

다층 레이어 퍼셉트론 기반 INS 내장형 컴퓨터에서의 실시간 중력교란 보상

MLP Based Real-Time Gravity Disturbance Compensation in INS Embedded Computer

김현석¹ · 김형수¹ · 최윤혁¹ · 조운철¹ · 박찬식^{2*}

¹국방과학연구소

²충북대학교 지능로봇공학과, 컴퓨터 정보통신연구소

Hyun-seok Kim¹ · Hyung-soo Kim¹ · Yun-hyuk Choi¹ · Yun-chul Cho¹ · Chan-sik Park^{2*}

¹Agency for Defense Development, Yuseong P.O. Box 35, Daejeon 34186, Korea

^{2*}Department of Intelligent Systems & Robotics, Research Institute for Computer and Information Communication, Chugbuk National University, Korea

[요 약]

이 논문에서는 INS의 항법 정확도에 영향을 주는 중력 교란에 대한 실시간 예측기법으로 다층 퍼셉트론 모델을 제안하였다. 적합한 MLP 모델을 선정하기 위해서 학습 정확도 및 실행시간을 비교할 수 있게 신경망의 크기가 다른 4개의 모델을 설계하였다. 이 MLP 모델의 학습을 위해 해상 또는 육상의 지표면을 따라 이동하는 물체의 위치 및 중력교란 데이터를 사용하였으며, 중력교란 데이터의 계산은 2160차의 EGM2008을 SHM을 이용하여 이루어졌다. 학습 정확도 평가에서는 MLP4가 가장 우수한 것으로 확인되었고, 이후 실행시간을 측정하기 위해 학습이 완료된 4개 모델의 가중치와 바이어스 항들을 INS의 내장형 컴퓨터에 저장하여 MLP 모델을 구현하였다. 4개 모델 중 MLP4의 실행시간이 가장 짧은 것을 확인할 수 있었다. 이러한 연구 결과는 향후 중력 교란 보상을 통한 INS의 항법 정확도를 향상시키는데 활용될 수 있을 것으로 기대된다.

[Abstract]

In this paper, a real-time prediction technique for gravity disturbances is proposed using a multi-layer perceptron (MLP) model. To select a suitable MLP model, 4 models with different network sizes were designed to compare the training accuracy and execution time. The MLP models were trained using the data of vehicle moving along the surface of the sea or land, including their positions and gravity disturbance. The gravity disturbances were calculated using the 2160th degree and order EGM2008 with SHM. Among the models, MLP4 demonstrated the highest training accuracy. After training, the weights and biases of the 4 models were stored in the embedded computer of the INS to implement the MLP network. MLP4 was found to have the shortest execution time among the 4 models. These research results are expected to contribute to improving the navigation accuracy of INS through gravity disturbance compensation in the future.

Key word : Inertial navigation system (INS), Earth gravity model 2008(EGM2008), Deflection of vertical (DOV); Multi-layer perceptron (MLP).

<http://dx.doi.org/10.12673/jant.2023.27.5.674>



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.

Received 6 October 2023; Revised 12 October 2023
Accepted (Publication) 23 October 2023 (30 October 2023)

*Corresponding Author: Chan-sik Park

Tel: +82-43-261-3259

E-mail: chansp@cbnu.ac.kr

I. 서 론

관성항법시스템(INS; inertial navigation system)은 내장된 자이로스코프와 가속도계를 이용하여 플랫폼의 자세, 속도, 위치를 지속적으로 결정할 수 있는 자율 시스템이다[1], [2]. 이러한 특성으로 인해 INS는 외부 간섭에 영향을 받지 않으며 미사일 및 민간 항공기와 같은 군사 및 민간 응용 분야 모두에서 매우 유용한 항법장치이다. 그러나 INS, 특히 추측 항법 접근 방식의 경우 자체 관성 센서 부정확성으로 인해 오차가 누적될 수 있다. 오차의 원인 중에서 자이로스코프와 가속도계 bias drift는 INS 부정확성의 중요한 원인이 된다. 이러한 관성센서의 bias drift의 크기를 줄이기 위해 상당한 노력이 투자되었다. 한편으로는 관성 센서의 정밀도를 향상시키기 위해 저온 원자 간섭계와 같은 첨단 기술이 사용되었다[3]. 반면에 회전 변조와 같은 시스템 수준 보상 방법은 INS 성능을 크게 향상시켰다[4]. INS 성능이 향상됨에 따라 이전에 간과되었던 오차 원인이 전면에서 등장했으며, 중력 교란은 INS 정확도의 추가 향상을 제한하는 주요 요인 중 하나이다[5].

전통적으로 INS는 중력 보상을 위해 정규 중력(normal gravity) 또는 이론 중력으로 알려진 값에 의존해 왔다. 이 정규 중력은 항상 기준 타원체에 수직이므로 수평 성분은 '0'이고 수직 성분만 존재한다. 이 정규중력의 크기는 Somigliana 공식을 Taylor 급수 전개를 사용하여 계산할 수 있다. 정규중력과 실제 지구중력의 차이는 정규중력과 실제중력 사이의 크기 차이를 의미하는 중력 이상(gravity anomaly)와 각 편차를 의미하는 수직 편향(DOV; deflection of vertical)으로 알려진 수평 중력 교란을 포함하여 중력 교란이라고 한다. INS의 오차 분석에서 DOV는 주로 초기 정렬 및 위치/속도 계산 정확도에 영향을 미친다. Kwon과 Jekeli[4], Jekeli[6], Jekeli et al. [7]의 연구를 포함한 여러 문헌에서는 정밀한 INS에서 중력 보상을 통해 달성된 성능 향상을 분석했다.

Hanson [8]은 초기 정렬에서 DOV 보상이 보편적으로 적용되지 않는 이유를 분석하고 보상되지 않은 가속도계 드리프트 바이어스와 DOV 사이의 상관 관계를 분석했다. 그러나 [8]의 결론은 부정적이며 제시된 보상 절차는 특정 사례에 국한되었다. George [9]는 정렬 중 DOV 보상을 통해 성능을 향상시킨 군용 표준 링 레이저 관성 항법 장치인 LN-93E를 소개하였다. 초창기 연구에서는 DOV 보상 값이 실시간 계산이 아닌 경로를 따라 미리 계산되거나 측정된 값에 의존하여 정렬 전에 미리 잡입되었다는 점에 주목할 가치가 있다. 넓은 영역에 걸쳐 고정밀의 DOV 보상 값을 결정하려면 상당한 계산 리소스가 필요하므로 실제로 DOV 보상은 실시간 계산이 필요하지 않은 초기 정렬 과정에 국한되었다.

[10], [11]에서 연구자들은 측정된 중력 데이터를 기반으로 중력 교란을 추정하고 위치 오차 전파를 최소화하기 위해 INS 방정식 내에서 이를 보상함으로써 INS에 대한 중력 교란 보상을 연구했다. 최근 INS의 중력 교란을 보상하기 위해 고해상도

전역 중력장 모델을 사용하는 데 대한 관심이 높아지고 있다. 이러한 많은 모델은 구면 조화 모델(SHM; spherical harmonic model)을 기반으로 하며, 지구 중력 모델 2008(EGM2008; earth gravity model 2008)은 최대 차수 2160을 특징으로 하는 대표적인 중력모델이다. 연구 [12]-[16]에서는 SHM, 특히 EGM2008이 어떻게 INS 성능을 향상시킬 수 있는지에 대한 연구가 이루어졌다. 그러나 이 작업의 대부분은 특히 온보드 INS 컴퓨터의 제한된 컴퓨팅 성능으로 인해 실시간 애플리케이션을 위해 SHM을 단순화하는 데 중점을 두었다. 예를 들어, Wang et al. [13]은 실시간 INS 애플리케이션을 위한 수정된 SHM의 타당성과 정확성을 평가한 반면 Wang et al. [14]는 SHM에서 과생된 단순화된 2D 2차 다항식 모델을 제안했다. Wuet al. [15]는 해상 및 항공 INS에 대해 SHM을 사용하여 중력의 최소 유효 계산주기를 연구했다. 문헌 [16]은 초기 정렬과 항법 해 계산 모두에 대해 EGM2008을 사용하여 DOV 보상을 분석했으며 항법 해 계산 중에만 DOV를 보상하는 것이 가장 바람직하다는 결론을 내렸다. 이외에도 초기 정렬 및 INS 항법 솔루션에 대한 중력 교란 보상에 대한 여러 연구가 진행되었다.

[11]에서는 ELM이라는 인공 신경망을 적용하여 미리 계산된 중력 교란을 높은 정밀도로 학습하여 중력 및 DOV 값을 제공했다. 그러나 이 연구에서는 신경망의 크기를 공개하지 않았고 컴퓨팅 환경에 따라 달라질 수 있는 인공신경망의 계산 시간 측정 결과는 제시하지 않았다.

INS 항법 정확도를 향상시키기 위해 DOV 보상의 가능성을 확인한 기존 연구에도 불구하고 INS의 내장 컴퓨터 내에서 실시간 DOV 보상 방법에 관한 문헌에는 주목할 만한 가치가 있다. 따라서, 이 논문에서는 실시간 DOV 보상을 위해 다층 퍼셉트론(MLP; multi-layer perceptron) 인공 신경망을 사용하여 중력교란을 학습하여 학습정확도를 평가하고 해당 신경망을 실제 INS의 내장 컴퓨터에 구현할 것이다. 이후 INS의 내장 컴퓨터에서 각 신경망의 실행시간을 측정하여 정밀 중력교란 데이터의 실시간 예측 가능성에 대해서 살펴보도록 하겠다.

이를 위해 본 논문은 다음과 같이 구성하였다. II장에서는 SHM 방법을 이용하여 중력 교란 벡터를 정의한다. III장에서는 INS 항법 중 실시간 DOV 보상을 위한 방안으로 MLP를 소개하고, MLP를 학습하기 위한 학습 DB를 생성하는 과정을 다루었다. IV장에서는 학습 DB를 이용하여 신경망을 학습하고 학습 결과를 정량적으로 평가하여 성능을 비교하고, INS 내장형 컴퓨터에 실제 MLP 신경망을 구현하고, 각 신경망의 실행시간을 측정하였다. 마지막으로 섹션 V에서는 결론을 제시한다.

II. 중력교란 및 수직편향

중력 potential 이론에 따르면 중력 벡터는 등전위 중력면의 수직선에 해당합니다. 지구의 등전위 중력면은 매우 복잡하므로 실용적인 목적으로 WGS-84와 같은 기준 타원체 모델을 사

용하여 근사화하는 경우가 많다. 중력 교란 벡터는 실제 지구의 중력 벡터와 정규 중력 벡터의 차이를 의미한다. 크기의 차이는 중력 이상을 정의하는 반면, 각 중력 벡터의 각도의 차이는 DOV를 의미한다. DOV로 인해 수평 평면 내에 지구 중력 벡터의 특정 투영 구성 요소가 존재하며 이를 수평 중력 교란이라고도 정의한다.

중력 교란은 지구의 실제 중력 \mathbf{g}^n 와 정규 중력 γ^n 의 차이로 정의되며 다음과 같이 표현될 수 있다.

$$\Delta \mathbf{g}^n = \mathbf{g}^n - \gamma^n = [\Delta g_E \ \Delta g_N \ g_U] - [0 \ 0 \ \gamma] = [\Delta g_E \ \Delta g_N \ \Delta g_U] \quad (1)$$

여기서 중력 교란의 동쪽과 북쪽 요소는 Δg_E 및 Δg_N 으로 표시되고, Δg_U 는 중력 이상이라고 한다. γ 는 정규중력 벡터 γ 의 Norm이다. 위첨자 n 은 이러한 벡터가 항법좌표계로 투영됨을 의미한다.

그림 1과 같이 DOV의 북쪽 및 동쪽 구성 요소는 각각 ξ 및 η 로 표기하고, 수평 중력 교란과 DOV 사이의 관계는 다음과 같이 표현할 수 있다[7].

$$\xi \approx \tan \xi = -\frac{\Delta g_N}{g_U}; \quad \eta \approx \tan \eta = -\frac{\Delta g_E}{g_U} \quad (2)$$

여기서 g_U 는 수직 중력의 크기이며 EGM2008 모델을 사용하여 직접 계산할 수 있다. DOV의 최대값은 전지구 범위로 영역을 넓히면 가속도계 바이어스로 환산하면 500 mGal(1 mGal = 10^{-5} m/s^2)에 해당하는 100 arcsec(1 arcsec = $1/3600 \text{ deg}$)에 달한다. 이 값은 고정밀 가속도계의 일반적인 가속도계 바이어스 값인 10 mGal보다 훨씬 크다[6].




그림 1. 중력교란 벡터, 실제 중력 및 정규중력의 관계
 Fig. 1. Relationship between gravity disturbance vector, actual gravity and normal gravity

방정식 (2)를 방정식 (1)에 통합하면 중력 교란은 다음과 같이 표현할 수 있다.

$$\Delta \mathbf{g} = [-\eta g_U \ -\xi g_U \ \Delta g_U] \quad (3)$$

여기서 수평 중력 교란은 다음과 같이 지구 중력장의 구면 조화 모델(SHM)을 통해 계산할 수 있다[17].

$$\Delta g_N = -\frac{GM}{r^2} \sum_{n=2}^{n_{max}} \sum_{m=0}^n \left(\frac{a}{r}\right)^n [\bar{C}_{nm}^* \cos m\lambda + \bar{S}_{nm}^* \sin m\lambda] \frac{d\bar{P}_{nm}(\cos\vartheta)}{d\vartheta} \quad (4)$$

$$\Delta g_E = \frac{GM}{\sin\vartheta \cdot r^2} \sum_{n=2}^{n_{max}} \sum_{m=0}^n \left(\frac{a}{r}\right)^n m [\bar{C}_{nm}^* (-\sin m\lambda) + \bar{S}_{nm}^* (\cos m\lambda)] \bar{P}_{nm}(\cos\vartheta) \quad (5)$$

여기서 G 는 중력 상수, M 는 지구의 질량, a 는 기준 타원체의 장축 길이이고, r 은 현재 위치에서 기준 타원체의 중심까지의 반경 거리이다. ϑ 는 구면좌표계에서 정의된 현재 위치의 위도이며, λ 는 구면좌표계에서 정의한 경도, n 과 m 은 SHM의 degree와 order, \bar{C}_{nm}^* 과 \bar{S}_{nm}^* 는 SHM의 계수, n_{max} 는 SHM 계산에 사용된 최고 차수, $\bar{P}_{nm}(\cos\vartheta)$ 는 degree n 및 order m 차수의 완전히 정규화된 르장드르 함수이다.

III. 다층 퍼셉트론 기반 실시간 DOV 예측

현재 컴퓨팅 성능이 향상되고 GPU가 널리 채택됨에 따라 인공지능 기술은 광범위한 분야에서 그 가치를 입증했으며 지속적으로 뛰어난 결과를 제공하고 있다. 전통적으로 복잡한 수학적 모델이 필요했던 복잡한 문제를 해결하기 위해 가장 많이 활용되는 도구 중 하나가 되었다. 특히, 고차 정밀 중력 모델에서 수직 편향(DOV)의 실시간 예측 값을 제공하는 경우에도 유용할 것으로 판단된다.

간단히 신경망이라고도 불리는 인공 신경망은 동물의 뇌에서 발견되는 생물학적 신경망에서 영감을 얻었다. 인공 신경망과 생물학적 신경망이 공유하는 기본 특성은 명시적 프로그래밍에 의존하지 않고 예제를 통해 작업을 학습하는 능력이다. 신경망은 생물학적 시스템에 존재하는 뉴런을 모델링하는 인공 뉴런으로 알려진 상호 연결된 노드로 구성된다. 시냅스를 통해 연결된 이러한 노드는 특정 활성화 기능에 응답하여 정보를 전송하거나 억제한다[18].

인공 신경망의 시작은 McCulloch와 Pitts가 도입한 1943년으로 거슬러 올라간다[19]. 퍼셉트론으로 알려진 초기 구현은 출력 레이어에 연결된 일련의 인공 뉴런으로 구성되었다. 1975년이 되어서야 Werbos는 역전파 알고리즘을 개발하여 다층 네트워크(다층 퍼셉트론 또는 MLP라고 함)의 훈련을 실현 가능하

고 효율적으로 만들었다[20]. GPU 및 분산 시스템 덕분에 컴퓨팅 성능이 계속 발전함에 따라 신경망 모델의 깊이가 깊어질 수 있었다. 이러한 딥 러닝 네트워크는 이미지 및 시각적 인식 문제를 해결하는 데 탁월한 성능을 제공한다.

3-1 MLP의 기초

다층 퍼셉트론(MLP)으로 알려진 다층 신경망은 입력 층과 출력 층 사이에 끼워진 여러 개의 숨겨진 층으로 구성된다. MLP 네트워크는 복잡한 비선형 관계를 모델링하는 데 탁월하다. 예를 들어, 객체 식별 신경망에서 각 객체는 기본 이미지 요소의 계층적 구성으로 표현될 수 있다. 그러면 추가 레이어가 하위 레이어의 기능을 점차적으로 통합할 수 있다. MLP 네트워크는 표준 역전파 알고리즘을 사용하여 훈련될 수 있다[21]. 가중치는 아래 방정식을 사용하여 경사하강법을 통해 갱신 가능하다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \epsilon \frac{\partial C}{\partial w_{ij}} \quad (6)$$

여기서 Δw_{ij} 는 가중치를 나타내고, ϵ 는 학습률, C 는 비용 함수를 의미한다.

비용 함수의 선택은 학습 유형 및 활성화 함수와 같은 요소에 따라 달라진다. 다중 클래스 분류 문제에서 지도 학습의 경우 일반적으로 소프트맥스 함수와 교차 엔트로피 함수가 각각 활성화 함수와 비용 함수로 사용된다.

효율성에도 불구하고 MLP를 포함한 심층 신경망은 과적합 및 높은 시간 복잡성과 같은 문제에 직면할 수 있다. 과적합을 완화하기 위해 가중치 감소(l_2 -regularization) 또는 희소성(l_1 -regularization 및 dropout 정규화)과 같은 정규화 방법이 등장했다. Dropout은 훈련 중에 숨겨진 레이어에서 일부 단위를 무작위로 제외하는 것을 포함한다. 오차 역전파 및 경사하강법은 구현이 용이하고 로컬 최적화 가능성 때문에 선호된다. 그러나 이러한 방법으로 심층 신경망을 훈련하는 것은 계산 집약적일 수 있다. 시간 복잡성과 과적합 문제를 해결하기 위해 미니 배치 학습 및 드롭아웃과 같은 기술이 개발되어 부분적인 솔루션을 제공한다. 또한 행렬 및 벡터 계산에 최적화된 GPU는 학습 속도를 크게 향상시켰다.

본 연구에서는 두 개 이상의 완전 연결 레이어로 구성된 히든 레이어를 사용하여 다층 퍼셉트론 네트워크를 구축하였다. 신경망 모델의 은닉 층과 각 은닉층의 노드 수를 변경해가면 각 신경망 모델의 학습 정확도를 분석하였다.

3-2 훈련 데이터세트

MLP를 훈련하고 정확도를 평가하려면 각 위도, 경도 및 고도 좌표에 해당하는 중력 교란 데이터베이스가 필수적이다.

정확한 중력 교란 계산을 달성하려면 고차의 정밀한 중력 모

델이 필요하며, 미국 NGA(National Geospatial-Intelligence Agency)에서 개발한 2160차수의 EGM2008 중력모델은 대표적이다. 본 연구에서는 2160차 구면고조파 모델을 PC에서 계산하여 한반도 일원에 대한 EGM2008 중력교란 DB를 구축하였다. 신경망 훈련에 사용된 중력 교란 데이터는 한반도 주변 지역, 위도 33°~39°, 경도 124°~132°를 대상으로 3 arcsec간격으로 계산하였다. 그 결과 MLP 학습에 사용되는 61,924,800개의 데이터 세트가 생성되었다. MLP 훈련 중 예측 정확도를 검증하기 위해 6,192,480개의 무작위 위치(훈련 데이터의 10%)로 구성된 검증 데이터 세트를 생성하였으며 결과는 그림 2~4를 통해 확인할 수 있다.

EGM2008 중력 모델은 구면 좌표로 표현되는 위도, 경도, 고도의 함수이다. 본 연구에서 대상으로 하는 플랫폼이 오로지 지구 표면에서만 움직인다고 가정할 때, 플랫폼의 수평 좌표인 위도 및 경도를 결정하면 해당 지점의 고도를 확정할 수 있게 된다.




그림 2. 각 격자점 위치에서의 중력교란 동쪽 성분
Fig. 2. The eastern component of gravity disturbance




그림 3. 각 격자점 위치에서의 중력교란 북쪽 성분
Fig. 3. The northern component of gravity disturbance




그림 4. 각 격자점 위치에서의 지구중력 수직 성분
 Fig. 4. The vertical component of Earth gravity

여기서 발생하는 한 가지 문제는 각 데이터간의 고도에 대한 정의가 다르기 때문에 각각의 학습 DB간 기준고도에 대한 변환이 필요하며, 이에 대해서는 다음 절에서 자세히 다루도록 하겠다.

3-3 지오이드 고도

지오이드는 바람과 조수와 같은 외부 영향을 제외하고 중력 당김 및 회전과 같은 요소를 설명하는 지구의 중력에 의해 영향을 받는 해수면의 모양을 나타낸다. 지오이드는 매끄럽지만 불규칙한 표면으로, 지구 내부와 지구상의 고르지 않은 질량 분포로 인해 형성된다. 지오이드에 대한 정확한 정보를 얻으려면 광범위한 중력 측정과 계산이 필요하다. 중요한 것은 지오이드 표면의 모든 지점이 동일한 지구 전위, 즉 중력 위치 에너지와 원심 위치 에너지의 합을 공유한다는 것이다. 중력은 모든 곳에서 지오이드에 수직으로 작용한다. 다른 영향이 없으면 수직선은 수직을 가리키고 해수면은 지오이드와 평행하게 정렬된다. 지오이드의 표면은 양의 중력 이상이 있는 지역에서 기준 타원체 위로 올라가 질량 초과를 나타내며, 음의 중력 이상이 있는 지역에서는 질량 부족을 나타내는 타원체 아래로 내려가게 된다.

지오이드 기복은 기준 타원체에 대한 지오이드의 높이를 나타낸다. 고도의 일반적인 정의에는 기준 타원체로 정의된 타원체의 높이를 나타내는 GPS 고도와 측지학 및 측량에 사용되는 평균 해수면 고도가 포함됩니다. 타원체 높이(h), 평균 해수면 높이(H), 지오이드 고도(N) 간의 관계는 그림 5에서 확인할 수 있고 식 (7)과 같이 정의할 수 있다.

$$h = H + N \tag{7}$$

여기서 지오이드 고도 또는 지오이드 기복이라고 정의하는 N 은 EGM2008 지오이드 모델을 사용하여 계산하거나 [22]에

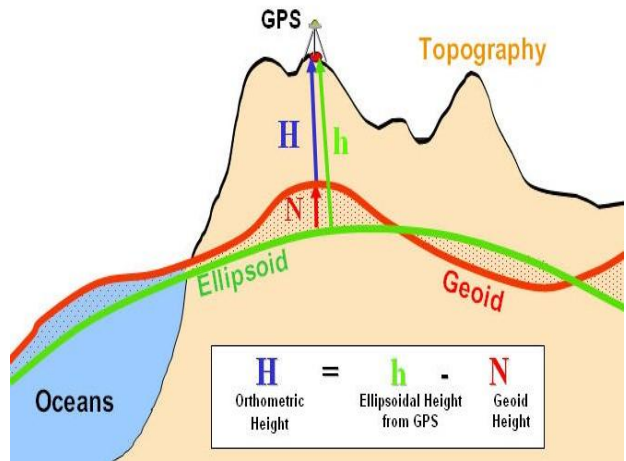


그림 5. 지오이드 고도, 타원체 고도, 정사고도의 개념
 Fig. 5. The definitions and relations for geoid height, ellipsoidal height and orthometric height




그림 6. 한반도 주변의 지오이드 고도(지오이드 기복)
 Fig. 6. A geoid undulation around the Korean Peninsula

기술한 바와 같이 사전에 계산하여 저장한 지오이드 기복 값을 불러와서 내삽하여 구할 수 있다. 그림 6에서는 한반도 주변의 지오이드 기복 분포를 보여주며, 약 15m에서 31m 범위로 남동쪽에서 북서쪽으로 점진적인 경사를 형성하고 있는 것을 확인할 수 있다. 그림 5에서와 같이 지표면의 타원체 고도는 지오이드 고도와 정사고도를 더해서 결정할 수 있다. 이 정사고도(H)는 수치표고모델을 통해서 획득할 수 있으며, 다음 절에서 이에 대해서 다루었다.

3-4 수치표고모델

평균 해수면 고도를 '0'으로 가정하면 해상에서의 고도를 계산하는 것은 상대적으로 간단하다. 그러나 육상 지역의 경우 처리과정이 더 복잡해진다. 여기에는 지형 불규칙성과 지면 또는 도로의 모양을 고려하여 각 그리드 지점에서 지표면의 고도를

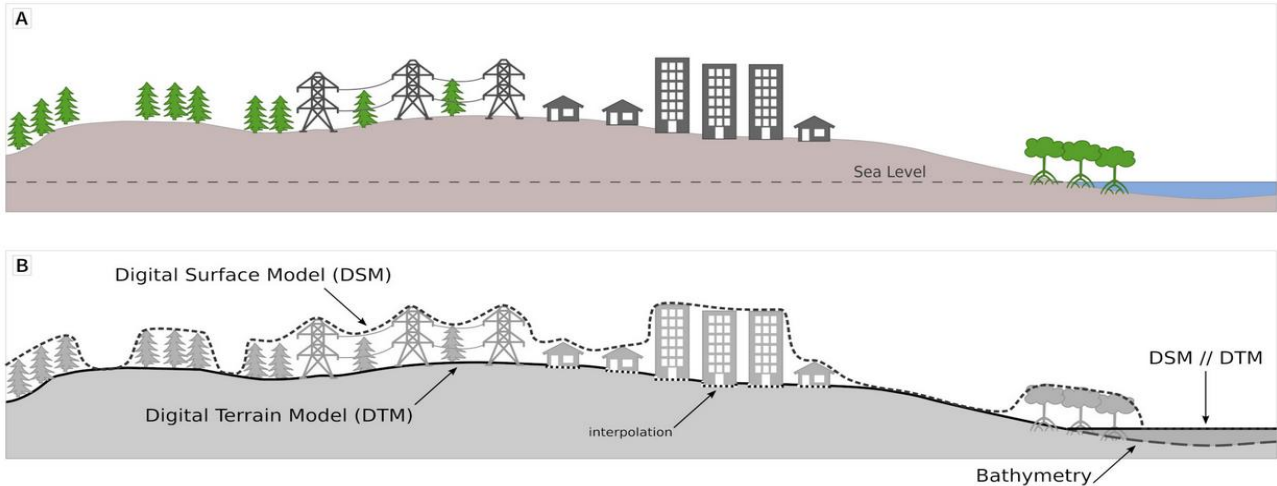


그림 7. DSM 및 DTM으로 표현된 지표면의 도식적 표현
Fig. 7. A schematic representation of surfaces represented by a DSM and DTM

결정하는 작업이 포함된다. 이를 위해 수치표고모델(DEM; digital elevation model)이 사용된다. DEM은 지형 벡터 특징(예: 하천, 능선) 및 인공 구조물(전선, 건물, 탑)은 물론 나무 및 초목과 같은 자연 지형을 제외한 지형의 그리드 래스터 데이터 표현이다.

수치 고도 모델과 관련된 다양한 정의가 있는데, 두 가지 주요 정의로는 수치 지형 모델(DTM; digital terrain model)과 수치 표면 모델(DSM; digital surface model)이 있다. 맨땅과 표면 개체를 구별하는 것이 중요하지 않은 대부분의 경우 일반 용어인 DEM이면 충분하다. DEM은 일반적으로 레이저 스캐닝(LiDAR; light detection and ranging), 측지 측량 또는 레이더 간섭계(InSAR; interferometry synthetic aperture radar)와 같은 기술을 사용하여 위성, 드론, 비행기를 통해 수집된 원격 감지 데이터로 생성된다.

1) 디지털 지형 모델(DTM)

DTM은 정의된 높이를 가진 점을 특징으로 하는 지형 또는 표면 지형의 3차원 묘사를 나타낸다. DTM에는 강, 능선, 브레이크라인과 같은 특징점이 포함되지만 초목이나 건물과 같이 지구 표면에서 발견되는 자연 또는 인공 물체는 제외된다. 이는 표면 특징을 고려하지 않고 맨땅의 고도를 대략적으로 계산한다. DTM은 특징점과 기준면 또는 측지 데이터 사이의 수직 거리에 가까운 높이 값을 가진 2D 점 세트를 포함한다. 특정 연구 분야에서 DTM은 맨땅 지형(예: 브레이크라인, 능선)의 선형 특징으로 보강된 벡터 데이터셋으로 간주된다. 항공 및 우주 스테레오 이미지의 사진 측량 처리는 DTM을 생성하는 데 종종 사용된다. DTM은 표면 객체(예: 나무, 건물)와 주변 환경의 높이 값 간의 차이를 계산하여 DSM에서 파생될 수도 있다.

2) 디지털 표면 모델(DSM)

DSM은 지구 표면의 자연 물체와 인공 물체를 모두 포함하

여 지구 표면 높이를 3차원으로 표현한다. 이는 초목, 건물 및 맨땅 위에 있는 기타 물체를 포함한 반사 표면의 평균 해수면 고도를 나타낸다. DSM은 일반적으로 맨땅에 캐노피 모델을 오버레이 한다. DSM의 주목할만한 예로는 NASA의 위성 기반 InSAR DEM 기술을 사용하여 지구 육지의 약 80%를 커버하는 SRTM(shuttle radar topography mission)이 있다. SRTM 데이터는 인터넷에서 무료로 다운로드할 수 있으며 1 arcsec 해상도로 전 세계적으로 적용된다[23].

3) DEM vs DTM vs DSM

앞에서 언급한 세 가지 모델을 구별하는 것이 중요하다. DEM은 DTM과 DSM을 모두 포함하는 포괄적인 용어이다. DTM은 맨땅의 고도에 초점을 맞춘 DEM인 반면, DSM은 모든 표면 객체를 포함한다. 그림 7은 DTM과 DSM의 차이점을 보여 준다. DTM은 지면의 윤곽을 따르고 DSM은 건물 및 나무 꼭대기와 같은 표면 구조를 캡처한다. DEM은 디지털 지도 제작, 지리 정보 시스템에 광범위하게 사용되며 지형 표현의 기본 기반으로 사용된다. DTM은 홍수 모델링, 토지 이용 연구, 지질 연구, 행성 과학 분야에서 주로 이용하는 반면 DSM은 통신, 조경 모델링, 도시 모델링 및 시각화와 같은 작업에 선호된다.

엄밀히 말하면, SRTM 데이터를 사용하여 식 (7)과 같이 지오이드 기복을 이용하여 타원체 고도로 변환할 때 표면 지형지물의 높이와 동일한 오차가 발생한다. 그러나 본 연구에서는 지상 차량이나 수상 선박에 초점을 맞추었으며, 지상에서 차량의 이동은 장애물이 없는 도로 등과 같은 곳으로만 이동한다고 가정한다. 따라서 본 연구의 범위 내에서는 SRTM이 제공하는 수치 고도가 DTM과 일치한다고 가정하는 것이 합리적이다. SRTM의 해상 수치 고도는 일관되게 '0'이라는 점은 주목할 가치가 있다.

IV. MLP 신경망 설계 및 구현

4-1 MLP 신경망 설계 및 학습결과

본 연구에서는 MATLAB Deep Learning Toolbox[24]를 사용하여 신경망을 설계하고 학습하였다. 본 논문의 목표는 P2020 듀얼 코어 1GHz 프로세서로 구동되는 내장형 컴퓨터에서 실시간으로 중력교란을 예측하여 관성항법시스템의 항법계산에서 보상하는 것이다[25]. 엄격한 실시간 요구 사항을 충족하려면 각각의 수평중력교란 계산이 최대 1.2 ms 이내에 완료되어야 한다[26]. 이를 위해 신경망의 실행속도를 예측하기 위해서 계산복잡도 개념을 도입하였다. T_c 로 표시되는 계산복잡도는 다음과 같이 계산할 수 있다.

$$T_c = (N \times M)MUL + (N \times M + M)ADD + N + (N)\tanh \quad (8)$$

이전 연구에서 T_c 가 13,250 일 때 약 1 ms의 실행 시간이 필요함을 확인하였다. 이는 입력 및 출력 차원이 각각 2와 1일 때 각각 50개의 뉴런을 포함하는 5개의 숨겨진 레이어가 있는 신경망 모델의 실행시간과 유사하다. 따라서 본 연구에서는 이 계산 복잡도 범위에 속하는 매개변수를 사용하여 네트워크를 설계하고 학습시켰다. 결과적으로 4개의 MLP 신경망을 설계하였으며 표 1에 요약되어 있다.

이 신경망 설계에서 입력 레이어는 입력 벡터 요소(위도, 경도)를 호스팅하는 두 개의 뉴런으로 구성된다. 2번째부터 N번째까지의 레이어는 은닉 레이어 역할을 하며, 각 레이어는 완전 연결되어 있다. 출력 레이어는 DOV의 동부 및 북부 구성 요소를 생성한다. 신경망을 훈련시키기 위해 은닉 레이어(출력 레이어 제외)는 완전한 연결을 위한 'fullConnectedLayer', 학습을 촉진하고 로컬 최적값을 해결하기 위한 'batch-Normalization-Layer', 활성화 함수인 'swishLayer'로 구성된다. 방정식 (9)에 의해 주어진 'swish' 활성화 함수는 Google이 개발한 함수로 심층 계층 훈련에서 ReLU보다 뛰어난 성능을 보이는 것으로 알려져 있다.

$$f(x) = \frac{1}{(1 + e^{-x})}, f'(x) = f(x) \times sigmoid(1 - f(x)) \quad (9)$$

표 1. MLP 네트워크: 은닉 레이어 수, 뉴런 및 시간 복잡성.

Table 1. MLP networks: number of hidden layer, neurons and time complexity

	Input	# of hidden layer	# of neuron per hidden layer	Output	Computational complexity(T_c)
MLP1	2	31	20	1	13740
MLP2	2	20	25	1	13625
MLP3	2	14	30	1	13590
MLP4	2	5	50	1	13250

표 2. DOV 예측 MLP 네트워크에 대한 훈련 옵션

Table 2. Training options for gravity disturbance prediction MLP networks

Optimizer	Adam	Learning rate schedule	Piece wise
Mini-batch size	1,238,496	Shuffle	Once
Activation function	Swish function	Validation frequency	Every 25th epoch
Initial learn rate	0.1	Epoch	100
Learn rate drop factor	0.4	Iteration	5000
Learn rate drop period	5	Iteration per epoch	50

MLP 신경망 학습은 MATLAB R2021a에서 이루어졌다. 각 경우에 대한 신경망 크기는 표 1에 나타나 있으며, 학습 조건은 표 2에 자세히 나와 있다. 회귀분석에 적합한 'adam' 최적화 함수를 활용하였으며, 초기 학습률은 0.1로 0.4씩 감소하였다. 5번째 에포크마다. 이러한 동적 학습률 변경은 처음에는 검증 오차 편차를 키우지만, 궁극적으로는 학습 속도가 빨라진다. Epoch가 진행됨에 따라 학습률이 감소하여 검증 오차 편차가 감소한다.

훈련 결과를 평가하기 위해 방정식 (10)과 (11)에 정의된 대로 One Half Mean Squared Error(HMSE)를 사용하여 손실을 계산하고 평균제곱근오차(RMSE; root mean squared error)로 MLP 네트워크 성능을 검증했다.

$$One\ Half\ MSE = \frac{1}{2n} \sum (\hat{y}_i - y_i)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (\hat{y}_i - y_i)^2} \quad (11)$$

신경망 훈련 과정은 Intel Xeon Gold 2.5GHz 듀얼 프로세서 기반 컴퓨터에서 실행되었다. 그림 8은 훈련 프로세스의 진화를 보여준다. 위쪽 부분은 RMSE 예측 오차를 나타내고 아래쪽 부분은 RMS 손실을 나타낸다. 1,238,496의 미니 배치 크기가 사용되었다. 이는 신경망 학습시에 1 epoch마다 50개의 iteration으로 학습이 진행되고, 각각의 iteration마다 역전파 알고리즘을 사용하여 뉴런 가중치 조정이 이루어졌음을 의미한다. 그 결과 전체 훈련 세트가 61,924,800개의 데이터로 구성되어 있기 때문에 전체 학습과정에서 총 5,000번의 학습 반복이 이루어졌다. 학습률 안정성을 높이고 훈련이 끝날 때 급격한 변동을 방지하기 위해 학습률은 시작 값을 0.1로 설정하고 5 epoch마다 0.4배로 줄어든게 설계하였다.

50번의 학습 반복마다 6,192,480개의 검증 세트 항목에 대해 MLP 신경망들의 정확도를 평가했다. 이 평가를 통해 신경망이 효과적으로 학습하고 있는지 확인했다. 학습 과정은 5,000번의 훈련 반복이 모두 완료된 이후에 종료되도록 구성되었다. 학습 중 편향을 제거하기 위해 입력 및 출력 데이터가 사전 정규화되었다. 각 신경망의 평균 훈련 시간은 대략 2,000~2,400분이 소요되었다. 표 3에는 Δg_E 및 Δg_N 각각의 MLP1~MLP4 신경망에 대한 최종 훈련 손실 값과 최종 검증 오차가 나와 있다. 표를 보면 MLP3이 가장 작은 학습오차를 보여주는 것을 확인할

표 3. MLP1~MLP4 학습 완료시 최종 검증 손실 및 RMSE

Table 3. Final validation loss and RMSE of MLP1~MLP4 training results

	MLP1		MLP2		MLP3		MLP4	
	δg_E	δg_N	δg_E	δg_N	δg_E	δg_N	δg_E	δg_N
HMSE	0.0477	0.3974	0.0269	0.0539	0.0199	0.0420	0.0391	0.0460
RMSE	0.3087	0.8915	0.2320	0.3283	0.1993	0.2899	0.2796	0.3033

표 4. MLP 신경망 구현 및 실행시간 측정에 사용된 INS의 내장컴퓨터 사양

Table 4. A specification of INS's embedded computer used in MLP test

CPU	Flash Rom	RAM	Real-time OS
P2020, dual core 1GHz, 512k L2 Cache	Nor Flash 16M byte	DDR2 400MHz 256M byte	VxWorks 6.9

수 있다.

4-2 MLP 신경망의 구현 및 실행시간 측정

이 절에서는 학습이 완료된 신경망을 실제 INS의 내장형 컴퓨터에 구현하기 위한 준비과정과 측정된 실행시간에 살펴보도록 하겠다. 먼저 INS에서 실시간으로 항법해를 계산하기 위해서는 컴퓨터가 필요한데 표 4에서 실험에 사용된 INS 내장형 컴퓨터의 사양을 제공한다. 이 컴퓨터에서는 실시간 처리를 보장하기 위해 상용 실시간 운영 체제인 VxWorks 6.9를 채택하였다[27].

신경망 훈련이 완료되면 모든 MLP 신경망 모델의 각 계층의 뉴런에 대한 bias 및 weight 값을 single-precision floating point 형식으로 확보할 수 있다.

각 신경망의 bias와 weight를 바이너리파일 형태로 저장하였으며 각 파일의 크기는 표 5를 통해 확인할 수 있다. 표 4에서는 INS 내장형 컴퓨터의 사양을 확인할 수 있는데, 16 MB의 Nor flash에는 8 MB 크기의 True Flash File System(TFFS)이 구축되어 있다. 따라서 각 신경망의 bias 및 weight 파일들은 내장 컴퓨터보드의 TFFS에 파일 형태로 저장이 가능하며 VxWorks에서 실시간으로 접근이 가능하다. 이러한 가중치와 bias 값을 이용하여 각 신경망 모델의 실행 시간을 정확하게 측정하기 위해 실제 INS 내장형 컴퓨터에 구현하였다.

표 5. MLP1~MLP4 신경망의 bias 및 weight 크기

Table 5. Bias and weights size of MLP1~MLP4

	MLP1	MLP2	MLP3	MLP4
Bias	5280 Byte	4400 Byte	3840 Byte	2800 Byte
Weight	99,680 Byte	100,600 Byte	101,520 Byte	101,200 Byte

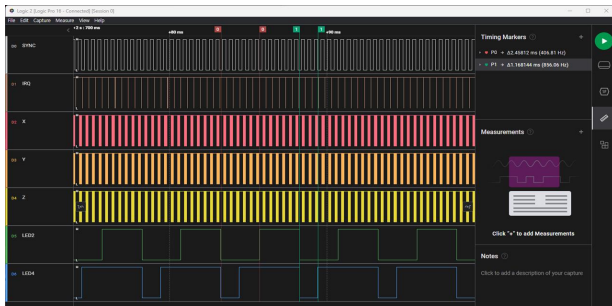


그림 8. MLP1 신경망 실행시간 측정결과(1.168ms)

Fig. 8. MLP1 execution time measurement result(1.168ms)

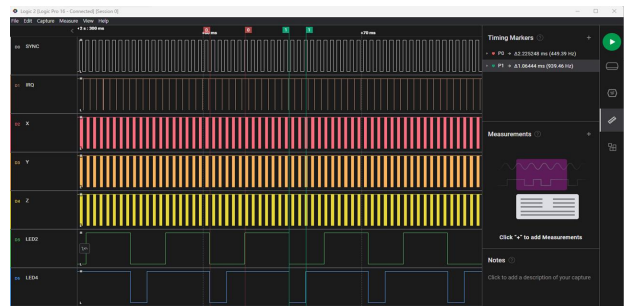


그림 10. MLP3 신경망 실행시간 측정결과(1.064ms)

Fig. 10. MLP3 execution time measurement result(1.064ms)

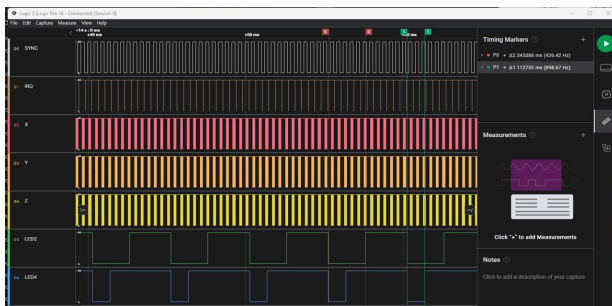


그림 9. MLP2 신경망 실행시간 측정결과(1.113ms)

Fig. 9. MLP2 execution time measurement result(1.113ms)

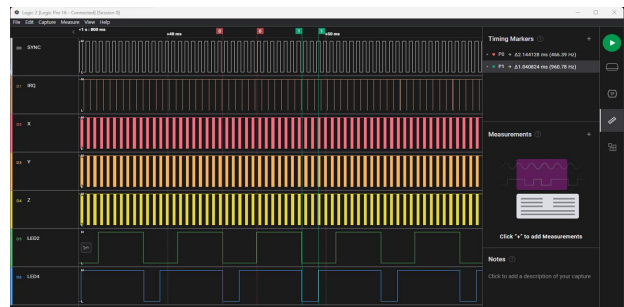


그림 11. MLP4 신경망 실행시간 측정결과(1.041ms)

Fig. 11. MLP4 execution time measurement result(1.041ms)

신경망 모델에 진입하기 전과 후의 시간차를 기록하기 위해

logic analyzer를 사용했으며 그 결과는 그림 8~11에 나와 있다.

앞 절에서 예측한 바와 같이 계산 복잡도가 가장 높은 MLP1의 실행 시간이 가장 길었고, 계산 복잡도가 감소할수록 실행 시간도 감소하는 결과를 보였다. MLP1의 실행시간은 1.168ms, MLP2의 실행시간은 1.113ms, MLP3의 실행시간은 1.064ms, MLP4의 실행시간은 1.041ms로 측정되었다. MLP1의 실행시간이 가장 길게 측정되었지만, 요구조건인 1.2ms 이하를 만족하기 때문에 실행시간 측면에서는 문제가 없음이 확인되었다.

V. 결 론

본 논문에서는 EGM2008 중력 모델에서 파생된 지표면 중력 데이터를 학습한 MLP 신경망을 사용하여 중력교란을 실시간으로 추정하는 방법에 대해서 다루었다. 본 연구의 범위는 장애물이 없는 수상이나 지상의 도로만을 주행하는 플랫폼을 대상으로 한다. 제한조건 하에서 움직이는 차량이나 선박의 고도는 위도와 경도 좌표를 기준으로 미리 결정되어 있다고 가정하였다. 이러한 제약조건으로 인해 학습 데이터를 2차원 상의 한 점으로 처리할 수 있어 MLP 기반 학습이 가능해졌다.

또한 MLP 신경망을 구현해야 하는 타겟은 INS의 내장형 컴퓨터이기 때문에 각 신경망의 계산시간이 1.2ms로 제한되어 있다. 따라서 신경망 크기를 결정하기 위해 계산복잡도(T_c) 공식과 이전의 연구결과를 인용하여 각 MLP의 계산복잡도가 $T_c \approx 13,250$ 과 유사한 크기를 갖도록 MLP1~MLP4로 표시되는 4개의 서로 다른 신경망을 설계하여 중력교란의 동쪽 및 북쪽 구성 요소 계산이 약 1.2ms 내에 완료될 수 있도록 하였다. MLP 학습에 사용된 데이터는 한반도 주변 지역으로, 위도 33°~39°, 경도 124°~132°를 대상으로 3 arcsec($1^\circ/3600$) 간격으로 계산하였다. 그 결과 MLP 학습에 사용되는 61,924,800개의 데이터 세트가 생성되었으며, 학습대상 데이터 세트는 중력교란 데이터와 육상에서의 고도를 결정하기 위한 평균해수면 고도 및 SRTM 데이터 세트가 포함되었다. 최종 검증 과정에서 학습 정확도를 평가하기 위해 Half Mean Squared Error와 RMSE를 계산했으며, 학습오차가 가장 작은 것은 MLP3 신경망 모델인 것으로 확인되었다.

본 연구에서는 학습이 완료된 신경망을 이후 INS의 내장형 컴퓨터에 구현하였으며, 실행 시간을 측정한 결과 MLP1의 실행시간은 1.168ms, MLP2의 실행시간은 1.113ms, MLP3의 실행시간은 1.064ms, MLP4의 실행시간은 1.041ms로 측정되었다. MLP1에서 MLP4까지 실행 시간이 계산복잡도 결과와 유사하게 순차적으로 감소하는 것으로 나타났다.

이번 연구를 통해 기존 연구에서는 제시하지 못했던 고정밀, 고차원의 중력모델의 INS 내장형 컴퓨터에서 실시간 계산이 가능함이 입증되었다.

Acknowledgment

이 논문은 2023년 정부의 재원으로 국방과학연구소의 지원을 받아 수행된 연구임.

References

- [1] D. H. Titterton, and J. L. Weston, *Strapdown Inertial Navigation Technology*, 2nd ed.; London, U.K.: IEE, 2004.
- [2] X. Xu, T. Zhang, and Z. Wang, "In motion filter-QUEST alignment for strapdown inertial navigation systems," *IEEE Trans. Instrum. Meas.* Vol. 67, No. 8, pp. 1979–1993, Aug. 2018.
- [3] M. de Angeli, A. Bertoldi, L. Cacciapuoti, A. Griorgini, G. Lamporesi, M. Prevedelli, G. Saccorrotti, F. Sorrentino and G. M. Tino, "Precision gravimetry with atomic sensors," *Meas. Sci. Technol.*, Vol. 20, No. 2, 022001, Dec. 2009.
- [4] J. H. Kwon, and C. Jekeli, "Gravity requirements for compensation of ultra-precise inertial navigation," *J. Navigation*, Vol. 58, No. 3, pp. 479–492, Sep. 2005.
- [5] C. Lubin, Q. Fangjun, and W. Meiping, "Gravity Disturbance Compensation for Inertial Navigation System," *IEEE Trans. Instrum. Meas.*, Vol. 68, No. 10, pp. 3751–3765, Oct. 2019.
- [6] C. Jekeli, "Precision free-inertial navigation with gravity compensation by an onboard gradiometer," *J. Guid. Cont. Dyn.* Vol. 29, No. 3, pp. 704–713, May 2006.
- [7] C. Jekeli, J. K. Lee, and J. H. Kwon, "On the computation and approximation of ultra-high-degree spherical harmonic series," *J. Geodesy*, Vol. 81, No. 9, pp. 603–615, Sep. 2007.
- [8] P. O. Hanson, "Correction for deflection of the vertical at the runup site", *In Proceedings of the 1988 Record Navigation into the 21st Century Position Location and Navigation Symposium (IEEE PLANS '88)*, Orlando, FL, USA, pp. 288-296, 29 Nov.–2 Dec. 1988.
- [9] G. George, "High accuracy performance capabilities of the military standard ring laser gyro inertial navigation unit," *In Proceedings of the Position Location and Navigation Symposium*, Las Vegas, NV, USA, pp. 464-473, 11–15 Apr. 1994.
- [10] X. Zhou, G. Yang, and J. Wang, J. Li, "An improved gravity compensation method for high-precision free-INS based on MEC-BP-adaboost," *Meas. Sci. Technol.* Vol. 27, No. 12: 125007, Dec. 2016.
- [11] X. Zhou, G. Yang, Q. Cai, and J. Wang, "A novel gravity

compensation method for high precision free-INS based on extreme learning machine,” *Sensors*, Vol. 16, No. 12:2019, Nov. 2016.

[12] C. Förste, Q. Abrykosov, J. M. Lemoine, F. Flechter, G. Balmino, and F. Barthemes, “EIGEN-6C4 The latest combined global gravity field model including GOCE data up to degree and order 2190 of GFZ Potsdam and GRGS Toulouse,” *5th GOCE user workshop*, Paris, France, 25–28 Nov. 2014.

[13] J. Wang, G. Yang, X. Li, X. Zhou, “Application of the spherical harmonic gravity model in high precision inertial navigation systems,” *Meas. Sci. Technol.*, Vol. 27, No. 9: 095103, Sep. 2016.

[14] J. Wang, G. Yang, J. Li, X. Zhou, “An Online Gravity Modeling Method Applied for High Precision Free-INS,” *Sensors*, Vol. 16, No. 10:1541, Sep. 2016.

[15] R. Wu, Q. Wu, F. Han, T. Liu, P. Hu, H. Li, “Gravity compensation using egm2008 for high-precision long-term inertial navigation systems,” *Sensors*, Vol. 16, No. 10: 2177, Dec. 2016.

[16] J. Tie, M. Wu, J. Cao, J. Lian, S. Cai, “The impact of initial alignment on compensation for deflection of vertical in inertial navigation,” *In Proceedings of the IEEE 8th International Conference on Cybernetics and Intelligent Systems, Robotics Automation and Mechatronics*, Ningbo, China, 19–21 Nov. 2017.

[17] B. Hofmann-Wellenhof, H. Moritz, *Physical Geodesy*, 2nd ed. NewYork, NY: SpringerWienNewYork, 2006.

[18] R. Casado, A. Bermúdez, “Neural Network-Based Aircraft Conflict Prediction in Final Approach Maneuvers”, *Sensors*, Vol. 9, No. 10: 1708, Oct. 2020.

[19] W.S. McCulloch, W. Pitts, “A logical calculus of the ideas immanent in nervous activity,”. *Bull. Math. Biol.*, Vol. 5, pp. 115–133, Dec. 1943.

[20] P. J. Werbos, “Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. Ph.D. Thesis, Harvard University, Cambridge, MA, USA, 1974.

[21] K. T. Lee, M. S. Kim, H. J. Kim, J. H. Kim, “A Model to Predict Occupational Safety and Health Management Expenses in Construction Applying Multi-variate Regression Analysis and Deep Neural Network,” *Journal of the Architectural Institute of Korea*, Vol. 37, pp. 217–226, 2021.

[22] H. S. Kim, and C. S. Park, “A Study on Real-time Calculation of Geoid applicable to Embedded Systems,” *Jour. of Advanced Navigation Tech.*, Vo. 24, No. 5, pp. 374–381, 2020.

[23] USGS.gov. Available: <https://earthexplorer.usgs.gov>

[24] The MathWorks Inc. Deep Learning Toolbox. Available: <https://www.mathworks.com/products/deep-learning.html>

[25] NXP semiconductors. QorIQ P2020. Available: <https://www.nxp.com/products/processors-and-microcontrollers/power-architecture/qoriq-communication-processors/p-series/qoriq-p2020-and-p2010-dual-and-single-core-communications-processors:P2020>.

[26] H. S. Kim, and C. S. Park, “DNN Based Geoid Undulation Prediction Accuracy Evaluation Using EGM08 Gravity Model,” *Trans. of Korean Inst. of Elec. Engineering*, Vol. 71, No.8, pp 1157-1163, Aug. 2022.

[27] The Wind River Systems, Inc. VxWorks. Available online: <https://www.windriver.com/products/vxworks>



김 현 석 (Hyun-Seok kim)

2003년 : 한양대 전기전자공학부(공학사)
 2005년 : 서울대학교 전기전자공학부(공학석사)
 2005년 2월 ~ 현재 : 국방과학연구소 책임연구원
 2019년 3월 ~ 현재 : 충북대학교 전자정보대학 박사과정
 ※관심분야 : 관성항법시스템, 위성항법시스템, 추정 이론, INS/GPS 통합항법, 중력모델



김 형 수 (Kil-Dong Hong)

2007년 8월: 한국정보통신대학교 전자통신공학과 학사
 2009년 8월: 한국과학기술원 정보통신공학과 석사
 2009년 9월 - 2013년 3월: LG이노텍 주임연구원
 2014년 9월 - 현재: 국방과학연구소 연구원
 ※관심분야 : 관성항법, 위성항법, 칼만필터, 복합항법



최운혁 (Kil-Dong Hong)

2011년 8월 : 홍익대학교 조선해양공학과 (공학사)
2013년 8월 : 부산대학교 조선해양공학과 (공학석사)
2013년 8월 ~ 현재 : 국방과학연구소 연구원
※관심분야 : 관성항법시스템, 위성항법시스템, 복합보정항법, 칼만필터



조운철 (Yun-Chul Cho)

1989년 2월 : 부산대 기계공학 (공학학사)
1991년 2월 : 부산대 기계공학 (공학석사)
1991년 2월 ~ 현재 : 국방과학연구소 3본부 4부 책임연구원
※관심분야 : 관성항법시스템, 위성항법시스템, 별센서, 추정 이론, 필터링



박찬식 (Chansik Park)

1984년 2월 : 서울대학교 제어계측공학과(공학사)
1986년 2월 : 서울대학교 제어계측공학과(공학석사)
1997년 2월 : 서울대학교 제어계측공학과(공학박사)
1997년 3월 ~ 현재 : 충북대학교 전자정보대학 교수
※관심분야 : GNSS, PNS, SDR, 미지정수결정, 오차해석