

# GPS 시각전송 측정데이터에 대한 딥러닝 모델 기반 시각오프셋 예측

유동희<sup>1</sup> · 김민호<sup>2\*</sup>

## Deep Learning based Time Offset Estimation in GPS Time Transfer Measurement Data

Dong-Hui Yu<sup>1</sup> · Min-Ho Kim<sup>2\*</sup>

<sup>1</sup>Professor, Department of Software, Catholic University of Pusan, Busan, 46252 Korea

<sup>2\*</sup>Assistant Professor, Department of Software, Catholic University of Pusan, Busan, 46252 Korea

### 요약

본 논문에서는 세계협정시(UTC)를 결정하기 위해 GPS 위성에서 전송된 코드 신호에서 추출한 측정 데이터를 기반으로 한 정밀시각비교 기법에 딥러닝 모델인 LSTM을 적용하여 시각 오프셋을 예측하는 방법을 소개한다. 이를 위해 우선, 하루 단위로 GPS 위성으로부터 수신된 코드 신호에서 시각 정보를 추출하고 하루 단위의 시각 오프셋을 하나의 시계열 데이터로 구축하는 과정을 소개한다. 구축된 시각 오프셋 시계열 데이터에 대해 딥러닝 모델을 적용하는데, 순환신경망 중 하나인 LSTM을 적용하여 GPS의 시각 오프셋 예측을 수행하였다. 본 연구를 통해 GNSS 기반 정밀 시각비교분야에서 딥러닝을 적용한 시각 오프셋 예측의 가능성을 확인하였다.

### ABSTRACT

In this paper, we introduce a method of predicting time offset by applying LSTM, a deep learning model, to a precision time comparison technique based on measurement data extracted from code signals transmitted from GPS satellites to determine Universal Coordinated Time (UTC). First, we introduce a process of extracting time information from code signals received from a GPS satellite on a daily basis and constructing a daily time offset into one time series data. To apply the deep learning model to the constructed time offset time series data, LSTM, one of the recurrent neural networks, was applied to predict the time offset of a GPS satellite. Through this study, the possibility of time offset prediction by applying deep learning in the field of GNSS precise time transfer was confirmed.

**키워드** : GNSS 정밀시각비교, LSTM, 딥러닝, 시각 오프셋, 세계협정시

**Keywords** : GNSS precise time transfer, LSTM, Deep learning, Time offset, UTC

Received 8 October 2021, Revised 10 October 2021, Accepted 9 October 2021

\* Corresponding Author Minho Kim(E-mail: minho@cup.ac.kr, Tel:+82-51-510-0671)

Assistant Professor, Department of Software, Catholic University of Pusan, Busan, 46252 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.3.456>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서론

전 세계 정보 인프라들은 국제적으로 통일된 표준 시각 동기(Time Synchronization) 체계인 세계협정시(UTC, Universal Time Coordinated)를 기반으로 운영된다. 국제도량형국(BIPM, Bureau International de Poids et Mesures)에서는 국제원자시인 TAI(International Atomic Time)를 생성하고 세계협정시를 결정하기 위한 방법 중 하나로 GNSS(Global Navigation Satellite System)를 이용한 시간주파수 비교기술을 이용하고 있다.

GNSS는 정확한 시간을 생성하기 위해 원자시계를 탑재하고 있다. GNSS 위성 시계의 모니터링과 정밀시각조정은 지상국에서 담당한다. 이를 위해 지상국은 별도의 원자시계를 이용해서 시간을 생성하는데 더 정확하고 안정적인 시간 생성을 위해 앙상블 시계를 사용하고 있으며 세슘원자 분수시계나 광 시계와 같은 새로운 정밀 원자시계에 대한 연구가 진행되고 있다. 앙상블(ensemble) 시계는 UTC가 대표적이며 기존의 원자시계들을 결합한 시간으로 물리적 시계가 아닌 가상의 시계이다. UTC는 세계 80여개 정밀시각 관련 연구기관에서 생성하고 관리하는 해당 국가의 표준시간인 UTC(k)들과의 정밀시각비교를 통해 생성된다. 앙상블 시계를 사용하는 것은 앙상블을 구성하는 개별 시계들 보다 더 우수한 성능을 얻을 수 있기 때문이다.

정밀시각비교를 통해 다양한 시스템간의 시계를 동기화하는 기술을 정밀시각동기 기술이라고 한다. GNSS 기반 정밀시각동기 기술은 국제원자시나 세계협정시의 유지뿐만 아니라 산업·경제·사회분야의 기반기술로 다양하게 활용되고 있다.

GNSS 기반 정밀시각비교는 코드와 반송파로 구분하여 처리하는데 본 논문에서는 코드를 이용한 시각비교를 대상으로 한다. GNSS 위성이 송출하는 코드 신호는 지상의 수신기까지 전파되면서 그림 1과 같이 다양한 오차 요인들이 추가된다.

정밀한 시각비교를 위해서 각국의 정밀시각 연구기관은 GNSS 정밀시각 수신기에서 수신한 코드 신호에서 추출한 측정 데이터로부터 위성에서 지상의 해당 수신기까지 전파과정에서 발생하는 각종 오차 요소들을 후처리로 제거하여 위성과 지상 수신기 간의 시각 오프셋을 추출한다. 이렇게 처리된 전 세계 80여개 정밀시각 연구기관의 시각 오프셋 값들을 BIPM에서 수집하고 비

교하여 최적의 앙상블 시계를 생성한다.

GNSS를 기반으로 하는 거의 모든 정보 인프라들은 GNSS 신호에 의존적인데 GNSS 신호가 중단되거나 수신될 수 없는 상황 또는 재밍이나 시스템의 이상 등으로 이상치가 추출된다면 심각한 사회문제가 발생할 수도 있다.

국내의 GNSS 신호에 대한 이상치 탐지에 대한 연구는 GNSS 신호로부터 시각 오프셋 추출에 대한 연구가 보편적이지 않아 아직 활발하지 않은 편이고 심화학습이 적용한 사례는 없다[1]. 국외에서도 GNSS 신호에 딥러닝을 적용하는 연구가 최근 진행되는 추세이다[2].

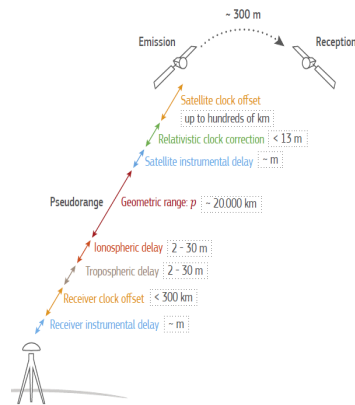


Fig. 1 Transmission of Satellite Code Signal

GNSS 측정 데이터는 위성에 탑재된 원자시계와 지상의 정밀시각수신기 시계의 특성이 반영된 데이터로 시간의 흐름에 따라 변화한다. 따라서 음성, 자연어 문장, 주식 가격 등의 데이터와 같이 그 구성 요소가 순차적으로 발생하고 구성 요소 간에 순서가 있는 즉, 이전 값들이 현재의 값에 연관이 있는 서열 데이터(sequence data)로 분류할 수 있다.

이런 시간적 특징을 가진 데이터에 대한 분류나 예측 등은 현 시점의 값뿐만 아니라 이전 시점의 값들을 고려할 필요가 있다. 이런 서열 데이터에 적용될 수 있는 대표적인 신경망 모델로 순환신경망(RNN, Recurrent Neural Network)이 있다.

이에 본 논문에서는 GNSS 기반 정밀시각비교에서 추출된 시각오프셋에 대해 딥러닝 기술을 적용하여 시각오프셋을 예측할 수 있음을 제안하고자 한다. 2장에서는 관련 연구로 GNSS 기반 정밀시각비교 기술과 딥러닝에 대해 소개하고 3장에서는 GNSS 측정 데이터로부터 추출된 시각오프셋 데이터에 딥러닝 기술의 적용

과정을 설명한다. 4장에서는 예측 결과를 제시하고 5장에서 결론을 맺는다.

## II. 관련 연구

### 2.1. GNSS 기반 정밀시각비교

GNSS는 GPS에서 시작되어 현재 Glonass, Beidou, Galileo 등 많은 시스템이 운영되고 있으며 GNSS 코드 신호를 이용한 시각 오프셋 추출은 전 세계적으로 표준화된 절차를 따르고 있다[3]. 본 논문에서는 GPS 코드 신호를 대상으로 시각 오프셋을 추출하였다. 시각 오프셋 추출은 그 데이터의 공신력을 위해 전 세계 정밀시각 연구기관에서 사용하고 있는 공인된 r2cggts 프로그램을 사용해야 한다.

GNSS 코드 신호로부터 시각 오프셋 추출은 수신기가 제공하는 rinex 포맷의 관측파일(observation file)과 항법 메시지(Navigation message)내의 정보들을 이용한다. 그림 1에서 제시한 바와 같이 코드 신호 전파 시 위성의 시계 오차, 위성의 궤도 오차, 수신기의 시계오차, 다중경로 오차, 대기를 통과할 때 발생하는 이온층 지연 및 대류층 지연 등이 오차 요소로 작용하고 (식 1)은 위성의 코드 신호가 지상 수신기에 전파되면서 반영되는 오차 요인들을 표현한 식이다.  $P_{1,2}$ 는 P1, P2 코드 신호이며,  $\rho$ 는 위성으로부터 수신기까지의 기하학적 거리로 항법메시지의 위성 궤도 정보와 수신기의 위치를 이용해서 구한다.

$$P_{1,2} = \rho_{1,2} - c\Delta t_{rec} + c\Delta t_{sat} + I_{1,2} + Tr + \delta_{1,2}^P + \epsilon_{1,2}^P \quad (1)$$

$c$ 는 빛의 속도,  $\Delta t_{rec}$ 는 수신기와 위성간의 시각비교 결과로써 최종 결과인 시각오프셋 값이다.  $\Delta t_{sat}$ 는 위성 시계의 오프셋으로 보정을 위해 GPS의 항법 메시지에 다항식의 계수들이 제공된다.  $I_{1,2}$ 는 P1, P2 코드 각각의 이온층 지연,  $Tr$ 은 대류층 지연,  $\delta_{1,2}^P$ 는 위성 하드웨어 지연이고  $\epsilon_{1,2}^P$ 는 노이즈 값이다. 이온층 지연은 P1, P2로부터 이온층 프리조합을 수행해서 얻은 P3 코드를 이용하여 제거할 수 있으며 대류층 지연은 Niel 매핑함수와 Saastamoinen 등의 대류층 지연 모델을 적용하여 제거한다. 2시간마다 수정·방송되는 항법 메시지에서 사냥 효과, 위성 시계 오차인  $\Delta t_{sat}$ , 위성 하드웨어 지연에

대한 바이어스 값을 이용해서 보정할 수 있으며 기타 수신기 케이블 지연 등도 고려해서 보다 정확한 시각비교 결과를 구한다.

### 2.2. 시계열 데이터 예측을 위한 딥러닝 모델

최근 딥러닝과 같은 머신러닝 기법을 다양한 분류나 예측에 적용하는 연구가 활발히 진행되고 있으며 특히 시계열 데이터에 대해서는 순환신경망 모델이 많이 사용되고 있다. 시간의 순서를 갖는 시계열 데이터에서는 이전 값들이 현재 값에 영향을 주는 경우가 많기 때문에 시계열 데이터들에 대한 분류나 예측은 현재 시점의 값과 이전 값들을 같이 고려하도록 한다[4]. 즉, 순환신경망은 시점  $t$ 에서 이전 시점  $t-1$ 의 상태를 입력으로 받는 구조로 이전의 정보가 현 시점  $t$ 에 영향을 주게 된다. 순환신경망은 이론적으로 모든 이전 시점의 상태가 영향을 줄 수 있지만 초기 시점은 학습이 길어질수록 영향력이 거의 없어지는 문제가 발생하는데 이를 장기 의존성 문제라고 한다.

LSTM(Long Short-Term Memory)은 기본 메모리 셀의 장기 의존성 문제를 해결하고 학습 또한 빠르게 수렴하는 특징이 있다. LSTM의 핵심은 그림 2에 제시된 바와 같이 네트워크가 장기 상태( $c_t$ )에서 기억할 부분, 삭제할 부분, 읽어 들일 부분을 학습하는 것이다.




Fig. 2 LSTM cell structure

장기 기억  $c_{t-1}$ 은 셀의 왼쪽에서 오른쪽으로 망각 게이트를 지나면서 일부 정보를 잃는 대신 입력 게이트로부터 새로운 기억 일부를 추가하게 된다[5,6].

시계열은 연속적인 숫자 데이터의 연속으로서 일정 간격마다 측정되며 주어진 시계열에 대한 딥러닝 기반 시계열 분석은 함수  $f$ 를 찾는 것이 목적이다.

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \quad (1)$$

### III. 딥러닝 기반 GPS 시각오프셋 예측

#### 3.1. GNSS 측정 데이터

본 논문에서는 GPS 시각전송 측정데이터로 NASA에서 제공하는 데이터를 사용하였다. 측정데이터는 벨기에 ROB 연구소에서 측정한 2014년 7월 3일부터 2014년 12월 31일까지 1번 위성으로부터 측정된 총 4,786 개의 시계열 데이터를 적용하였다.

위성의 시각오프셋 데이터를 추출하기 위한 단계는 다음과 같다. 1단계는 일별 측정데이터인 GPS 관측파일과 항법메시지를 다운받는 것이다. GNSS 관측파일과 항법메시지는 NASA가 관리하고 있는 일별 GPS 관측파일과 항법 메시지 제공 사이트(<https://cddis.nasa.gov/archive/gnss/data/daily/>)에서 ROB의 일별 데이터들을 해당 디렉터리로부터 개별적으로 다운받는다.

2단계로 다운받은 관측 파일들로부터 시각 오프셋을 추출하기 위한 r2cggts 프로그램을 실행한다. 시각 오프셋의 정확성을 확보하기 위해 전 세계의 정밀시각 연구기관에게 허가된 r2cggts 프로그램을 사용하였다. r2cggts 프로그램을 실행하기 위해서는 해당 관측 연구기관의 정확한 수신기 위치 좌표, 수신기 타입, 안테나로부터 수신기까지의 거리, 윤초 등의 설정을 위한 파라미터 파일인 paramCGGTTS.dat 이 준비되어야 한다. r2cggts 프로그램이 성공적으로 실행되고 나면 CGGTTS 파일 형식의 시각오프셋이 포함된 결과 파일이 일별로 생성된다[7,8].

CGGTTS 포맷에서 날짜는 MJD(Modified Julian Day)로 표현하고 STTIME이 hhhmmss의 표기에 따른 시, 분, 초를 의미한다. GPS 위성은 정지위성이 아니므로 위성이 관측 가능한 시간이 일정하지 않다. 일단 스테이션에서 관측이 되면 16분 간격으로 처리하도록 표준화되어 있다. ELV는 위성에 대한 양각이고 AZTH는 방위각을 나타낸다. REFSYS는 추출된 관측 위성인 1번 위성과 ROB에서 관리하는 BRUX 스테이션의 Trimble NETR9 1.2-0수신기 사이의 r2cggts 프로그램의 실행 결과인 시각 오프셋이다.

CGGTTS 파일의 여러 속성 중 시각오프셋에 해당하는 필드는 REFSYS 값으로, 해당 위성과 지상 정밀시각 수신기와의 시각비교 결과이며 일별로 생성된 REFSYS 값들을 하나의 csv 파일로 변환하면 데이터 구축이 완료된다. 그림 3은 CGGTTS 파일 내용에서 본 연구에 사용

할 단일 변량인 REFSYS와 시간 서열을 포함하여 학습에 사용될 학습데이터가 구축된 결과이다.

	MJD	STTIME	ELV	AZTH	REFSYS
0	56841	200	403	1413	1593
1	56841	1800	331	1440	1600
2	56841	3400	259	1463	1596
3	56841	5000	189	1484	1608
4	56841	10600	121	1502	1613
...	...	...	...	...	...
4781	57022	124200	117	1502	1545
4782	57022	202600	21	300	1399
4783	57022	204200	34	240	1464
4784	57022	205800	37	179	1465
4785	57022	211400	31	119	1454

Fig. 3 CGGTTS data results

그림 4는 1번 위성에 대해 ROB에서 관리하는 BRUX 스테이션의 Trimble NETR9 1.2-0 수신기 처리 결과를 나타내는 것이다. x 축은 2014년 7월 3일부터 12월 31일까지 관측된 1번 위성의 관측 횟수로 총 4,786개의 REFSYS 값들의 시간의 흐름에 따른 현상이다. 위성이 관측되는 시점부터는 16분 단위로 시각 오프셋이 추출된다. y 축은 1번 위성과 BRUX 스테이션의 수신기 사이의 시각 오프셋 값으로 0.1ns 단위의 값이다.




Fig. 4 satellite 1 time offset results during year 2014

#### 3.2. 딥러닝 적용

본 연구에서는 REFSYS 단일 변량값에 대해 LSTM 순환신경망을 적용해 보았다. 데이터 분석 라이브러리

로는 pandas를 사용하였다. pandas는 해당 데이터를 행과 열로 이루어진 데이터 객체로 만들어 보다 안정적으로 대용량의 데이터들을 처리하는 도구이다. GPS 측정 데이터는 MJD와 hhmmss 형태의 시간 정보로 표현되어 있는데 pandas에서는 각 열의 데이터형에 따라 지원하는 기능이 다르기 때문에 date형태로 변환하였다. REFSYS 값을 이용한 시계열 예측의 경우 유일한 독립변수는 시간정보이므로 date 열을 해당 DataFrame의 index로 지정하였다. 단일 특성인 REFSYS만 사용한 시계열 예측 모델을 학습한 뒤 특정 시점에서의 REFSYS를 예측하고자 전체 데이터에서 일부인 80%를 따로 추출하였다. 텐서플로나 케라스 같은 딥러닝 라이브러리의 메서드들이 사용하는 매개변수형인 numpy의 ndarray로 변환하고 데이터의 상대적 크기에 대한 처리를 위해 데이터 정규화 과정을 적용하였다. 데이터 정규화 방법으로는 z-점수 정규화 방법을 적용하였다. 순환신경망을 이용한 시계열 예측은 감독학습이다.

딥러닝 모델로는 장기 의존성 문제에 강건한 모델인 LSTM 셀을 사용하고 딥러닝 라이브러리로 텐서플로와 케라스를 사용하였다.

학습을 위해 예측하고자 하는 값의 범위에 따라 독립변수의 열과 종속변수의 열로 구분하여 데이터를 재구성해야 하는데, 그림 5와 같이 슬라이딩 윈도우를 재구성해 가도록 하여 학습데이터에 대한 감독학습을 진행하였다. 즉, Training 부분이 독립변수로서 학습에 반영되며 이 학습의 정답인 종속변수가 Forecasting 값으로 구성된다.




Fig. 5 Forecasting models using sliding window

LSTM에서는 중요한 하이퍼 파라미터인 time step의 값이 독립변수의 크기가 되며 10개로 설정하고 이에 따른 종속변수로 다음 1개의 시각 오프셋에 대한 예측을 하여 학습하도록 설정하였다.

LSTM의 또 다른 하이퍼 파라미터인 batch size는 10으로 설정하였다.

단일변수에 대한 LSTM 모델은 가장 많이 사용되는 모델 구조인 단층 LSTM 레이어와 Dense 레이어로 구성하였다.

```
simple_lstm_model = tf.keras.models.Sequential([
    tf.keras.layers.LSTM(10, input_shape=x_train_uni
        .shape[-2:]), tf.keras.layers.Dense(1)])
```

목적 함수로는 실제 값과 예측 값 차이의 절댓값 평균을 계산하는 평균절대오차(MAE : Mean Absolute Error)를 사용하고 최적화 방법은 현재 가장 많이 사용되고 있는 고급경사하강법인 아담을 사용하였다.

```
simple_lstm_model.compile(optimizer='adam', loss
    ='mae')
```

아담은 케라스에서 제공하는 여러 최적화 방법 중 모멘텀과 RMSProp을 합친 방법으로, 타 고급경사하강법에 비해 정확도와 보폭 크기 개선 효과가 있다고 알려져 있다.

#### IV. 딥러닝 기반 시각 오프셋 예측 결과

딥러닝 기반의 시각 오프셋 예측에 대한 비교를 위해 단순 이동평균법에 의한 예측치를 계산하였다.

단순이동평균법은 과거 여러 기간의 시각 오프셋에 동일한 가중치를 부여하여 예측하고자 하는 기간의 직전 일정 기간의 실제 시각 오프셋의 단순평균치를 예측하는 방법이다. 단순이동평균법에서 시각 오프셋 추정을 위한 구간은 LSTM의 time step과 동일하게 10으로 설정하였다.

LSTM을 사용한 예측값과 단순이동평균법을 사용한 예측값의 성능 비교는 검증 데이터에서 각각 40개, 50개의 실제 연속된 시각오프셋을 기준값으로 사용하였다. 그림 6은 40개의 시각 오프셋을 기준으로, 그림 7은 50개의 시각 오프셋을 기준으로 단순이동평균법을 적용한 시각 오프셋과 LSTM 모델 예측에 의한 시각 오프셋을 비교한 그래프이다. y축은 시각오프셋 값을 0.1ns로 표시하고 x축은 평가를 위한 연속된 시각 오프셋 값들

이다. LSTM 예측값이 단순이동평균 예측값에 비해 실제 시각 오프셋의 추세를 따르는 것으로 보인다. 그림 7에서 첫 6번의 예측은 단순이동평균값이 더 나은 성능을 보이기도 하였으나 전체적으로는 LSTM이 나은 성능을 보이고 있다.

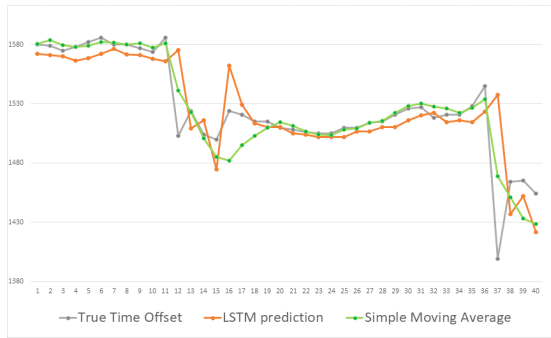


Fig. 6 Comparison of 3 models for 40 time offset series




Fig. 7 Comparison of 3 models for 50 time offset series

두 모델의 평균절대오차 평가 결과는 표 1에 제시하였다. 그래프에서와 같이 LSTM의 예측 결과가 단순이동평균법에 비해 더 나은 성능을 보이는 것을 확인할 수 있다.

Table. 1 Mean Absolute Error(MAE) comparisons

	MAE	
	40 predictions	50 predictions
Simple Moving Average	9.0569	10.2404
LSTM	1.3769	3.2427

## V. 결론

본 논문에서는 GNSS 기반 정밀시각비교에서 추출된 시각오프셋에 대해 딥러닝 기술을 적용하여 정확한 시각오프셋을 예측할 수 있는 방법을 제안하였다. 우선 전세계의 정보 인프라와 생활의 기본 표준인 세계협정시인 UTC에 대해 소개하고 이 UTC를 생성하기 위한 GNSS 기반 정밀시각비교 방법에 대해 소개하였다.

본 연구는 최근 다양한 분야에 딥러닝 기술이 접목되는 상황에서 다소 생소한 GNSS 기반 정밀시각비교 분야에 딥러닝 기술을 적용해 본 첫 단계로 딥러닝의 활용 가능성을 확인할 수 있었다. 향후 시각 오프셋 추출에 영향을 줄 수 있는 다른 변수들과의 연관성 도출, 시각 오프셋 특성에 맞는 딥러닝 모델 적용 등 다양한 연구를 계획하고 있다.

## References

- [ 1 ] Y. K. Lee, S. H. Yang, H. S. Lee, J. K. Lee, and S. W. Hwang, "Outlier Detection Method for Time Synchronization," *Journal of Positioning, Navigation, and Timing*, vol. 9, no. 4, pp. 397-403, Dec. 2020.
- [ 2 ] W. Fang, J. Jiang, S. Lu, Y. Gong, Y. Tao, Y. Tang, P. Yan, H. Luo, and J. Liu, "A LSTM Algorithm Estimating Pseudo Measurements for Aiding INS during GNSS Signal Outrages," *Remote Sensing*, vol. 12, iss. 2, 2020.
- [ 3 ] D. W. Allan and C. Thomas, "Technical Directives for Standardization of GPS Time Receiver Software," *Metrologia*, vol. 31, no. 1, 1994.
- [ 4 ] G. M. Lee, *Artificial Intelligence*, SangNeung Pub., pp. 317-334, 2019.
- [ 5 ] G. M. Lee, *Artificial Intelligence*, Sangneung Pub, ch. 5, pp. 254-385, 2019.
- [ 6 ] Y. W. Lu, C. Y. Hsu, and K. C. Huang, "An autoencoder Gated Recurrent Unit for Remaining Useful Life Prediction," *Processes*, vol. 8, iss.9, 2020.
- [ 7 ] J. Azoubib and W. Lewandowski, "CGGTTS GPS/GLONASS Data format version 02," 7th CGGTTS meeting, Nov. 1998.
- [ 8 ] G. Petit and E. F. Arias, "Use of IGS products in TAI applications," *Journal of Geodesy*, vol. 83, no. 3-4, pp. 327-334, Mar. 2009.



**유동희(Dong-Hui Yu)**

1992년 부산대학교 전자계산학과 학사  
1994년 부산대학교 전자계산학과 석사  
1994년 한국전자통신연구원 연구원  
2001년 부산대학교 전자계산학과 박사  
2002년 부산가톨릭대학교 소프트웨어학과 교수  
※ 관심분야 : 위성항법시스템 시각동기, 클라우드컴퓨팅, IoT, 기계학습, 딥러닝



**김민호(Min-Ho Kim)**

2007년 부산대학교 정보컴퓨터공학부 학사  
2009년 부산대학교 컴퓨터공학과 석사  
2011년 부산대학교 전기전자컴퓨터공학과 박사수료  
2020년 부산대학교 소프트웨어교육센터 교수  
2020년 부산가톨릭대학교 소프트웨어학과 교수  
※ 관심분야 : 자연언어처리, 정보검색, 인공지능, 기계학습