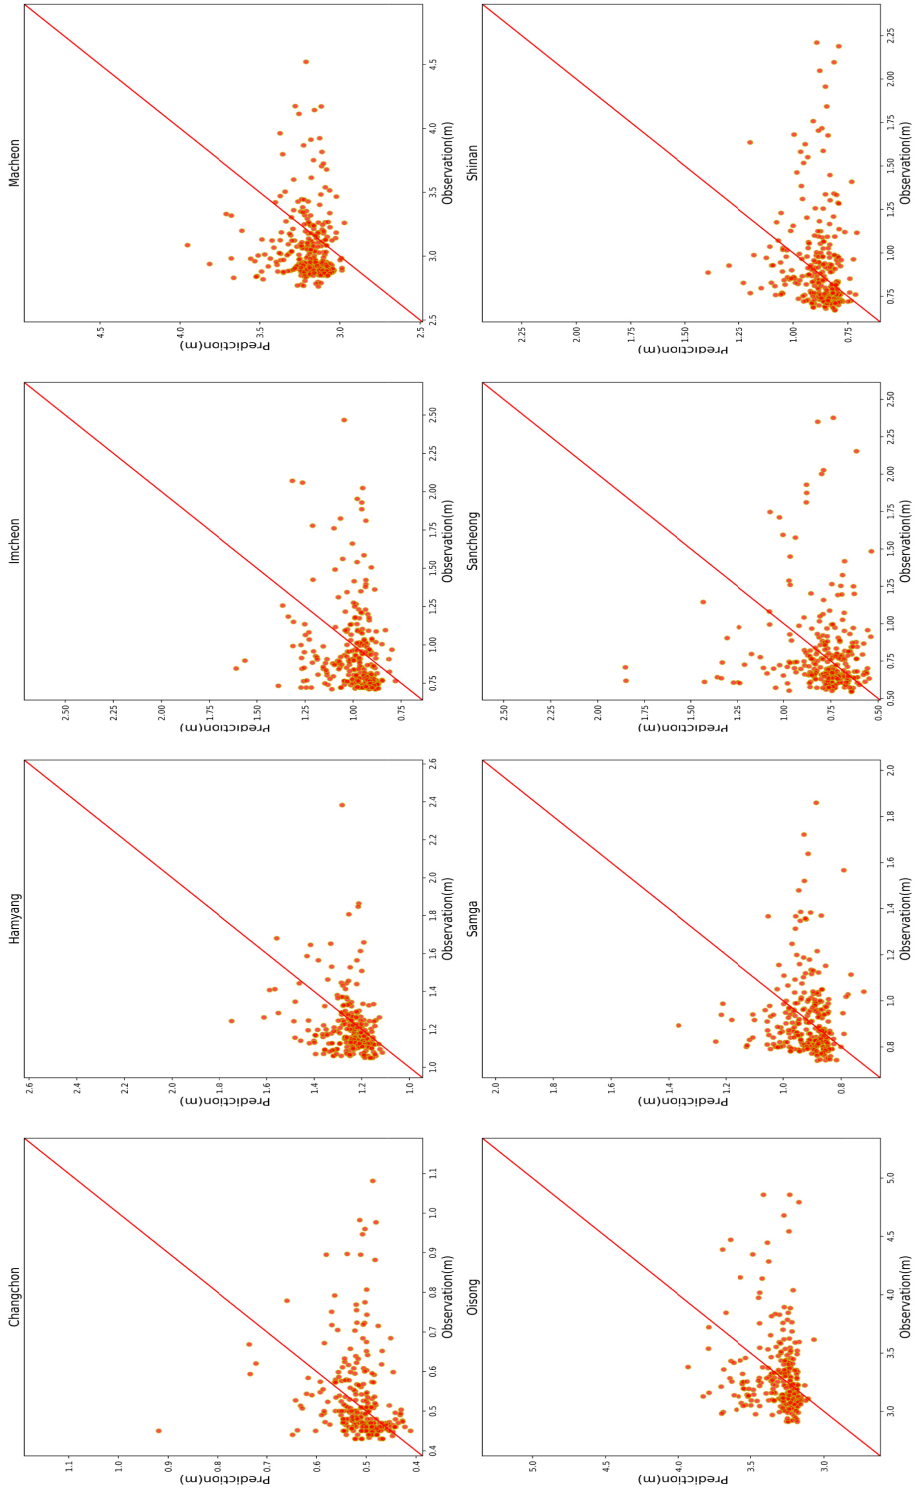
D-3-12. Comparison of scatter plot of 5 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



D-3-13. Comparison of scatter plot of 6 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



D-3-14. Comparison of scatter plot of 7 day prediction using S2S (7 day interval) with measured water elevation vs. measured water elevation data



【연구자】

이승수 선임연구원

연구보고서 2018-17

계절내 예측자료를 이용한 홍수위험도 평가기술 개발

I S B N 979-11-5698-249-4

발 행 2019년 3월

발 행 인 권 원 태

발 행 처 APEC기후센터
부산시 해운대구 센텀7로 12

제작·인쇄 경성문화사

이 보고서는 APEC기후센터 홈페이지(<http://www.apcc21.org/>)에서 이용하실 수 있습니다.
또한 보고서에 실린 내용은 출처를 명시하면 자유롭게 인용할 수 있습니다. 단, 무단 전재 및
복제를 금합니다.