

HS 코드 분류를 위한 CNN 기반의 추천 모델 개발

이동주* · 김건우** · 최근호***

〈요 약〉

현재 운영되고 있는 관세신고납부제도는 납세의무자가 세액 산정을 스스로하고 그 세액을 본인 책임으로 납부하도록 하는 제도이다. 다시 말해, 관세법상 신고 납부제도는 납세액을 정확히 계산해서 납부할 의무와 책임이 온전히 납세의무자에게 무한정으로 부과하는 것을 원칙으로 하고 있다. 따라서, 만일 납세의무자가 그 의무와 책임을 제대로 행하지 못했을 경우에는 부족한 만큼의 세액 추징과 그에 대한 제재로 가산세를 부과하고 있다. 이러한 이유로 세액 산정의 기본이 되는 품목분류는 관세평가와 함께 가장 어려운 부분이며 잘못 분류하게 되면 기업에게도 큰 리스크가 될 수도 있다. 이러한 이유로 관세전문가인 관세사에게 상당한 수수료를 지불하면서 수입신고를 위탁하여 처리하고 있는 실정이다. 이에 본 연구에서는 수입신고 시 신고하려는 품목이 어떤 것인지 HS 코드 분류를 하여 수입신고 시 기재해야 할 HS 코드를 추천해 주는데 목적이 있다. HS 코드 분류를 위해 관세청 품목분류 결정 사례를 바탕으로 사례에 첨부된 이미지를 활용하여 HS 코드 분류를 하였다. 이미지 분류를 위해 이미지 인식에 많이 사용되는 딥러닝 알고리즘인 CNN을 사용하였는데, 세부적으로 CNN 모델 중 VggNet(Vgg16, Vgg19), ResNet50, Inception-V3 모델을 사용하였다. 분류 정확도를 높이기 위해 3개의 dataset을 만들어 실험을 진행하였다. Dataset 1은 HS 코드 이미지가 가장 많은 5종을 선정하였고 Dataset 2와 Dataset 3은 HS 코드 2단위 중 가장 데이터 샘플의 수가 많은 87류를 대상으로 하였으며, 이 중 샘플 수가 많은 5종으로 분류 범위를 좁혀 분석하였다. 이 중 dataset 3로 학습시켜 HS 코드 분류를 수행하였을 때 Vgg16 모델에서 분류 정확도가 73.12%로 가장 높았다. 본 연구는 HS 코드 이미지를 이용해 딥러닝에 기반한 HS 코드 분류를 최초로 시도하였다는 점에서 의미가 있다. 또한, 수출입 업무를 하고 있는 기업이나 개인사업자들이 본 연구에서 제안한 모델을 참조하여 활용할 수 있다면 수출입 신고 시 HS 코드 작성에 도움될 것으로 기대된다.

핵심주제어: 분류, 추천, HS 코드, 딥러닝, CNN

논문접수일: 2020년 05월 20일 수정일: 2020년 06월 24일 게재확정일: 2020년 07월 27일

* (주)데이터월드 차장(제1저자), djlee@dataworld.co.kr

** 한밭대학교 경영회계학과 부교수(교신저자), gkim@hanbat.ac.kr

*** 한밭대학교 경영회계학과 조교수, keunho@hanbat.ac.kr

I. 서론

최근 5년간 우리나라 수입거래량을 보면, 2015년 14,459,780건에서 매년 백만 건 이상 증가하며 2018년에는 수입건수가 21,559,704건으로 2015년과 비교하여 1.5배 가까이 늘어났다(수출입무역통계, 2019).

이와 같이, 수입거래량이 늘어나면서 수입을 신고하는 양이 많아졌으며 이에 따라 관세 납부도 증가하고 있는 추세이다. 관세는 수입신고서 작성 시 기재되는 HS 코드를 근거로 세율을 부과하고 있다. 하지만 일반인이 수입 품목에 대한 HS 코드를 작성하는 것은 쉬운 일이 아니다. 통관 절차 중 품목분류는 관세평가와 같이 가장 어렵고 잘못 분류할 경우 기업입장에서도 큰 리스크가 될 수 있는 업무 중 하나이다. 그 이유는 현재의 관세신고납부제도는 납세의무자가 신고 품목에 대해 스스로 판단해 세액을 산정하고, 산정된 세액에 대해서는 신고자의 책임 하에 납부가 이루어지기 때문이다. 다시 말해, 관세법상 신고 납부제도는 납입할 세액을 정확히 계산해서 납부할 의무가 납세의무자에게 있고 이에 대한 책임도 납세의무자에게 있으며, 이를 제대로 이행하지 못할 경우 부족한 세액에 대한 추징과 가산세가 부여될 수 있으며, 이에 따라 행정적인 절차와 관련한 마찰이 발생할 수 있다.(강홍중, 2010; 박상봉, 2016).

이렇듯 현 제도는 무역업자에게 납세에 대한 책임을 크게 지우고 있지만 정확한 품목분류를 통한 납세신고는 일반인에게는 여전히 어려운 일이다. 품목분류는 상품에 대한 지식수준이 높고 관세율표상 품목분류 원리에 대한 지식과 경험이 필요하기 때문에 기업 입장에서 이러한 위험 부담을 피하기 위해 관세 전문가인 관세사를 통해 많은 양의 수수료를 지불하면서 수입신고를 위탁하고 있는 실정이다.

HS 코드는 세계관세기구(WCO)가 정한 국제통일 상품분류체계(HS)에 따라 전 세계에서 거래되는 각종 물품을 하나의 품목번호에 분류하는 것으로서, 국제통상 상품분류체계에 관한 국제협약(The International Convention on the Harmonized Commodity Description and Coding System: HS 협약)에 따라 체약국은 HS체계에서 정해진 원칙에 따라 품목분류 업무를 수행하게 된다.

국제통일 상품분류체계(HS)는 관세, 무역통계, 운송, 보험 등과 같이 다양한 목적에 이용될 수 있도록 만든 상품분류체제로서, 상품분류 체계의 통일을 기하여 국제무역을 원활히 하고 관세율 적용의 일관성을 유지하는 것을 목적으로 한다(대구본부세관 홈페이지).

이렇듯 품목분류는 통관절차 중 가장 어려운 과정 중 하나이며, 품목분류에 따라 세율이 달라지는 만큼 품목분류를 정확히 하는 것은 무역업자들에게는 매우 중요한 일이다.

품목분류에 대한 기존의 관련 연구들을 살펴보면, 품목분류제도에 대한 이론적 고찰 및 주요 국가의 품목분류제도 운용 현황, 그리고 품목분류에 대한 분쟁사례와 판례 분석을 통해 시사점을 도출하고 제도적 측면에서의 개선방안을 제안하는 연구가 주를 이룬다(윤인철, 2013; 육수진, 2017; 성원식, 심재원, 김은경, 2018). 이와 같이, 기존의 연구들은 품목분류의 분쟁사례와 이슈들에 대해 정책적/제도적 개선방안을 제시했다는 점에서 매우 의의가 높다고 할 수 있다.

최근 인터넷과 컴퓨팅 기술이 급속히 발전하면서 빅데이터를 이용한 기계학습 및 인공지능 기반의 문서분류 성공사례가 여러 산업 군에서 나오고 있지만, HS 코드를 자동으로 분류하는 사례는 그 필요성에도 불구하고 아직까지 찾아볼 수 없는 실정이다.

따라서, 본 연구에서는 통관절차에서 가장 어려운 과정 중에 하나인 품목분류를 대상으로 수

입신고 시 기입해야 하는 HS 코드를 추천하고자 한다. 이를 위해 기존 품목분류 사전심사 시 사용되었던 신고품목 이미지를 이용하여 새롭게 수입 신고하려는 품목의 HS 코드 정보를 제공해주는 모델을 제안하고자 한다.

본 연구는 수입신고품목 이미지에 딥러닝 모델을 적용하여 HS 코드 분류를 시도한 첫 사례라는 점에서 의의를 갖는다. 또한, 최근 이미지를 이용한 분류모델 구축 시 가장 널리 사용되어져 오고 있고 우수한 성능을 보여준 CNN 기반의 여러 알고리즘별 딥러닝 분류 모델을 구축하고 각 모델의 분류 성능을 비교 평가하였다는 점, 그리고 학습 데이터의 클래스별 균형을 맞추기 위해 좌우 반전, 상하 반전, 회전 등을 통한 데이터 생성을 수행하였다는 점에서 CNN을 활용한 이미지 분류 관련 선행연구들과는 다른 학술적 의의를 지닌다. 즉, 본 연구는 수입신고품목 이미지만을 활용해 HS 코드에 대한 분류를 시도하고 분류 모델을 제안하는데 목적이 있다.

본 연구의 구성은 다음과 같다. 2장에서는 관세품목분류와 딥러닝, 그리고 CNN에 관한 선행연구들을 다룬다. 3장에서는 본 연구에서 사용한 HS 코드 이미지 데이터와 실험 방법에 대해 다루며, 4장에서는 본 연구의 이미지 분류 실험 결과에 대해 다룬다. 마지막으로 5장에서는 본 연구의 결론과 시사점, 그리고 한계점을 다룬다.

II. 이론적 배경

1. 관세품목분류 관련 연구

1.1 관세품목분류

관세품목분류는 무역업자들이 수입하는 물품에 대해 정확한 HS 코드를 부여하는 것만으로

해당 품목에 대한 관세율이 정해지기 때문에 수입하는 물품에 대한 정확한 납부세액 산출을 위해서는 매우 중요한 요소이다. 또한 FTA 협정에서 HS 코드별로 원산지결정기준이 각각 달리 정해져 있으므로 FTA 협정 관세의 정확한 적용을 위해서도 검토되어야 하는 매우 중요한 요소이다(관세법인화우, 2016).

1.2 HS 코드의 배열체계와 분류 기준

HS는 관세, 통계 등을 위한 다목적 품목분류표로 수출입 되는 모든 상품 분류가 합리적으로 명확하게 규정되어야 한다. 이러한 이유로 HS 코드 분류는 수직적으로는 부→류(2단위)→호(4단위)→소호(5,6단위)로 배열되고 수평적으로는 부(1부, 2부, ..., 21부)·류(1류, 2류 ..., 97류)·질 및 호로 배열된다. HS의 상품배열은 식물성, 동물성, 광물성 생산품 등의 기초 원재료부터 시작하여 산업별 또는 생산단계별로 수평 배열된다.

HS는 동일한 원재료에서 얻어지는 모든 물품은 동일한 1개의 류(Chapter)에 같이 분류한다. 그리고 각류 내에서는 생산단계별 및 가공단계별로 원재료→반제품→완제품 순으로 호별 수직 배열된다. 그러나 윤인철(2013)에 따르면, 서로 다른 원재료를 사용하여 하나의 제품으로 완성되는 물품의 경우에는 일반적인 생산단계별 및 가공단계별 분류기준을 적용하지 않고 있다. 이는 무역거래의 특성상 다양한 물품을 각기 다른 기준에 따라 분류하는 것이 합리적이기 때문이다.

1.3 HS 코드 분류표의 체계

HS는 협약의 부속서에 규정된 Heading(호)·Sub-Heading(소호)의 내용 및 그것과 관련된 Section(부)·Chapter(류)·소호의 주(註, Note)와 HS해석에 관한 통칙 등으로 구성되어 있다. HS

기본구조는 품목분류표 전체의 분류원칙을 정한 통칙(GRI)이 있고 분류체계는 부→류→(절)→호→소호의 수직적 분류형식을 취하고 있으며, 통칙과 함께 품목분류의 지침이 되는 것이 “주(註)”인데 이는 부·류·소호에 게시되어 있다.

HS 해석에 관한 통칙(GRI: General Rules for Interpretation of Nomenclature)은 ‘호의 용어’와 ‘주’ 등의 적용에 있어 해석에 따라 품목분류가 달라질 수 있는 사항에 대하여 통칙적 분류를 하기 위한 기본원칙을 정해놓은 것이다. ‘주’나 ‘호의 용어’에서 특별히 규정하고 있지 아니한 모든 상품의 분류에 적용되는 일반원칙이며 법적 구속력이 있다.

부는 제01부부터 제21부까지 전체 21개의 부로 구성되어 있는데, 각 부에는 표제(예: 제01부-살아 있는 동물과 동물성 생산품)가 설정되어 있다. 하지만 표제는 품목분류적용에 있어 참조 편의상 설정된 것이며 법적 구속력은 가지고 있지 않다. 다만, HS의 구조로서의 구속력은 갖고 있다.

류는 제01류부터 제97류까지 전체 97개의 류로 구성되어 있으나 제77류는 유보 상태로 96개의 류를 사용하고 있다. 류는 부(Section)를 세분한 것으로 반드시 2단위 숫자로 표기하여야 하며(예: 07류), 류의 2단위 숫자는 호를 형성하기 위한 필수 단위 숫자이기 때문에 품목분류에 있어서는 류가 먼저 확정되어야 한다. 또한 류의 품목분류는 일반적으로 부와 같이 산업별 형태를 유지하면서 재질, 가공형태, 용도 등에 따라 분류되어 있으며 각 류에는 유사한 물품들이 그룹화 되어 있다.

절은 류를 참조 편의상 세분한 것으로 절에도 부·류와 마찬가지로 법적 구속력이 없는 표제가 설정되어 있으며, 특정류 외에는 절이 없다. 절이 있는 류는 제28류, 제29류, 제39류, 제63류, 제69류, 제71류, 제72류 등이다.

호는 류를 품목에 따라 세분한 것으로서, 2012년 기준으로 총 1,244개의 호로 구성되어 있다. 앞의 2단위는 류를 의미하고, 뒤의 2단위는 류 내에서의 품목번호를 나타내고 있다. 호의 용어란 4단위 코드번호와 연결하여 설정되어 있는 개별 품목들을 의미하며, 호의 용어는 HS 해석에 관한 통칙 1의 규정에 따라 법적 구속력이 있는 협약된 용어이다. ‘호(소호포함)’의 용어는 통칙, 부·류의 주와 함께 HS 코드 분류의 3대 구성요소이다.

소호는 호(4단위)를 5단위 또는 6단위로 세분화 한 것으로서 HS는 6단위 분류체계이다. HS는 총 5,225개의 소호로 구성되어 있고, 소호에만 적용되는 ‘주’가 일부 설정되어 있다. 이 주는 소호의 코드번호(6단위)와 연결된 품목을 의미하며 호의 경우와 같이 순서나 내용 등의 변경을 임의로 할 수 없는 법적 구속력이 있는 협약된 용어이다.

앞서 설명한 “통칙” 내지 “소호”의 내용은 HS 구성요소에 대한 설명이며(6단위까지), 7단위 이하를 우리나라 실정에 맞게 세분한 것이 관세·통계통합품목분류표(HSK)에 대한 구성요소라 할 수 있다. 소호(6단위)를 7·8단위 및 9·10단위로 세분화하였고 8단위는 세목을 의미하는데 10단위까지는 기획재정부 고시사항인 통계분류(세분류) 사항이다.

1.4 HS 코드 분류 분쟁

WCO HS 협약 제10조에는 품목분류의 분쟁 해결방법과 절차가 규정되어 있으며, 품목분류분쟁 조정제도와 정책의 수립은 HS 이사회에서 맡고 있다. 실제로 우리나라의 수출물품이 수입국 세관의 자의적인 품목분류로 인해 부당한 관세를 부과받거나 통관승인이 어려워져 과세관청에 호소하는 사례가 발생하고 있다. 특히, 여러 많은 국가들과 FTA를 체결하게 되면서, 한국산

물품에 대한 관세가 낮아지게 되자 수입국의 품목분류심사가 엄격해지고 있는 실정이다. 즉, 자국의 무역보호와 이익을 위해 품목분류를 주관적으로 해석해 적용하는 사례가 줄지 않고 있으며, 이는 국가 간의 품목분류 분쟁으로 이어지고 있다(육수진, 2017). 또한, 관세법령정보포털 결정 사례에 따르면, 품목분류 및 각종 행정적인 절차와 관련하여 국내에서도 지속적인 마찰이 발생하고 있는 것으로 나타났다.

2. 딥러닝 관련 연구

딥러닝은 새로운 이론이 아니며 인공 신경망을 통해 학습하는 기계학습(machine learning)의 한 분야이다. 인공 신경망(Artificial Neural Network)은 인간의 뇌가 가지고 있는 생물학적 특성 중 하나인 뉴런의 연결 구조인데, 이러한 신경망을 따라 만든 네트워크 구조의 알고리즘을 말한다. 이러한 딥러닝은 기계학습의 한 분야이지만 차이점이 있다. 우선, 기계학습의 경우, 학습하려는 데이터의 여러 특징 중 어떤 특징을 추출할 것인지를 인간이 분석하고 직접 판단해야 하는 반면, 딥러닝은 기계가 자동으로 학습하여 데이터에서 어떠한 특징을 기계 스스로 학습하여 추출한다는 것이다. 이처럼 딥러닝과 기계학습의 가장 큰 차이점은 바로 기계의 자가 학습 여부로 볼 수 있다. 즉, 딥러닝은 기계가 자동으로 대량의 데이터에서 중요한 패턴 및 규칙을 학습하여 이를 토대로 의사결정이나 예측 등을 수행하는 기술이라 할 수 있다.

딥러닝 알고리즘에는 이미지 인식 분야에서 큰 성과를 보이고 있는 CNN(Convolutional Neural Network), 단어의 순서에 따른 연결이 고려되는 자연어 처리에서 많이 사용되며 데이터의 시간적 정보를 학습하기 위한 RNN(Recurrent Neural

Network), 입력층과 은닉층으로 구성된 RBM(Restricted Boltzmann Machine)을 블록처럼 여러 층으로 쌓은 형태인 DBN(Deep Belief Network) 등이 있으며 데이터의 특성과 학습 목표에 따라 적절한 딥러닝 알고리즘이 사용된다(LeCun, Bengio, & Hinton, 2015).

3. CNN 관련 연구

3.1 CNN(Convolution Neural Network)

CNN은 딥러닝 구조 중 하나로 인간의 시신경을 모방해서 만들었다. 이 CNN은 convolution 연산을 통해 이미지의 공간적 정보를 유지하면서 fully connected neural network 대비 연산되는 양을 엄청나게 줄였고 이미지 분류 영역에서 좋은 성능을 나타내고 있는 딥러닝 구조이다. 1980년 Kunihiko Fukushima는 Neocognition을 발표하였는데 이것이 CNN 구조의 시초라고 할 수 있다. LeCun et al.(1998)은 수기로 작성한 숫자를 인식하기 위한 방법으로 LeNet-5를 제안했으며 이는 이미지 데이터 학습에 큰 발전을 가져오게 되었다. 이를 기반으로 CNN은 다양한 형태의 모델들이 나왔고, 이미지 인식 경연대회를 휩쓸며 여러 응용 분야에서 널리 사용되고 있다.

LeNet은 입력 층을 제외한 다수의 층들로 구성되어 있으며 3개의 다른 층(C1,C3,C5)인 컨볼루션 층(convolutional layer), 2개의 서브샘플링 층(Subsampling- S2,S4), 1개의 완전연결층(fully connected layer, F6), 아웃풋 레이어(Output layer)로 구성되어 있다. 일반적인 CNN 구조는 컨볼루션층과 풀링층을 번갈아 가며 사용하여 입력된 데이터의 특성을 추출하고 마지막에 완전연결층을 통해 특정한 형태 이미지를 인식하여 분류를 하게 된다. CNN이 다른 딥러닝 알고

리즘 보다 이미지나 비디오 분류에 더 좋은 성과를 내는 이유는 다음과 같은 3가지 이유다.

첫째, CNN은 컨볼루션 층에서 이미지의 특징을 찾아내기 위해 필터(Filter)를 이용한다. 필터는 커널(Kernel)이라고도 하는데, 필터는 대부분 (4,4)이나 (3,3)과 같은 정사각형 행렬로 정의되며 입력 데이터를 지정된 간격으로 이동하며 채널별로 합성곱을 하고 모든 채널에서의 합성곱을 계산하며 특성맵(Feature Map)을 만든다. 이때 필터를 순회하는 지정된 간격을 스트라이드(Stride)라 하며, 입력 데이터가 여러 채널을 가지고 있다면 필터는 각 채널을 순회하면서 합성곱을 계산해 채널별 특성맵을 만들게 되는데, 여기에 활성화 함수(Activation Function)를 적용하면 최종 특성맵(Activation Map)을 얻게 된다.

둘째, 풀링층(Pooling Layer)은 데이터의 공간적 특성은 그대로 유지하면서 크기를 줄이는 층으로서, 연속적인 합성곱층 사이 사이에 주기적으로 넣어준다. 이렇게 함으로써 데이터의 상대적인 특성을 구성하고 모수의 수를 줄일 수 있다. 풀링층은 특정위치에서 큰 역할을 하는 특징을 추출하거나 전체를 대변하는 특징을 추출할 수 있으며 크기가 줄어들기 때문에, 학습할 가중치도 크게 줄어 과적합 문제(Overfitting problem)를 완화시킨다. 풀링에는 평균 풀링(Average Pooling), 최대 풀링(Max Pooling), 최소 풀링(Min Pooling) 등이 있다. 평균 풀링은 해당 영역 내 값들의 평균을 선택하는 방법이고 최대 풀링은 해당 영역 내에서 가장 큰 값을 선택하는 방법이며 최소 풀링은 해당 영역 내에서 가장 작은 값을 선택하는 방법이다. 보통 CNN에 적용하여 사용할 때는 최대 풀링을 많이 이용하며 일반적으로 결과도 좋다고 알려져 있다.

셋째, 드랍아웃(Dropout)은 과적합 문제를 해결하기 위해 제안된 방법이다. 학습 중에 전체 가중치를 학습에 참여시키는 것이 아니라 층

(layer)에 포함된 가중치 중 일부만 학습시켜 과적합을 방지하는 방법이다. 이렇게 드랍아웃을 적용하면 다양한 구조를 학습할 수 있고 학습시 발생하는 과적합도 완화시킬 수 있다 (Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014).

CNN을 활용한 이미지 분류 관련 연구들을 살펴보면, 백승훈 외(2020)는 의류 이미지 데이터에 CNN 기술을 적용하여 새로운 의류 이미지와 유사한 의류 제품을 탐색하는 모델을 제안하였다. 윤재웅 외(2019)는 CNN 기법을 활용한 지능형 유사 상표 검색 모델을 개발하여 기업의 상표권 보호 및 선등록 상표에 대한 사전조사 시 발생하는 비용을 절감하고 상표권 침해 문제를 해결하고자 하였다. 윤재웅 외(2017)는 아토피피부염 환자의 삶의 질을 향상시키고자 아토피피부염 환자의 이미지 데이터를 수집한 후, 이를 학습하여 CNN 알고리즘에 기반한 지능형 아토피피부염 중증도 진단 모델을 개발하였다. 장현웅 & 조수선(2016)은 CNN 기법을 적용하여 이미지의 내용정보를 바탕으로 이미지로부터 태그를 자동으로 추출하는 방법을 제안하였다.

3.2 VggNet

VggNet은 옥스퍼드 대학의 연구팀 Visual Geometry Group(VGG)에 의해 개발된 모델이다. 2014년 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에 참가하여 GoogleNet과 함께 주목을 받았고 근소한 차이로 2위를 차지하였다. 하지만 VggNet은 GoogleNet에 비해 훨씬 간단한 구조와 이해와 변형이 쉽다는 장점이 있어 이 대회에서 1위를 차지한 GoogleNet 보다 많은 네트워크에서 응용되고 있다. VggNet은 모델의 깊이가 성능에 얼마나 영향을 미칠지에 관점을 두고 연구한 모델이다. 깊은 네트워크를 가지고는 있지만 GoogleNet과 비교해보면 구조가

더 간단하다. 깊이의 따른 변화를 비교하기 위해서 3X3의 작은 필터를 사용하였고 모델의 구조와 깊이에 변화를 주며 실험하였다.

VggNet의 특징은 작은 필터 크기의 컨볼루션 연산을 한다는 것이다. Alexnet의 Convolution layer의 필터 크기는 11X11이고 GoogleNet의 경우는 7X7이지만 VggNet은 3X3의 필터 크기를 사용한다. 3X3 컨볼루션을 두 번 쌓는 것은 5X5 컨볼루션과 동일한 정보를 처리하지만 3X3 컨볼루션을 여러 번 쌓는 것이 성능을 더 좋게 낼 수 있는데 그 이유는 두 가지이다.

첫째, 3X3 컨볼루션 연산을 여러 번 수행하는 것은 여러 번의 비선형 처리를 하는 것과 같아 큰 필터로 한 번만 연산하는 것보다 더 많은 비선형성을 가질 수 있다. 둘째는 파라미터 수가 3X3 컨볼루션을 여러 번 했을 때 더 적다는 것이다.

VggNet의 단점으로는 fully connected layer가 3개가 있고 풀링(Pooling)을 거친 뒤에는 특성맵(Feature Map)의 수가 2배로 많아지면서 필요한 파라미터가 과도하게 많아진다. 파라미터가 많아진다는 것은 gradient vanishing과 과적합 등의 문제를 야기할 가능성이 크다는 것을 의미한다. 하지만 이러한 단점에도 불구하고 VggNet은 간단한 구조와 좋은 성능으로 네트워크에서 많이 사용되고 있다.

3.3 ResNet

Resnet은 2015년 ILSVRC(ImageNet Large-Scale Visual Recognition Challenge) 대회에서 우승하였고 Top5 Error가 3.6%로 사람이 분류하는 수준인 5%를 능가한 모델이다. Alexnet이 처음 제안된 이후로 CNN 아키텍처의 층은 점점 더 깊어졌으며, Alexnet이 불과 5개 층인 반면 VggNet은 19개 층, GoogleNet은 22개 층에 도달했다. 하지만 층이 깊어질수록 gradient vanishing

또는 exploding 문제 때문에 오히려 성능이 떨어지는 원인이 되는데 이런 현상을 degradation 문제라고 한다. 층이 깊은 상태에서 학습을 많이 진행한 경우 가중치의 분포가 균등하지 않고 역전파시 기울기가 충분치 않아 학습을 안정적으로 진행할 수 없는 문제가 발생된다. 이러한 degradation 문제를 해결하기 위해 residual block이 제시되었는데, gradient가 잘 흐를 수 있도록 일종의 지름길(shortcut connection)을 만들어 주는 것과 같은 역할을 한다.

3.4 Inception(GoogleNet)

GoogleNet은 2014년 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서 1위를 차지한 모델이다. 이 대회 이후 GoogleNet은 “Going deeper with convolutions”이라는 논문에서 Inception이라는 이름을 발표하여 사용하였다. 보통 딥러닝은 망이 깊고 레이어가 넓을수록 성능이 좋다고 하는데 현실적으로는 네트워크를 크게 만들면 파라미터가 많아지고 망이 늘어날 때마다 연산량이 지수적으로 많아지며 과적합, Gradient vanishing 등의 문제로 학습이 힘들다. 그래서 이를 해결하기 위해 노드간의 연결을 줄이면서(Sparse connectivity) 행렬 연산은 Dense 연산을 할 수 있도록 한 것이 Inception Module이다(Szegedy et al., 2015).

3.5 Inception-V3

Inception-V3는 구조적인 변화나 다양한 모양의 필터를 사용한 기능들을 조합하여 만든 모델로 기존의 GoogleNet보다 학습 시 사용되는 연산량을 많이 줄인 모델이다.

Inception-V3의 특징은 컨볼루션 층의 필터들을 다양한 모양으로 factorization한 후, 컨볼루션을 실행하여 연산량을 줄인다는 것이다. VggNet 모델에서 보았듯이 3x3 컨볼루션 연산을 두 번

하는 것이 5×5 컨볼루션 연산을 한번 하는 것보다 더 좋다는 것을 알 수 있다. Inception-V3에서는 이러한 부분을 받아들였고 이것이 Inception module-A이다. Inception module-B는 $1 \times n, n \times 1$ 의 형태로 factorization 하여 사용하는데, 이렇게 할 경우 연산량을 줄일 수 있게 된다(Szegedy et al., 2016). 마지막으로 Inception module-C는 average pooling 전의 Inception module을 더 넓게 형성하였고 또한 차원을 줄이면서 발생하는 정보 손실을 막기 위해 같은 입력값에 대해 다양한 연산을 하게 하였다.

III. 연구방법

본 연구에서 제안한 이미지 기반의 HS 품목 분류 학습을 위한 실험환경 구성 및 절차는 다음과 같다. 먼저, 크롤링을 통해 학습 및 검증에 사용할 HS 코드 이미지 데이터를 수집하고, 수집된 데이터를 학습 데이터와 검증 데이터로 분할하였다. 이후, 학습 데이터 이미지에 CNN 모델을 적용하여 HS 코드 이미지 분류 모델을 학습시키고, 마지막으로 검증 데이터를 이용하여 HS 코드 이미지 분류 모델의 성능에 대한 평가를 진행하였다.

1. 데이터 수집

본 연구는 관세청에서 운영하는 관세법령정보 포털에서 제공하는 품목분류 국내사례에 등록된 기존 HS 코드 결정사례 데이터를 크롤링하여 수집하였다. 본 연구에서 수집한 데이터는 2007년부터 2019년까지 약 13년에 걸쳐 수출입 신고 전 수출입 업자의 품목분류에 대한 질의에 대해 관세청 관세평가분류원에서 법적인 효력이 있는

HS 코드를 결정하여 회신한 데이터로서, 품목분류를 요청한 품목의 이미지와 결정된 HS 부호를 포함하고 있다.

수집된 품목 이미지는 HS 코드 기준으로 전체 2,957종이며 수집된 전체 이미지 수는 27,428개이다. HS 코드별로 수집된 데이터의 분포를 보면 100개 이상의 이미지를 가지고 있는 HS 코드는 전체 33종이며 나머지 HS 코드의 분포는 51~100개 42종, 21~50개 166종, 20개 미만은 2,716종으로, 수집된 데이터의 약 90%가 100개 미만의 이미지를 가지고 있었다.

2. 데이터 전처리

처음 수집된 품목분류 이미지의 명칭은 품목 분류 결정사례에 등록된 문서번호로 되어 있어 해당 이미지의 HS 코드가 무엇인지 직관적으로 파악하기 어려웠다. 따라서, 본 연구에서는 수집된 이미지의 명칭을 변경하여 명칭만 보아도 해당 이미지가 어떤 HS 코드에 해당하는지 알 수 있도록 하기 위하여 이미지의 명칭을 “HS 코드+ 문서번호+일련번호”로 변경하여 가독성을 높였고, 이미지 명칭이 중복되지 않도록 변경하였다.

3. 이미지 데이터셋 구성

본 연구에서는 위와 같이 수집 및 전처리된 이미지 데이터를 이용하여 이미지 기반의 HS 코드분류 모델을 구축하기 위해 다음과 같이 세 가지의 dataset을 구성하였다.

첫 번째 dataset(Dataset 1)은 이미지수가 가장 많은 HS 코드 5종을 선택하여 구성하였다. 학습 데이터는 HS 코드별로 모두 동일하게 100개의 원본 이미지 데이터를 무작위로 선택하고, 선택된 각각의 이미지 데이터를 좌우 반전, 상하

반전, 회전을 시켜 이미지 당 5개의 이미지를 생성해 총 500개의 새로운 변환 이미지를 생성하였다. 즉, HS 코드별로 원본 데이터 100개와 변환 이미지 500개를 합한 총 600개의 이미지를 학습 데이터로 사용하였으며, 그 결과 HS 코드 5종에 대해 전체 3,000개의 이미지를 학습 데이터로 사용하였다. 검증 데이터는 HS 코드별로 학습에 사용되지 않은 원본 이미지 50개를 무작위로 선택하여 HS 코드 5종에 대한 총 250개의 검증 데이터를 구성하였다.

두 번째 dataset(Dataset 2)은 비슷한 성격의 이미지 데이터가 있는 특정 HS 코드 2단위(류)별로 모델을 구축하여 이미지 분류를 시도하는 것이 더 현실적일 수 있다고 판단하였고, 본 연구에서는 우선적으로 수집된 HS 코드 2단위 중 가장 많은 데이터를 가지고 있는 87류를 선정하여 데이터셋을 구성하였다. 수집된 87류의 HS 코드는 총 48종으로 이루어져 있는데, 이중 데이터가 가장 많은 4종은 원래의 HS 코드를 사용하였고 나머지 44종의 HS 코드는 데이터가 많지 않아 모두 함께 묶어 임의의 부호인 "8799999999"로 HS 코드를 부여하였다. 학습 데이터와 검증 데이터는 7:3의 비율로 나누었고, Dataset 1과는 달리 이미지를 가공하여 생성하지 않고 원본 데이

터만을 이용하였다. 최종적으로 학습 데이터 1,805개와 검증 데이터 776개가 실험에 사용되었다.

세 번째 dataset(Dataset 3)은 Dataset 2와 같이 데이터 수가 가장 많은 87류를 대상으로 하였으나, 그 구성을 다르게 하였다. Dataset 2에서는 HS 코드의 원본 이미지만을 사용하여 학습 데이터를 구성하였기 때문에 HS 코드마다 학습 데이터의 수가 다를 수밖에 없었는데, 이는 모델의 편향된 학습을 야기시켜 구축된 모델의 분류 정확도를 떨어뜨릴 수 있기 때문에 학습 데이터와 검증 데이터의 HS 코드별 데이터 수의 균형을 맞추는 작업을 수행하였다. 또한, 원본이미지 데이터에서 학습에 방해될 수 있는 질이 떨어지는 이미지들도 제외하였다.

학습 데이터와 검증 데이터의 비율은 Dataset2와 동일하게 7:3으로 하였고, 학습 데이터는 HS 코드별로 600개씩 총 3,000개를 검증 데이터는 250개씩 총 1,250개를 실험에 사용하였다. 학습 데이터와 검증 데이터 모두 원본 이미지만을 이용하여 실험이 가능한 HS 코드는 원본 이미지만으로 dataset을 구성하였고 이미지의 수가 부족한 HS 코드는 부족한 만큼 이미지를 변환 생성하여 이미지 수의 균형을 맞추었다. 각 dataset의 구성 정보는 <표 1>과 같다.

<표 1> Dataset 구성 정보

HS 코드	Image size	Train	Test
8708290000 (차량용 부분품과 부속품-기타)	224×224	600	50
3926909000 (플라스틱으로 만든 그 밖의 제품-기타)	224×224	600	50
8302300000 (모터차량용에 적합한 그 밖의 장작구/부착구와 이와 유사한 물품)	224×224	600	50
3926300000 (가구/차체와 이와 유사한 것들의 부착구)	224×224	600	50
7326909000 (철강으로 만든 그 밖의 제품-기타)	224×224	600	50

(A) Dataset 1

HS 코드	Image size	Train	Test
8708290000 (차량용 부분품과 부속품-기타)	224×224	897	384
8708999000 (차량용 부분품과 부속품-기타)	224×224	276	118
8708400000 (기어박스과 그 부분품)	224×224	198	85
8708309000 (차량용 부분품과 부속품-기타)	224×224	92	39
8799999999 (기타)	224×224	342	150

(B) Dataset 2

HS 코드	Image size	Train(원본/생성)	Test(원본/생성)
8708290000 (차량용 부분품과 부속품-기타)	224×224	600 (600/0)	250 (250/0)
8708999000 (차량용 부분품과 부속품-기타)	224×224	600 (245/355)	250 (105/145)
8708400000 (기어박스과 그 부분품)	224×224	600 (180/420)	250 (80/170)
8708309000 (차량용 부분품과 부속품-기타)	224×224	600 (75/525)	250 (26/224)
8799999999 (기타)	224×224	600 (320/280)	250 (135/115)

(C) Dataset 3

4. 이미지 분류 모델 학습

본 연구에서는 딥러닝 라이브러리인 케라스(Keras)를 이용하여 VggNet(Vgg16, Vgg19), Resnet50, Inception-V3 알고리즘을 사용한 CNN 모델을 구축하였다. 각 모델은 사전 학습된 모델(Pre-trained Model)의 가중치를 이용하였다. 사용한 가중치는 이미지넷(ImageNet)을 이용하였고 사전 학습된 컨볼루션층은 그대로 둔 상태에서 완전결합층 부분을 재구성하였다.

모든 모델을 구축하는 실험에서, batch size는 Vgg16 모델을 이용(Epochs: 5회)한 실험에서 batch size를 16, 32, 64로 조정하여 실험하였을 때 가장 정확도가 높게 나왔던 32로 설정하였고, optimizer(LR)는 RMSprop(lr=1e-4), dropout은 0.5로 동일하게 설정하였다.

Dataset 1을 이용한 모델 학습에서는 epochs를 10, 30회로 설정하였으며, Vgg16, Vgg19, ResNet50을 알고리즘으로 사용하였다. Dataset 2를 이용한 모델 학습에서는 epochs를 100, 150,

200회로 설정하였으며, Dataset 1에서 사용한 알고리즘에 Inception-V3 알고리즘을 추가하였다. 마지막으로 Dataset 3을 이용한 모델 학습에서는 epochs를 100, 150로 설정하였으며, Dataset 2에서와 동일한 알고리즘을 사용하였다.

IV. 실험결과

본 연구에서는 VggNet(Vgg16,Vgg19), Resnet50, Inception-V3 알고리즘에 기반한 CNN 모델을 이용하여 HS 코드 이미지를 학습시켜 HS 코드를 분류하는 실험을 진행하였다. 앞서 설명하였듯이, 서로 다른 3가지의 Dataset을 구성하여 각 모델들의 분류 정확도를 비교하였다. 분류 정확도는 다음과 같이 계산하였다.

$$Accuracy = \frac{n}{N}$$

N : 전체 샘플의 수, n : 정확히 예측한 샘플의 수

1. Dataset 1 실험결과

수집된 이미지 데이터의 샘플 수가 가장 많은 HS 코드 5종을 대상으로 수행한 실험의 결과를 살펴보면, 분류 정확도가 가장 높게 나온 모델은 Vgg19 모델(Epochs: 10, Batch Size: 32, Optimizer(LR): RMSprop(lr=1e-4), Dropout: 0.5)로 45.6%의 분류 정확도를 보이는 것으로 나타났다. 이는 Vgg19가 다양한 필터를 사용하고, 다

른 알고리즘에 비해 보다 많은 수의 weight layer로 구성되어 있기 때문에, 유사성이 적은 이미지들이 섞여 있는 비선형성이 높을 것으로 예상되는 dataset 1에서 보다 좋은 결과를 보인 것으로 유추된다. <표 2>는 Dataset1로 실험한 각 모델의 HS 코드 이미지 분류 정확도를 보여 주고 <표 3>은 분류 정확도가 가장 높은 모델의 HS 코드 분류 예측값을 보여준다.

<표 2> Dataset 1의 모델별 실험결과

Epochs	Vgg16	Vgg19	ResNet50
10	42.21%	45.60%	30.52%
30	37.66%	45.45%	38.96%

<표 3> Vgg19 모델 예측결과 값

실제	예측				
	3926300000	3926909000	7326909000	8302300000	8708290000
3926300000 (가구/차체와 이와 유사한 것들의 부착구)	31	2	8	3	6
3926909000 (플라스틱으로 만든 그 밖의 제품-기타)	5	12	23	5	5
7326909000 (철강으로 만든 그 밖의 제품-기타)	6	4	36	1	3
8302300000 (모터차량용에 적합한 그 밖의 장착구/부착구와 이와 유사한 물품)	13	3	12	18	4
8708290000 (차량용 부분품과 부속품-기타)	13	1	12	7	17

2. Dataset 2 실험결과

모델 사용의 현실성을 높이고자 HS 코드 2단위(류)별로 구성한 Dataset 2(87류로 구성)를 대상으로 수행한 실험의 결과를 살펴보면, 분류 정확도가 가장 높게 나온 모델은 Inception-V3 모델(Epochs: 150)로 55.67%의 정확도를 보였다.

이는 Inception-V3가 구조적인 변화나 다양한 모양의 필터를 사용한 기능들을 조합하여 만든 모델로서, 차원을 줄이면서 발생하는 정보 손실을 막기 위해 같은 입력값에 대해 다양한 연산을 수행하기 때문에 데이터 샘플의 수가 적은 클래스가 포함된 dataset 2에서 다른 알고리즘 대비 보다 나은 정확도를 보인 것으로 유추된다.

정확도가 가장 낮은 모델은 ResNet50으로 38.75%의 분류 정확도를 보였다. <표 4>는 Dataset 2을 대상으로 실험한 각 모델의 HS 코

드 이미지 분류 정확도를 보여주고 <표 5>는 분류 정확도가 가장 높은 모델의 HS 코드 분류 예측값을 보여준다.

<표 4> Dataset 2의 모델별 실험결과

Epochs	Vgg16	Vgg19	ResNet50	Inception-V3
100	44.38%	47.50%	30.52%	51.88%
150	51.25%	41.25%	38.75%	55.67%
200	50.62%	42.45%	38.12%	55.00%

<표 5> Inception-V3 모델 예측결과 값

실제	예측				
	8708290000	8708309000	8708400000	8708999000	8799999999
8708290000 (차량용 부분품과 부속품-기타)	289	6	5	41	43
8708309000 (차량용 부분품과 부속품-기타)	7	6	4	6	16
8708400000 (기어박스와 그 부분품)	12	5	41	8	19
8708999000 (차량용 부분품과 부속품-기타)	42	5	15	23	33
8799999999 (기타)	34	3	26	14	73

3. Dataset 3 실험결과

Dataset 2와 같이 HS 코드 87류를 대상으로 하고 있으나, 데이터의 구성 방법을 달리하여 모든 HS 코드의 데이터 개수를 동일하게 맞추어 Dataset 3를 대상으로 수행한 실험의 결과를 살펴보면, 분류 정확도가 가장 높게 나온 모델은 Vgg16 모델로 73.12%의 분류 정확도를 보였다. 이는 dataset 3의 경우, 동일한 HS 코드 2단위 (류) 내의 데이터들로 서로 비슷한 성격의 이미지 데이터들로 구성이 되며, 각 코드별 이미지의 수가 동일하여 균형 잡힌 학습이 가능하기에 상대적으로 weight layer의 수가 적은 Vgg16이 다

른 알고리즘에 대비 네트워크의 학습이 충분히 이루어져 상대적으로 좋은 정확도를 보인 것으로 유추된다. 또한 전반적으로 모든 모델에서 분류 정확도가 많이 향상된 것을 확인할 수 있었다. 이와 같이 분류 정확도가 높게 올라간 이유는 학습 데이터 구성 시 해당 HS 코드와 상관없는 이미지를 제외하고 HS 코드별 데이터 분포를 균등하게 맞추는 것이 영향을 준 것으로 판단된다. <표 6>은 Dataset 3으로 실험한 각 모델의 HS 코드 이미지 분류 정확도를 보여주고, <표 7>은 분류 정확도가 가장 높은 모델의 HS 코드 분류 예측값을 보여준다.

<표 6> Dataset 3의 모델별 실험결과

Epochs	Vgg16	Vgg19	ResNet50	Inception-V3
100	68.12%	65.00%	71.88%	41.25%
150	73.12%	71.25%	64.38%	45.00%

<표 7> Vgg16 모델 예측결과 값


실제	예측				
	8708290000	8708309000	8708400000	8708999000	8799999999
8708290000 (차량용 부분품과 부속품-기타)	219	5	1	10	15
8708309000 (차량용 부분품과 부속품-기타)	15	194	7	8	26
8708400000 (기어박스과 그 부분품)	4	6	192	10	38
8708999000 (차량용 부분품과 부속품-기타)	46	8	30	142	24
8799999999 (기타)	42	11	17	13	167

<그림 1>은 분류 정확도가 가장 높았던 Vgg16 모델의 정확도(Accuracy)와 손실값(Loss)을 나타낸 그래프로서, epochs가 증가할수록 정확도는 증가하고 손실값은 낮아지고 있음을 알 수 있다. 손실값은 다음과 같이 계산하였다.

$$D(S, L) = - \sum_{i=1}^n L_i \log(S_i)$$

$$Loss = \frac{1}{m} \sum_{j=1}^m D(S_j, L_j)$$

L_i : 실제값, S_i : 예측값, n : 클래스 수, m : 샘플 수



<그림 1> Vgg16 모델의 정확도 및 손실값 결과

V. 결 론

본 연구에서는 무역업자들이 수출입 신고 시 어려움을 겪고 있는 수출입 품목에 대한 HS 코드 작성에 도움을 줄 수 있도록 HS 코드 이미지를 활용하여 HS 코드를 자동으로 분류하는 모델을 제안하였다. 이를 위해, 이미지 분류에 탁월한 성능을 보여 온 Vgg16, Vgg19, ResNet50, Inception-V3 알고리즘 기반의 CNN 모델을 다양한 dataset에 적용하여 HS 코드 이미지에 대한 분류를 수행하였고 그 결과를 확인하였다. 본 연구의 실험에서 분류 정확도가 가장 높게 나온 경우는 Dataset 3을 대상으로 Vgg16 모델 (Epochs 150, Batch Size 32, Optimizer RMSprop(lr=1e-4), Dropout 0.5)을 적용한 경우로, 73.12%의 정확도를 보였다. 이는 Dataset 2의 실험에서 분류 정확도가 가장 높았던 55.67%보다 무려 17.5%p 향상된 수치이다. 이러한 실험 결과를 보면 모델 학습을 위한 dataset 구성이 CNN 모델 학습에 많은 영향을 미친다는 것을 알 수 있다.

본 연구의 시사점은 다음과 같다. 첫째, 기존의 관세분야의 HS 코드 관련 연구들은 주로 품목분류의 분쟁사례와 이슈사항들을 정책적, 제도적, 절차적 측면에서 접근하여 개선방안을 제안하였는데, 본 연구에서는 딥러닝에 기반한 HS 코드 추천 모델을 최초로 제안하여 기존 관세분야 HS 코드 관련 연구의 범위를 넓혔다는 점에서 의의가 있다. 둘째, 관세분야에서 HS 코드 이미지만을 이용하여 딥러닝 기반의 HS 코드 분류를 시도함으로써, 그 적용 가능성을 살펴보고, 관련된 이슈들을 도출하였다는 점에서 학술적인 시사점이 있다. 셋째, 본 연구는 CNN 기반의 여러 알고리즘별 딥러닝 분류 모델을 구축하고 각 모델들의 분류 성능을 비교 평가하였다는 점, 그

리고 좌우 반전, 상하 반전, 회전 등을 통한 데이터 생성을 통해 학습 데이터의 균형을 수행하였다는 점에서 학술적 시사점을 지닌다. 넷째, 본 연구에서 제안한 모델은 수출입 업무를 하고 있는 기업이나 개인사업자들이 수출입 신고 시 HS 코드를 분류하고 HS 코드를 작성하는데 있어 많은 도움을 줄 뿐 아니라, 관세사의 업무량도 감소시켜줄 수 있다는 점에서 실무적인 시사점이 있다.

본 연구는 HS 코드별로 수집된 데이터의 양이 많지 않았고, 실험 dataset 구성 시 이미지 간 데이터 수의 균형이 맞지 않았던 데이터 관점에서의 한계점이 있었다. 하지만, 이러한 한계점을 최소화 시키기 위해 data augmentation 기법을 사용하여 데이터를 변환하여 추가 생성함으로써 학습 데이터의 양을 증가시키면서도 과잉적합(Over-fitting)을 방지하려고 노력 하였다. 하지만 딥러닝 학습에 영향을 미치는 모든 파라미터에 대해 실험장비 및 시간적인 제약으로 인해 보다 다양한 실험을 진행하지 못한 점은 본 연구의 한계점이라 할 수 있다. 하지만 이러한 한계점은 시간이 지나면서 수집 가능한 데이터의 양이 증가하면 점차 해결될 수 있을 것으로 기대된다. 향후 연구에서는 HS 코드 이미지 분류 성능 향상시키기 위해 보다 더 많은 이미지를 확보하고 보다 다양한 파라미터의 조정을 통해 최적의 신경망 네트워크 모델을 찾아가자 한다. 아울러 Word2Vec과 같은 단어 임베딩 모델을 이용해 HS 코드 이미지뿐만 아니라, 수출입 품목에 대한 설명과 HS 코드 결정사례에 대한 내용을 같이 통합하여 HS 코드 분류를 시도한다면 이미지만을 이용했을 때보다 더 높은 분류 성능이 나올 수 있을 것으로 생각된다.

참고문헌

- 정민국 · 송우진 · 이현근 · 유정호(2017), “농축산물 품목분류 및 HS코드 도감,” *한국농어촌연구원 연구자료*, 1-104.
- 강홍중(2010), “품목분류 오류신고에 관한 연구,” *관세학회지*, 1-28.
- 관세법인화우, 수입물품의 관세품목분류 http://customs.hwawoo.com/kor/06_Resource/01_01_hwawoo_view02.do (02 June, 2016).
- 대구본부세관, 품목분류와 관세율 http://customs.go.kr/kcshome/main/content/ContentView.do?contentId=CONTENT_ID_000000595&layoutMenuNo=12071.
- 박상봉(2016), “조세심판청구제도의 문제점에 관한 개선방안,” *경영과 정보연구*, 35(2), 67-81.
- 백승훈 · 이승후 · 홍성찬 · 홍준기(2020), “CNN/ANNOY 기술을 이용한 의류 이미지 유사도 분석,” *정보기술아키텍처연구*, 17(2), 157-165.
- 성원식 · 심재원 · 김은경(2018), “관세율표상의 부분품과 부속품의 정의 및 분류기준 연구,” 관세평가분류원.
- 수출입무역통계, 수출입총괄 <https://unipass.customs.go.kr/ets/index.do>(10 October, 2019).
- 육수진(2017), “국가간 품목분류 분쟁은 어떻게 해결할까? -품목분류 국제분쟁의 해결방법과 절차,” *국제원산지정보원, FTA Trade Report*, 144-157
- 윤인철(2013), “수출입물품 품목분류 개선방안 연구,” 한국해양대학교 대학원 석사학위논문.
- 윤재웅 · 이석준 · 송철용 · 김연식 · 정미영 · 정상일(2019), “합성곱 신경망을 활용한 지능형 유사상표 검색 모형 개발,” *경영과 정보연구*, 38(3), 55-80.
- 윤재웅 · 전재현 · 방철환 · 박영민 · 김영주 · 오성민 · 정준호 · 이석준 · 이지현(2017), “합성곱 신경망을 활용한 지능형 아토피피부염 중증도 진단 모델 개발,” *경영과 정보연구*, 36(4), 33-51.
- 장현웅 · 조수선(2016), “CNN을 이용한 소셜 이미지 자동 태깅,” *정보과학회논문지*, 43(1), 47-53.
- LeCun, Y., Bengio, Y. and Hinton, G.(2015), “Deep learning,” *Nature*, 521, 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P.(1998), “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, 86(11), 2278-2324.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R.(2014), “Dropout: A simple way to prevent neural networks from overfitting,” *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- He, K., Zhang, X., Ren, S., and Sun, J. (2015), “Deep Residual Learning for Image Recognition,” *Computer Vision and Pattern Recognition*.
- Rezende, E., Ruppert, G., Carvalho, T., Ramos, F., and Paulo de Geus(2017), “Malicious Software Classification Using Transfer Learning of ResNet50 Deep Neural Network,” *16th IEEE International Conference on Machine Learning and Applications*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z.(2016), “Rethinking the inception architecture for computer vision,” *The IEEE Conference on Computer Vision and Pattern Recognition*, 2818-2826.

Abstract

CNN-based Recommendation Model for Classifying HS Code

Lee, Dongju* · Kim, Gunwoo** · Choi, Keunho***

The current tariff return system requires tax officials to calculate tax amount by themselves and pay the tax amount on their own responsibility. In other words, in principle, the duty and responsibility of reporting payment system are imposed only on the taxee who is required to calculate and pay the tax accurately. In case the tax payment system fails to fulfill the duty and responsibility, the additional tax is imposed on the taxee by collecting the tax shortfall and imposing the tax deduction on For this reason, item classifications, together with tariff assessments, are the most difficult and could pose a significant risk to entities if they are misclassified. For this reason, import reports are consigned to customs officials, who are customs experts, while paying a substantial fee. The purpose of this study is to classify HS items to be reported upon import declaration and to indicate HS codes to be recorded on import declaration. HS items were classified using the attached image in the case of item classification based on the case of the classification of items by the Korea Customs Service for classification of HS items. For image classification, CNN was used as a deep learning algorithm commonly used for image recognition and Vgg16, Vgg19, ResNet50 and Inception-V3 models were used among CNN models. To improve classification accuracy, two datasets were created. Dataset1 selected five types with the most HS code images, and Dataset2 was tested by dividing them into five types with 87 Chapter, the most among HS code 2 units. The classification accuracy was highest when HS item classification was performed by learning with dual database2, the corresponding model was Inception-V3, and the ResNet50 had the lowest classification accuracy. The study identified the possibility of HS item classification based on the first item image registered in the item classification determination case, and the second point of this study is that HS item classification, which has not been attempted before, was attempted through the CNN model.

Key Words: Classification, Recommendation, HS code, Deep learning, CNN

* Senior Manager, Dataworld Co. Ltd., djlee@dataworld.co.kr

** Associate Professor, Dept. of Business Administration, Hanbat National University, gkim@hanbat.ac.kr

*** Assistant Professor, Dept. of Business Administration, Hanbat National University, keunho@hanbat.ac.kr