



## **ArtMovement Identifier**

Camilo Salomón Torres

Monografía presentada para optar al título de Especialista en Analítica y Ciencia de Datos

Tutor

Raúl Ramos Pollán, PostDoctor (PostDoc)

Universidad de Antioquia

Facultad de Ingeniería

Especialización en Analítica y Ciencia de Datos

Medellín, Antioquia, Colombia

2022

---

<b>Cita</b>	(Salomon Torres, 2022)
<b>Referencia</b>	Salomon Torres, C. (2020). <i>ArtMovement Identifier</i> [Trabajo de grado especialización]. Universidad de Antioquia, Medellín, Colombia.
<b>Estilo APA 7 (2020)</b>	

---



Especialización en Analítica y Ciencia de Datos, Cohorte III.



Centro de Documentación Ingeniería (CENDOI)

**Repositorio Institucional:** <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - [www.udea.edu.co](http://www.udea.edu.co)

**Rector:** John Jairo Arboleda Céspedes.

**Decano/Director:** Jesús Francisco Vargas Bonilla.

**Jefe departamento:** Diego José Luis Botia Valderrama.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.



**UNIVERSIDAD  
DE ANTIOQUIA**

# **Identifying Paintings Art Movement: A Convolutional Approach**

Camilo Salomón Torres

Universidad de Antioquia

Facultad de Ingeniería

Medellín, Colombia

2022

# TABLA DE CONTENIDOS

<b>1. RESUMEN EJECUTIVO</b>	<b>4</b>
<b>2. DESCRIPCIÓN DEL PROBLEMA</b>	<b>5</b>
2.1 PROBLEMA DE NEGOCIO	5
2.2 APROXIMACIÓN DESDE LA ANALÍTICA DE DATOS	5
2.3 ORIGEN DE LOS DATOS	5
2.4 MÉTRICAS DE DESEMPEÑO	5
<b>3. DATOS</b>	<b>6</b>
3.1 DATOS ORIGINALES	6
3.2 DATASETS	6
3.3 DESCRIPTIVA	6
<b>4. PROCESO DE ANALÍTICA</b>	<b>7</b>
4.1 PIPELINE PRINCIPAL	7
4.2 PREPROCESAMIENTO	7
4.3 MODELOS	7
4.4 MÉTRICAS	7
<b>5. METODOLOGÍA</b>	<b>8</b>
5.1 BASELINE	8
5.2 VALIDACIÓN	8
5.3 ITERACIONES y EVOLUCIÓN	8
5.4 HERRAMIENTAS	8
<b>6. RESULTADOS</b>	<b>9</b>
6.1 MÉTRICAS	9
6.2 EVALUACIÓN CUALITATIVA	9
6.3 CONSIDERACIONES DE PRODUCCIÓN	9

# 1. RESUMEN EJECUTIVO

En este trabajo investigamos cómo identificar de forma automática los movimientos artísticos de pinturas dadas. Utilizando un dataset de obras de arte enfocado en autores de las pinturas, asignamos el movimiento artístico de las pinturas. Creamos modelos desde 0, obteniendo algunos resultados no tan animadores, así que optamos por hacer transfer learning con modelos pre-entrenados altamente utilizados en el estado del arte como VGG y RestNet; esta estrategia mejoró considerablemente los resultados de clasificación del modelo.

Repositorio de GitHub:

[https://github.com/CamiloSalomonT/art\\_movement\\_identifier/](https://github.com/CamiloSalomonT/art_movement_identifier/)

## 2. DESCRIPCIÓN DEL PROBLEMA

En el arte, existen diferentes conceptos que permiten crear segregaciones de las obras con base en diferentes características de estas(Papi L, 2018); El movimiento artístico, uno de estos conceptos, permite separar las obras estableciendo y diferenciando estilos y filosofías de las mismas(Isrow et al., 2017). Por lo general, es correcto asociar a un pintor con los lineamientos de cierto movimiento artístico, y adicionalmente, este suele estar correlacionado con el contexto histórico y geográfico del pintor.

### 2.1 PROBLEMA DE NEGOCIO

La identificación de este movimiento artístico, suele estar asociada a una tarea interpretativa que involucra tanto información de las técnicas, trazos y la comunicación visual de la obra; como de la semiótica, las metáforas visuales y los elementos contextuales que tienen las obras contienen. Con esta base, es claro que asignar un movimiento artístico a una pintura arbitraria dada, pareciera no ser una labor trivial, por lo que en este documento exploramos una alternativa end-to-end para realizar esta tarea y evaluaremos su desempeño(Masilamani et al., 2021).

Algunos estudios se han adelantado, con perspectivas diferentes, buscando identificar si es viable realizar segmentaciones en el estilo de arte, y si existe una correlación entre las segregaciones generadas y las perspectivas humanas ampliamente propagadas (Gultepe et al., 2018).

### 2.2 APROXIMACIÓN DESDE LA ANALÍTICA DE DATOS

La clasificación de movimientos artísticos puede tener muchos usos en el mundo productivo, si bien el objetivo de este trabajo es exploratorio, pueden realizarse a futuro:

- Categorizaciones al vuelo de pinturas nuevas en un marketplace o galería según su contenido
- Recomendación de pinturas a clientes según las preferencias de estilos artísticos

Por lo pronto, los modelos serán creados para hacer categorizaciones de una imagen dada, según su estilo artístico.

## 2.3 ORIGEN DE LOS DATOS

Los datos que serán utilizados, provienen del dataset de Kaggle *Best artworks of all time*. Este dataset consta de una base de datos de información de autores de pinturas y un conjunto de pinturas realizadas por cada uno de los artistas de la base de datos.

## 2.4 MÉTRICAS DE DESEMPEÑO

Se evaluará el **f1-score** del modelo y el **accuracy**, para comparar los modelos y técnicas de entrenamiento utilizados en el ejercicio desarrollado. Este es un modelo exploratorio, así que no habrán métricas objetivo a superar.

## 3. DATOS

### 3.1 DATOS ORIGINALES

Se cuenta con los datos de pintores provenientes del dataset [Best Artworks of All Time](#), proveniente de la plataforma Kaggle consta de 8446 imágenes de pinturas de 50 artistas diferentes. El peso total del dataset en Gb es de cerca de 2.4 Gb.

El dataset cuenta además con una base de datos, en formato CSV, que cuenta con la información descrita en la table 1 de cada uno de los artistas del dataset:

Column	Description
<i>id</i>	Número de identificación de cada artista
<i>name</i>	Nombre del artista
<i>years</i>	Años de nacimiento y muerte del artista
<i>genre</i>	Principal movimiento artístico del que el artista fue referente
<i>nationality</i>	Nacionalidad del artista
<i>bio</i>	Breve biografía del artista
<i>wikipedia</i>	Link de wikipedia del artista
<i># paintings</i>	Conteo de pinturas del artista en el dataset

Table 1 . Columnas del Dataset

Tal como se puede apreciar en la figure 1, la distribución del número de pinturas por autor es bastante diversa. El artista que cuenta con mayor número de pinturas es **Vincent Van Gogh** con **877** imágenes y el artista con el menor número es **Jackson Pollock** con **24** pinturas. Esto muestra que para esta categorización “artista” está fuertemente desbalanceado el dataset.






Figura 1. Número de pinturas por artista

## 3.2 DATASETS


Puesto que nuestro interés está en los datos de movimientos artísticos, y estos son los que se encuentran en la columna de **genre**, requerimos hacer el estudio de esta columna para poder solucionar nuestro objeto de estudio.

La columna **genre** cuenta con los principales movimientos artísticos que identificaron al artista durante su vida productiva, en caso de ser más de 1 el carácter de coma(,) separa los múltiples valores. La columna presenta **31** datos únicos que se distribuyen así

- **20** pertenecen a un único movimiento
- **10** pertenecen a dos movimientos
- **1** pertenece a tres movimientos

Para inferir el movimiento artístico de las pinturas, vamos a asumir que todas las pinturas con las que contamos de cada artista, pertenecen al movimiento que está referenciado en la columna **genre**, esto con el fin de utilizar la técnica de encoding *One-Hot Encoding*.

Tras esta transformación tenemos el conteo de los artistas por movimiento del cuál son referentes está representado por figura b.



figura


Se tomó la decisión de utilizar únicamente el primer elemento enlistado en la columna **genre**, para determinar el movimiento artístico de las pinturas en los casos en que se referenciaba a más de un movimiento.

Adicionalmente, tras realizar esta transformación en el objetivo, también se procedió a redistribuir las colecciones de imágenes con base en los movimientos.

### 3.3 DESCRIPTIVA

Finalmente, tras la modificación de los datasets, tenemos que una gran mayoría de


El resultado del conteo de imágenes por movimiento artístico se presenta a continuación:







Teniendo así un dataset fuertemente desbalanceado, característica que será tomada en cuenta para el desarrollo de este trabajo.

A continuación se presentarán algunos ejemplos de las imágenes etiquetadas con la estrategia de inferencia de movimiento artístico, descrita previamente:

High Renaissance



Surrealism



## 4. PROCESO DE ANALÍTICA

### 4.1 PIPELINE PRINCIPAL

Describe con un gráfico el flujo de trabajo general de los datos en tu proyecto. Añade o modifica secciones si lo consideras necesario

### 4.2 PREPROCESAMIENTO

Dadas las pocas muestras con las que se contaba para algunos de los movimientos artísticos, se procedió a realizar aumentación de datos, generando versiones de las imágenes en las que se contemplaban los siguientes casos:

- Reflejar horizontalmente
- Pequeñas rotaciones
- Zoom y crop

Buscando con esto generar datos aumentados fidedignos del dataset original que mejoren la identificación de trazos y evitar el sobreentrenamiento.

Dado el problema que se quería resolver, en el que la información contextual histórica es muy importante; se asumió que sería conveniente tener como input la imagen con todos sus canales, esperando que el modelo pueda encontrar información relevante basada en los colores (para inferir algunos pigmentos) que las pinturas usaban.

### 4.3 MODELOS

Se utilizaron 3 modelos base para hacer la clasificación. Todos estos modelos recibían como entrada la imagen reescalada a 224 x 224 píxeles, manteniendo los 3 canales de color.

#### 4.3.1. Starter CNN

El primer modelo propuesto es una red convolucional que conecta los siguientes patrones de capas de forma secuencial

**4x[Convolutacional + MaxPooling + Dropout] + Flatten + 3x[Dense]**

Esta es una arquitectura simple, que busca evidenciar en forma rápida la complejidad del problema a resolver.

### 4.3.2. VGG19

Se realizó la técnica de “*transfer learning*”(Lu et al., 2015) con la red preentrenada que seguía la arquitectura VGG19 (Simonyan et al.,2015) junto a los pesos de las capas provenientes de un entrenamiento realizado sobre el dataset imagenet, que consta de 19 capas secuenciales, a la que se adicionaron capas en pro de solucionar el problema objetivo. La arquitectura propuesta de forma secuencial es:

**2x[Convolutacional + MaxPooling]  
+ 3x[Convolutacional + Convolutacional + MaxPooling]  
+ Flatten + 4x[Dense] + Dropout + Dense**

Adicionalmente, se utilizó la técnica fine tuning para reentrenar algunas capas del modelo de la arquitectura VGG19. Los modelos entrenados fueron:

- VGG (sin re-entrenamiento)
- VGG (re-entrenadas las últimas 5 capas)
- VGG (re-entrenadas las últimas 10 capas)
- VGG (re-entrenadas las últimas 15 capas)
- VGG (completamente re-entrenado)

### 4.3.3. ResNet152 v2

Al igual que con la arquitectura VGG19, se realizó la técnica de *transfer learning* para la arquitectura ResNet152(He et al., 2015), entrenada sobre el dataset imagenet. La arquitectura ResNet152 consta de 152 capas, que en este caso no se conectan en forma secuencial, por el contrario va llevando un componente “residual” para cada bloque de la arquitectura. Se puede apreciar un ejemplo de dicho residuo en el segmento extraído de esta red. Adicionalmente, con el fin de crear la salida para el problema a resolver, se agregó la siguiente secuencia de capas:

**Dense + Dropout + Dense + Dropout + Dense**

Finalmente, se utilizó la técnica fine tuning para reentrenar algunas capas del modelo de esta arquitectura, produciendo modelos para las siguientes estrategias de entrenamiento:

- ResNet152 (sin re-entrenamiento)
- ResNet152 (re-entrenadas las últimas 114 capas)

- ResNet152 (re-entrenadas las últimas 30 capas)
- ResNet152 (completamente re-entrenado)

Es importante aclarar, que las 152 capas que describe el nombre, refieren capas de convolución, pero adicionalmente el modelo cuenta con capas intermedias que suben el conteo total de capas a 564.

## 4.4 MÉTRICAS

Para calcular el desempeño del modelo, se optará por utilizar la métrica de f1-score, que es una métrica que balancea los aciertos y los desaciertos del modelo. Adicionalmente, para tener una mejor observabilidad de las predicciones del modelo se utilizará la matriz de confusión y buscando entender las casuísticas de desaciertos en la clasificación se revisará el reporte de clasificación del modelo junto a los casos erróneamente clasificados.



# 5. METODOLOGÍA

## 5.1 BASELINE

La primera iteración

## 5.2 VALIDACIÓN

Dado el conjunto del dataset, se particionó de forma estratificada el dataset de la siguiente forma:

- 5615 imágenes para training
- 1755 imágenes para test
- 1404 imágenes para validación

Los datos de test, se utilizaron para evidenciar la presencia de sobreentrenamiento en nuestros procesos de entrenamiento, por medio de la visualización de la evolución del desempeño del modelo con los datos de validación y los de test.

## 5.3 ITERACIONES y EVOLUCIÓN

La **primera iteración** se realizó el análisis exploratorio, se evaluó según el estado del arte algunos modelos que presentaran buenos comportamientos, teniendo en cuenta la generación de características, redes convolucionales, ... Se redistribuyen las imágenes según el problema de estudio. Adicionalmente, se montó el primer modelo, en el que se planteó una arquitectura simple y entrenada por completo con inicialización aleatoria. En la **segunda iteración** se agregó un modelo un poco más complejo, la arquitectura VGG, y se utilizó transfer learning para evaluar este modelo sin modificar sus pesos. Para la **tercera iteración** se realizaron los caso de fine tuning del modelo con arquitectura VGG. Para la **cuarta y quinta iteración**, se agregó una nueva arquitectura más compleja ResNet152 y se realizó fine tuning respectivamente. En la **iteración 6** se generaron métricas y se organizó el código para su presentación.

## 5.4 HERRAMIENTAS

Plataformas: Kaggle, Google Drive, Google Colaboratory

Lenguaje: Python

Librerías: Tensorflow, Scikit Learn, Seaborn, Matplotlib,

# 6. RESULTADOS


Describiremos en esta sección los resultados obtenidos en la ejecución

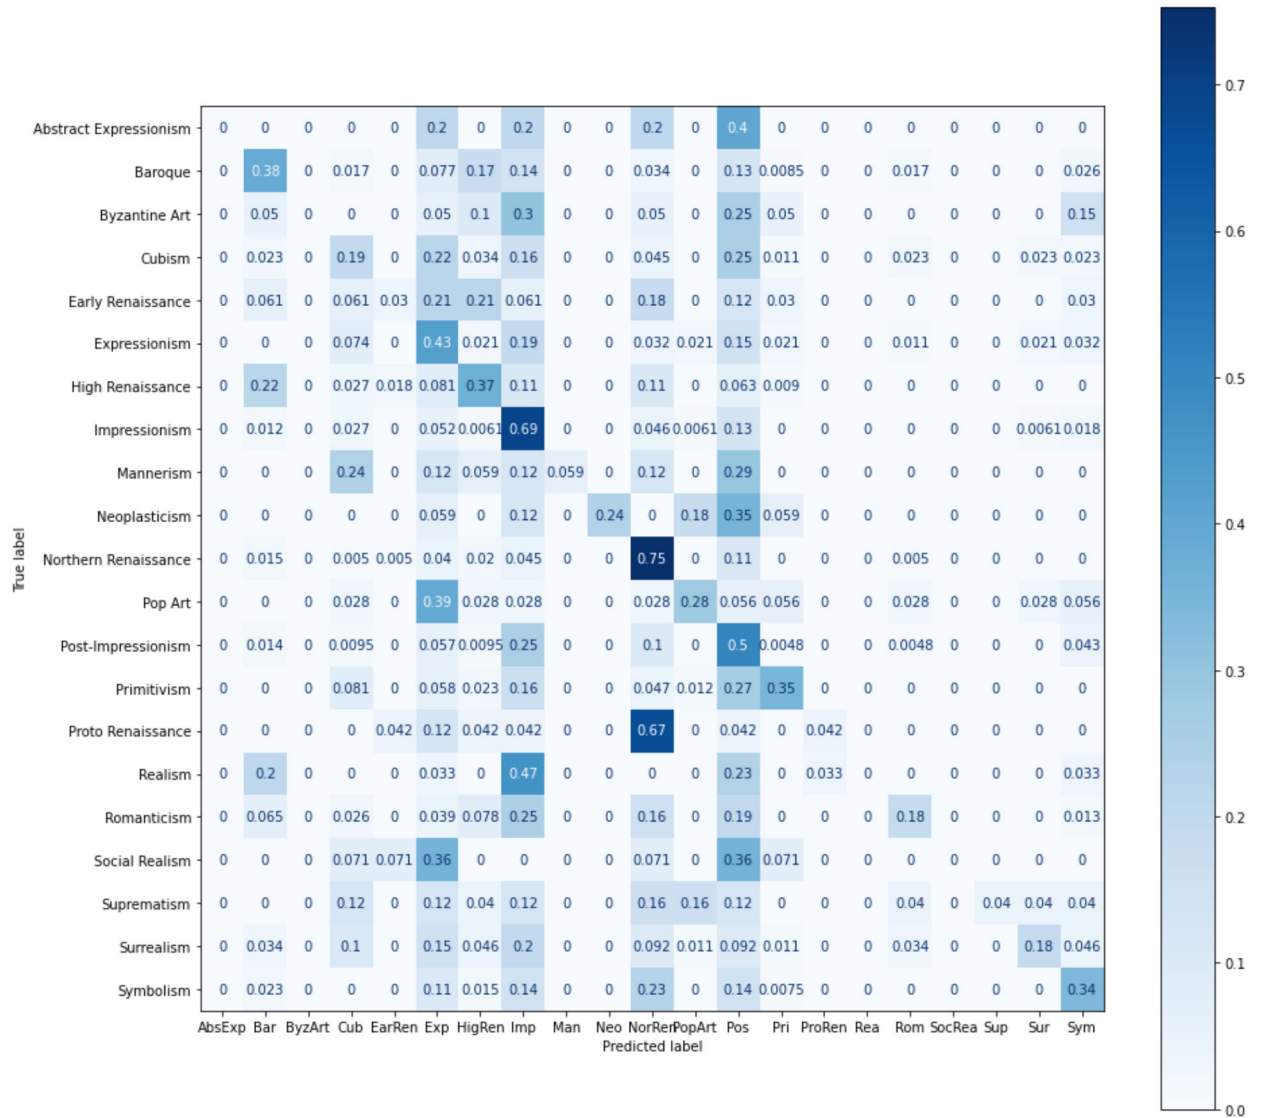
## 6.1 MÉTRICAS

Para cada uno de los modelos descritos previamente se generaron los siguientes gráficos:

1. Evolución del performance del modelo (medido por el accuracy) a través de los epochs, para el conjunto de datos de test y validación.
2. La matriz de confusión de la clasificación para identificar anomalías y casos relevantes durante el análisis de resultados.
3. El reporte de performance (precision, recall, f1-score) para cada clase y para el modelo en general.

### 6.1.1. Starter CNN



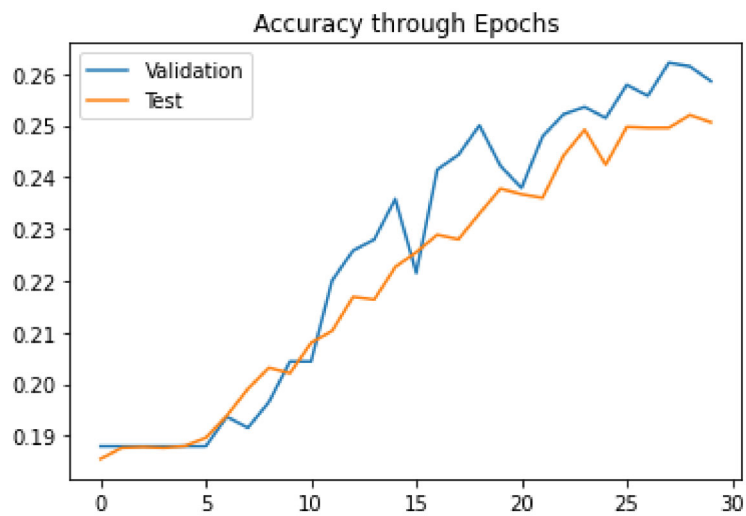


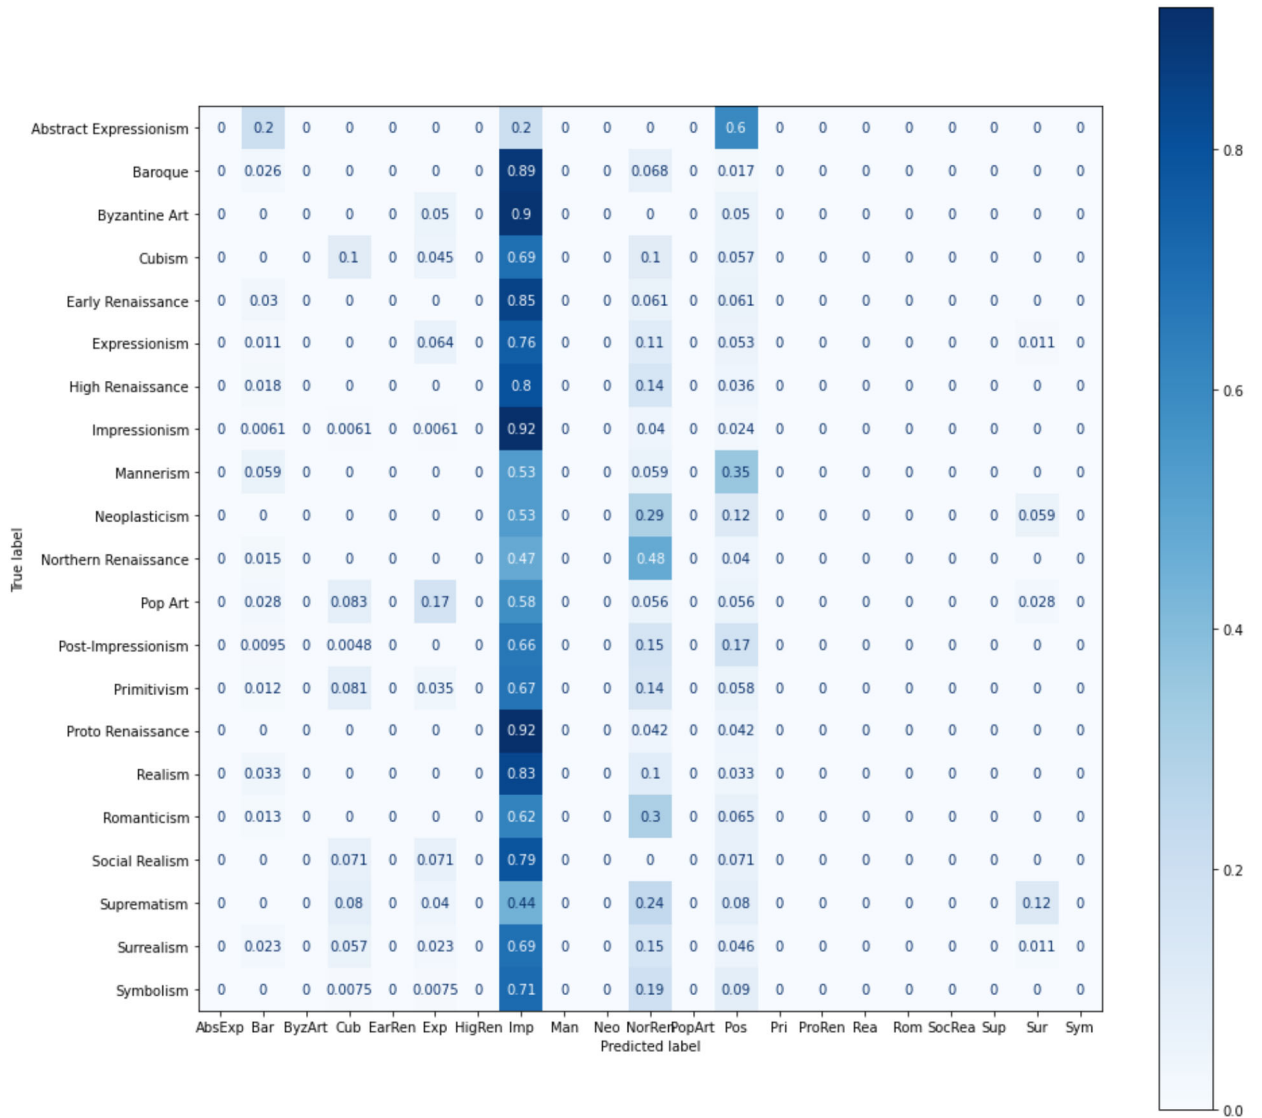
	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.45	0.38	0.41	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.24	0.19	0.22	88
Early Renaissance	0.17	0.03	0.05	33
Expressionism	0.21	0.43	0.28	94
High Renaissance	0.41	0.37	0.39	111
Impressionism	0.51	0.69	0.58	329
Mannerism	1.00	0.06	0.11	17

Neoplasticism	1.00	0.24	0.38	17
Northern Renaissance	0.51	0.75	0.61	202
Pop Art	0.43	0.28	0.34	36
Post-Impressionism	0.32	0.50	0.39	210
Primitivism	0.68	0.35	0.46	86
Proto Renaissance	0.50	0.04	0.08	24
Realism	0.00	0.00	0.00	30
Romanticism	0.54	0.18	0.27	77
Social Realism	0.00	0.00	0.00	14
Suprematism	1.00	0.04	0.08	25
Surrealism	0.67	0.18	0.29	87
Symbolism	0.56	0.34	0.42	133
<b>accuracy</b>			<b>0.43</b>	1755
macro avg	0.44	0.24	0.26	1755
weighted avg	0.46	0.43	0.40	1755

## 6.1.2. VGG19

- VGG (sin re-entrenamiento)

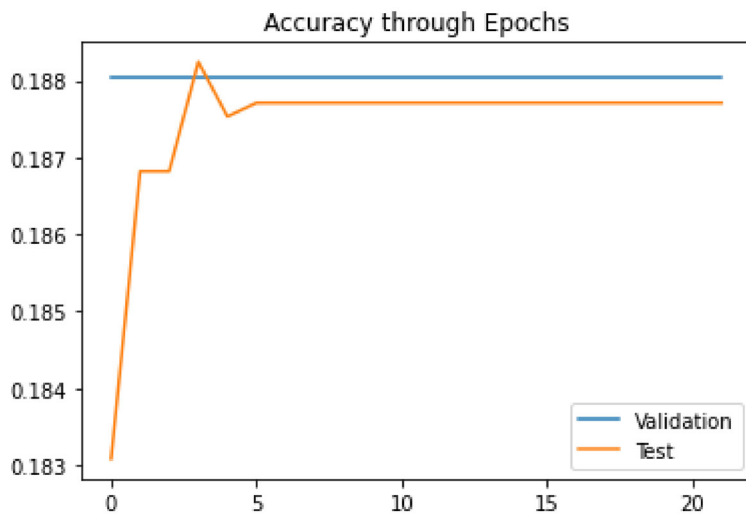





	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.14	0.03	0.04	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.29	0.10	0.15	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.22	0.06	0.10	94
High Renaissance	0.00	0.00	0.00	111
Impressionism	0.24	0.92	0.38	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	0.00	0.00	0.00	17
Northern Renaissance	0.35	0.48	0.40	202
Pop Art	0.00	0.00	0.00	36

Post-Impressionism	0.31	0.17	0.22	210
Primitivism	0.00	0.00	0.00	86
Proto Renaissance	0.00	0.00	0.00	24
Realism	0.00	0.00	0.00	30
Romanticism	0.00	0.00	0.00	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.00	0.00	0.00	25
Surrealism	0.14	0.01	0.02	87
Symbolism	0.00	0.00	0.00	133
<b>accuracy</b>			<b>0.26</b>	1755
macro avg	0.08	0.08	0.06	1755
weighted avg	0.16	0.26	0.16	1755

- VGG (re-entrenadas las últimas 5 capas)

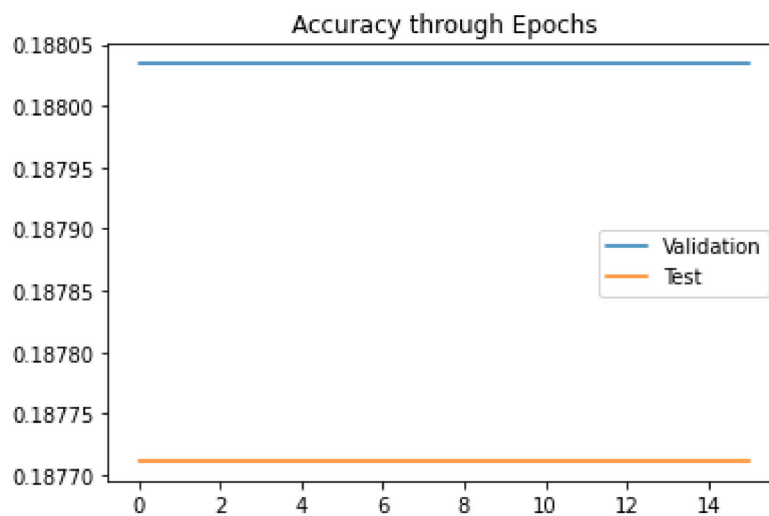





	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.00	0.00	0.00	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.00	0.00	0.00	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.00	0.00	0.00	94
High Renaissance	0.00	0.00	0.00	111
Impressionism	0.19	1.00	0.32	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	0.00	0.00	0.00	17
Northern Renaissance	0.00	0.00	0.00	202
Pop Art	0.00	0.00	0.00	36

Post-Impressionism	0.00	0.00	0.00	210
Primitivism	0.00	0.00	0.00	86
Proto Renaissance	0.00	0.00	0.00	24
Realism	0.00	0.00	0.00	30
Romanticism	0.00	0.00	0.00	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.00	0.00	0.00	25
Surrealism	0.00	0.00	0.00	87
Symbolism	0.00	0.00	0.00	133
<b>accuracy</b>			<b>0.19</b>	1755
macro avg	0.01	0.05	0.02	1755
weighted avg	0.04	0.19	0.06	1755

- VGG (re-entrenadas las últimas 10 capas)









	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.00	0.00	0.00	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.00	0.00	0.00	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.00	0.00	0.00	94
High Renaissance	0.00	0.00	0.00	111
Impressionism	0.19	1.00	0.32	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	0.00	0.00	0.00	17
Northern Renaissance	0.00	0.00	0.00	202
Pop Art	0.00	0.00	0.00	36

Post-Impressionism	0.00	0.00	0.00	210
Primitivism	0.00	0.00	0.00	86
Proto Renaissance	0.00	0.00	0.00	24
Realism	0.00	0.00	0.00	30
Romanticism	0.00	0.00	0.00	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.00	0.00	0.00	25
Surrealism	0.00	0.00	0.00	87
Symbolism	0.00	0.00	0.00	133
<b>accuracy</b>			<b>0.19</b>	1755
macro avg	0.01	0.05	0.02	1755
weighted avg	0.04	0.19	0.06	1755

- VGG (re-entrenadas las últimas 15 capas)







	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.00	0.00	0.00	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.00	0.00	0.00	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.00	0.00	0.00	94
High Renaissance	0.00	0.00	0.00	111
Impressionism	0.19	1.00	0.32	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	0.00	0.00	0.00	17
Northern Renaissance	0.00	0.00	0.00	202
Pop Art	0.00	0.00	0.00	36

Post-Impressionism	0.00	0.00	0.00	210
Primitivism	0.00	0.00	0.00	86
Proto Renaissance	0.00	0.00	0.00	24
Realism	0.00	0.00	0.00	30
Romanticism	0.00	0.00	0.00	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.00	0.00	0.00	25
Surrealism	0.00	0.00	0.00	87
Symbolism	0.00	0.00	0.00	133
accuracy			0.19	1755
macro avg	0.01	0.05	0.02	1755
weighted avg	0.04	0.19	0.06	1755

- VGG (completamente re-entrenado)






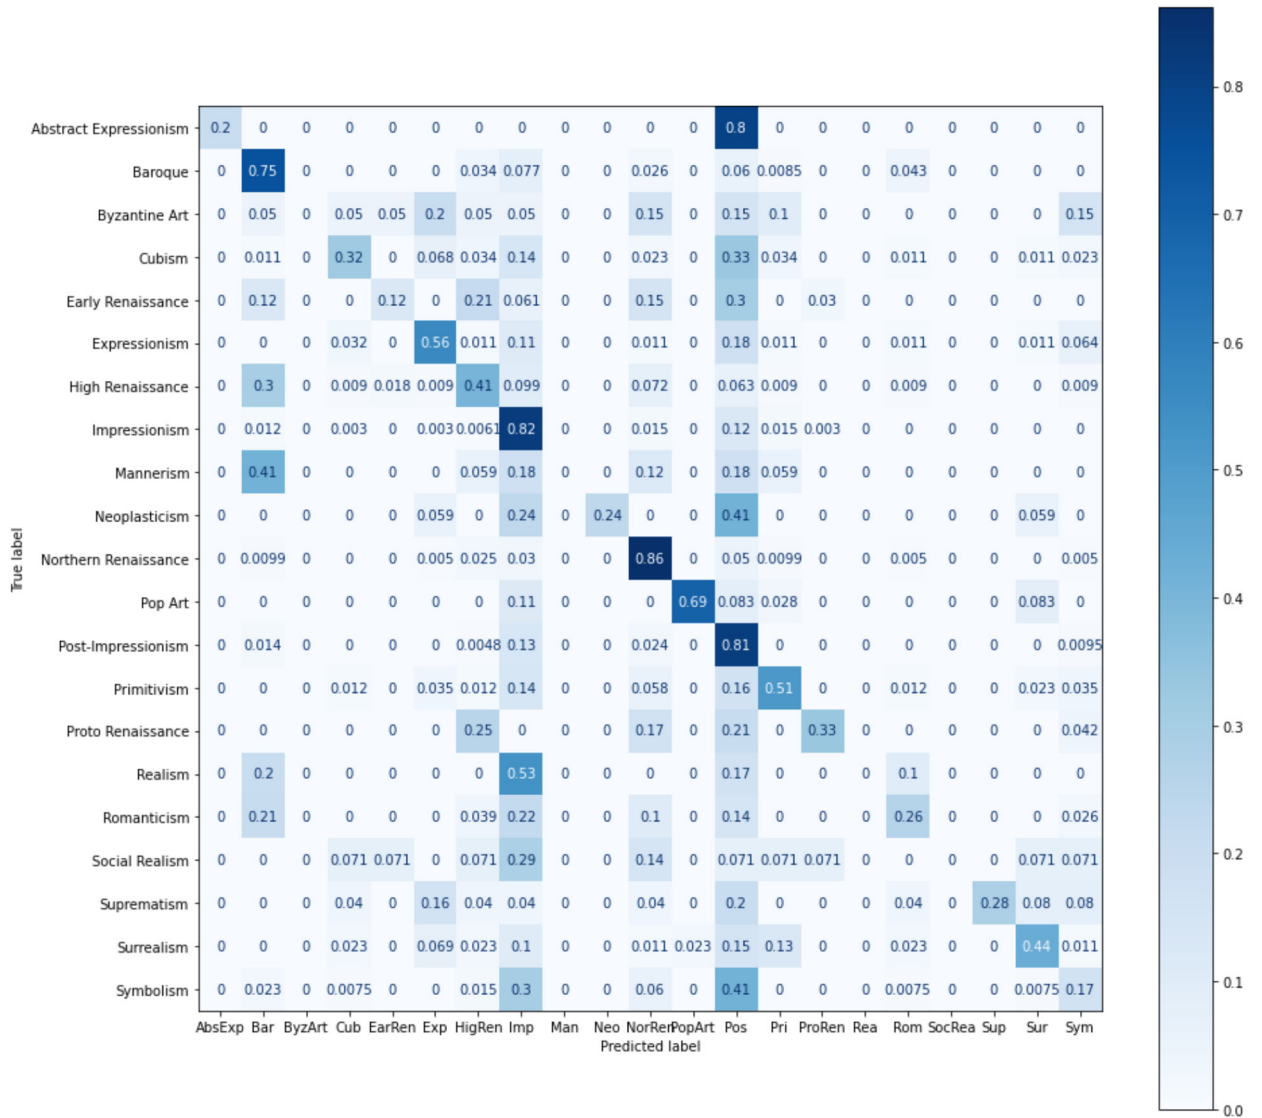
	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.00	0.00	0.00	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.00	0.00	0.00	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.00	0.00	0.00	94
High Renaissance	0.00	0.00	0.00	111
Impressionism	0.19	1.00	0.32	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	0.00	0.00	0.00	17
Northern Renaissance	0.00	0.00	0.00	202
Pop Art	0.00	0.00	0.00	36

Post-Impressionism	0.00	0.00	0.00	210
Primitivism	0.00	0.00	0.00	86
Proto Renaissance	0.00	0.00	0.00	24
Realism	0.00	0.00	0.00	30
Romanticism	0.00	0.00	0.00	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.00	0.00	0.00	25
Surrealism	0.00	0.00	0.00	87
Symbolism	0.00	0.00	0.00	133
accuracy			0.19	1755
macro avg	0.01	0.05	0.02	1755
weighted avg	0.04	0.19	0.06	1755

### 6.1.3. ResNet152 v2

- ResNet152 (sin re-entrenamiento)






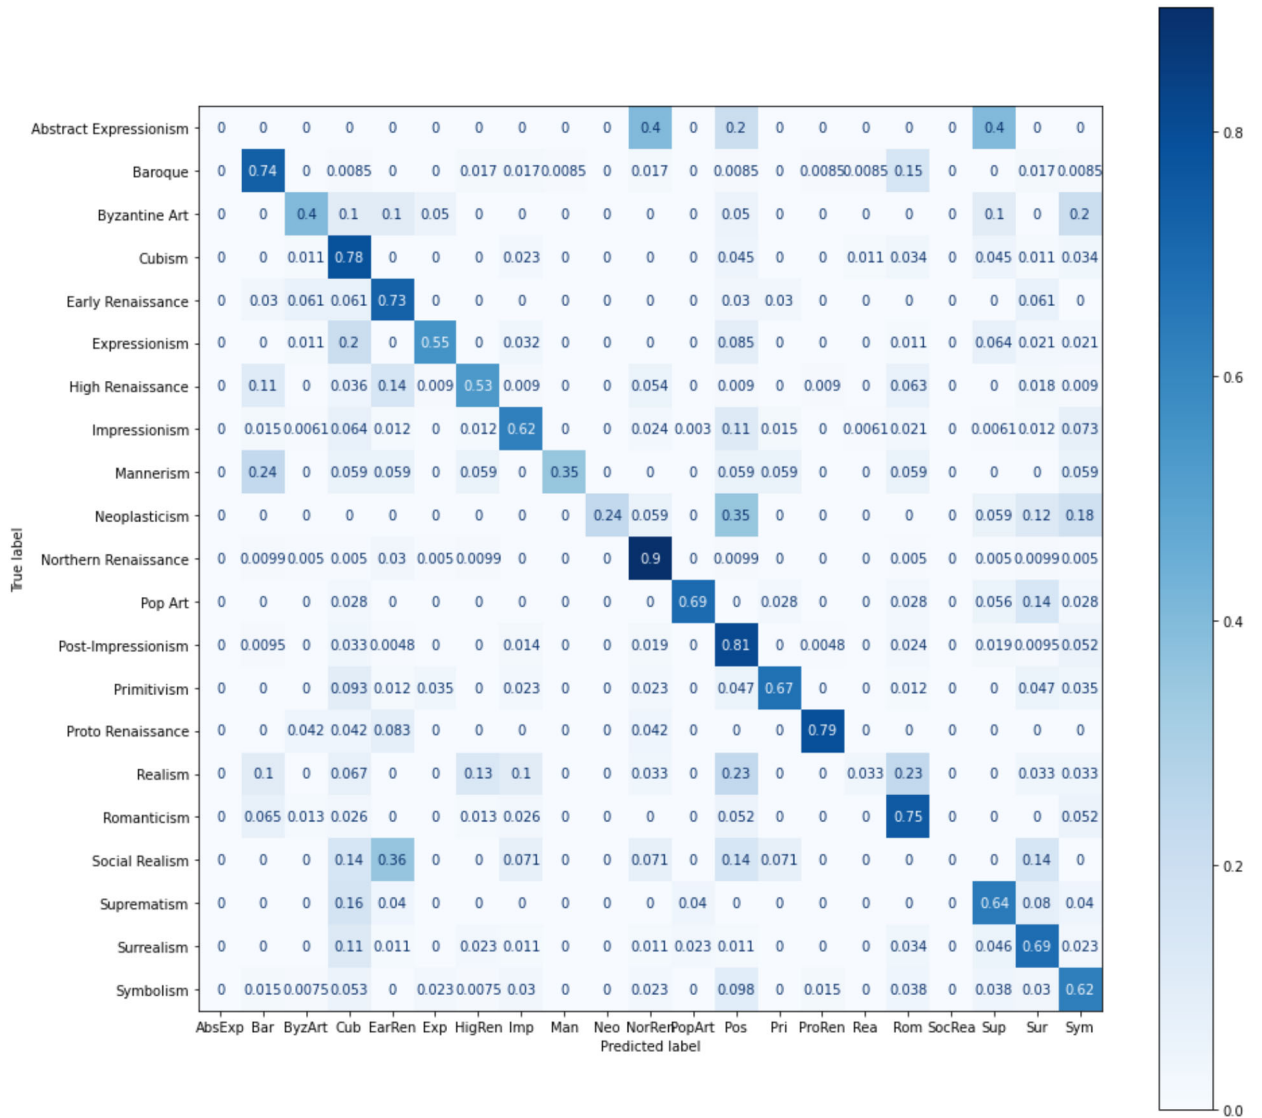
	precision	recall	f1-score	support
Abstract Expressionism	1.00	0.20	0.33	5
Baroque	0.52	0.75	0.62	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.70	0.32	0.44	88
Early Renaissance	0.50	0.12	0.20	33
Expressionism	0.66	0.56	0.61	94
High Renaissance	0.52	0.41	0.46	111
Impressionism	0.59	0.82	0.69	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	1.00	0.24	0.38	17
Northern Renaissance	0.73	0.86	0.79	202
Pop Art	0.93	0.69	0.79	36

Post-Impressionism	0.41	0.81	0.54	210
Primitivism	0.60	0.51	0.55	86
Proto Renaissance	0.73	0.33	0.46	24
Realism	0.00	0.00	0.00	30
Romanticism	0.54	0.26	0.35	77
Social Realism	0.00	0.00	0.00	14
Suprematism	1.00	0.28	0.44	25
Surrealism	0.76	0.44	0.55	87
Symbolism	0.47	0.17	0.24	133
<b>accuracy</b>			<b>0.57</b>	1755
macro avg	0.56	0.37	0.40	1755
weighted avg	0.57	0.57	0.53	1755

- ResNet152 (re-entrenadas las últimas 114 capas)






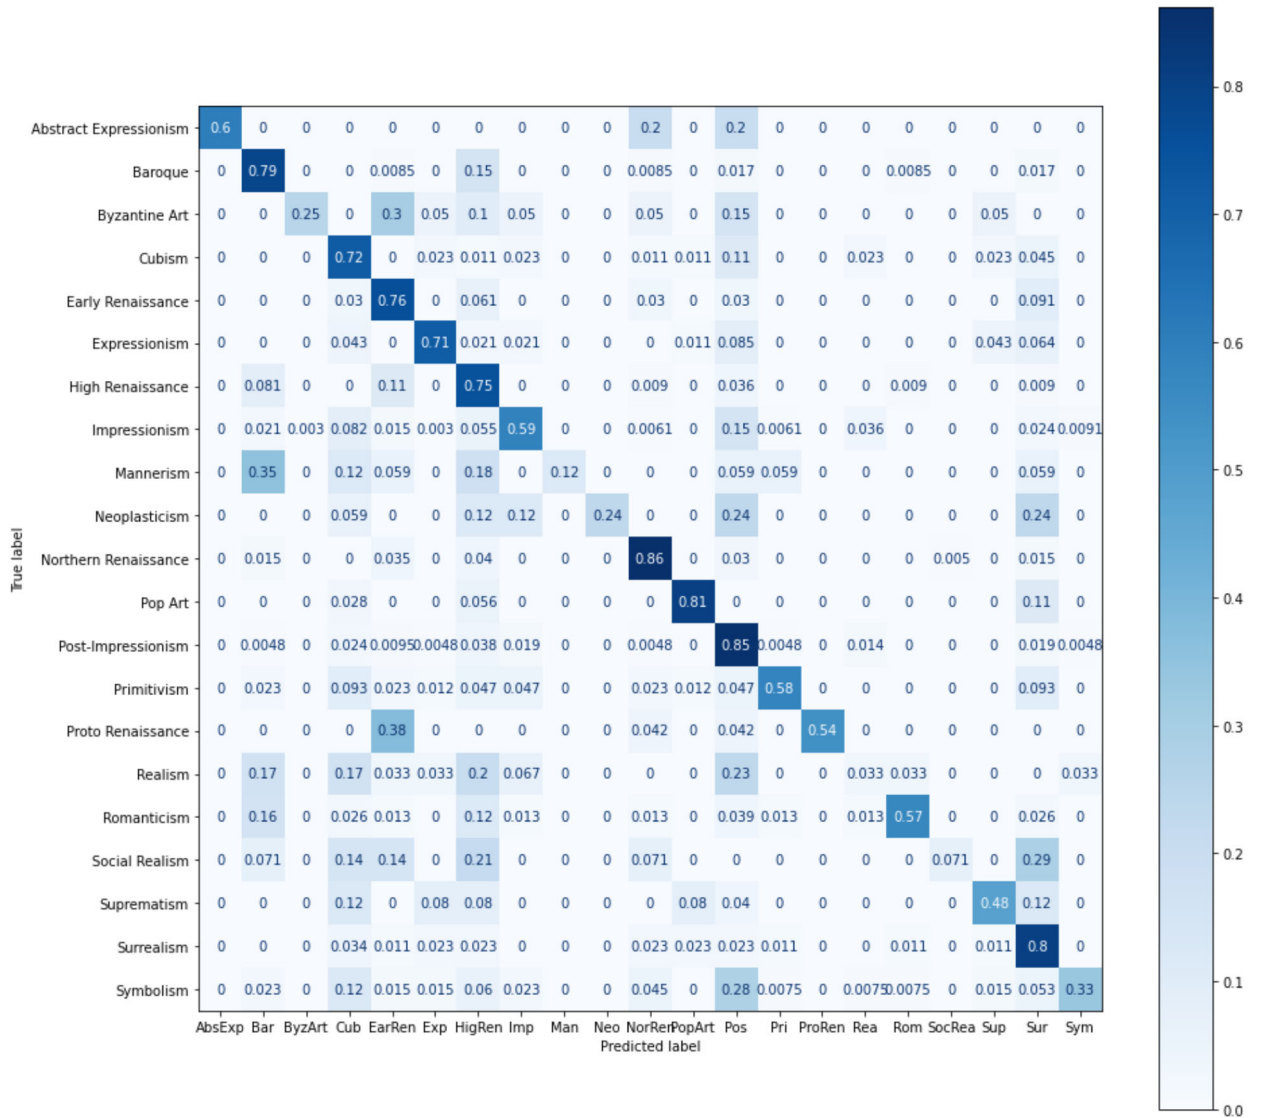


	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.70	0.74	0.72	117
Byzantine Art	0.44	0.40	0.42	20
Cubism	0.42	0.78	0.55	88
Early Renaissance	0.38	0.73	0.49	33
Expressionism	0.85	0.55	0.67	94
High Renaissance	0.78	0.53	0.63	111
Impressionism	0.89	0.62	0.73	329
Mannerism	0.86	0.35	0.50	17
Neoplasticism	1.00	0.24	0.38	17
Northern Renaissance	0.85	0.90	0.88	202
Pop Art	0.86	0.69	0.77	36

Post-Impressionism	0.65	0.81	0.72	210
Primitivism	0.87	0.67	0.76	86
Proto Renaissance	0.79	0.79	0.79	24
Realism	0.20	0.03	0.06	30
Romanticism	0.50	0.75	0.60	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.33	0.64	0.43	25
Surrealism	0.62	0.69	0.65	87
Symbolism	0.57	0.62	0.59	133
<b>accuracy</b>			<b>0.67</b>	1755
macro avg	0.60	0.55	0.54	1755
weighted avg	0.71	0.67	0.67	1755

- ResNet152 (re-entrenadas las últimas 30 capas)




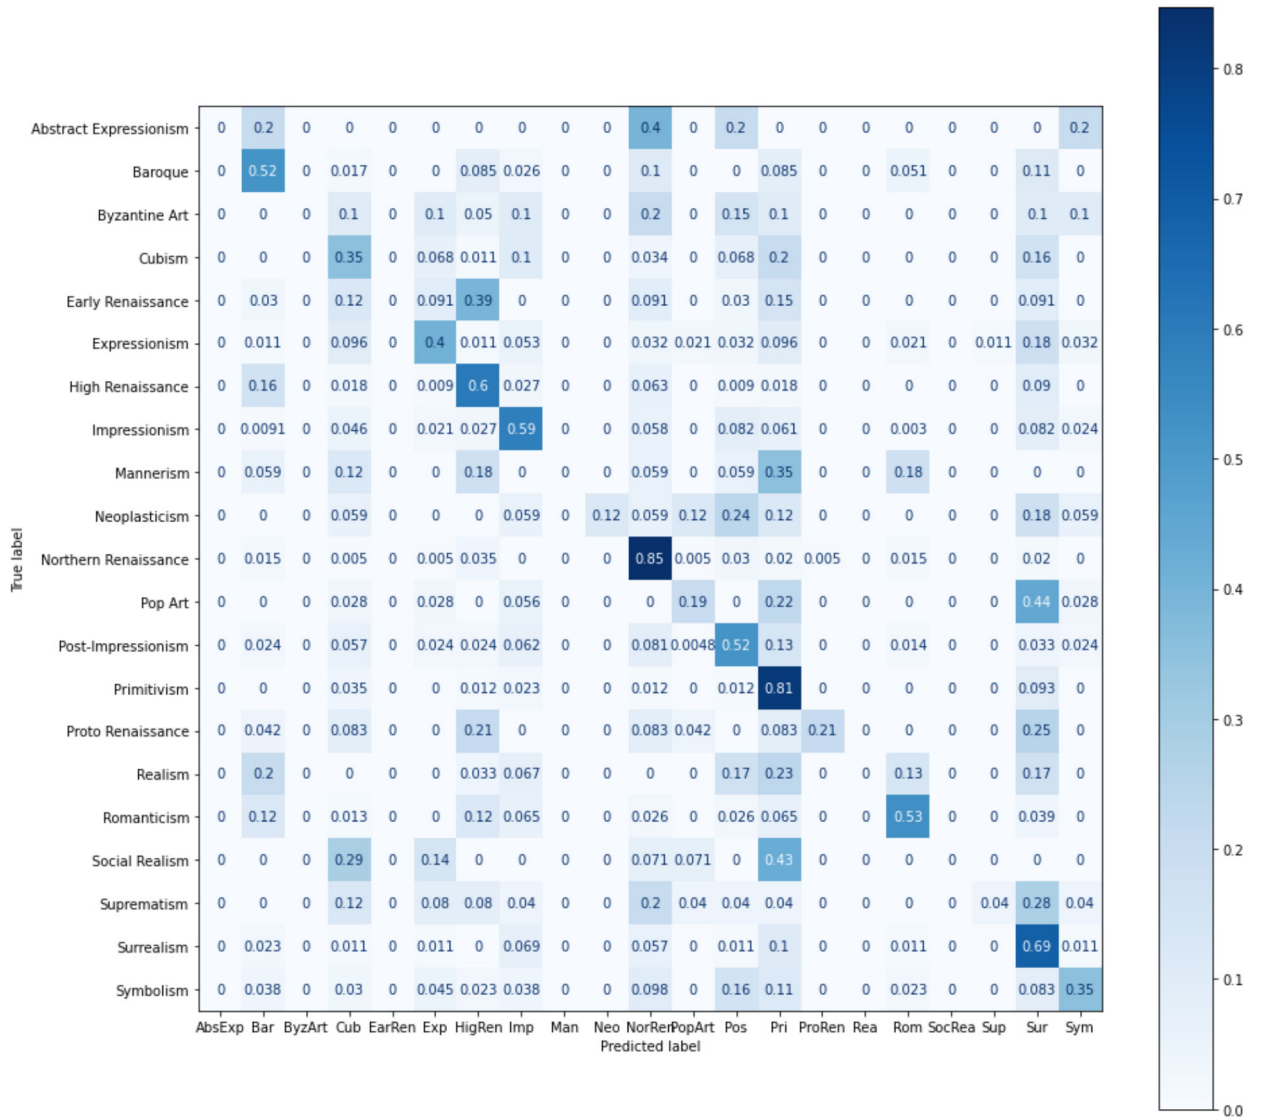


	precision	recall	f1-score	support
Abstract Expressionism	1.00	0.60	0.75	5
Baroque	0.65	0.79	0.71	117
Byzantine Art	0.83	0.25	0.38	20
Cubism	0.44	0.72	0.55	88
Early Renaissance	0.32	0.76	0.45	33
Expressionism	0.84	0.71	0.77	94
High Renaissance	0.45	0.75	0.56	111
Impressionism	0.90	0.59	0.71	329
Mannerism	1.00	0.12	0.21	17
Neoplasticism	1.00	0.24	0.38	17
Northern Renaissance	0.89	0.86	0.87	202
Pop Art	0.81	0.81	0.81	36

Post-Impressionism	0.55	0.85	0.67	210
Primitivism	0.88	0.58	0.70	86
Proto Renaissance	1.00	0.54	0.70	24
Realism	0.05	0.03	0.04	30
Romanticism	0.90	0.57	0.70	77
Social Realism	0.50	0.07	0.12	14
Suprematism	0.55	0.48	0.51	25
Surrealism	0.52	0.80	0.63	87
Symbolism	0.90	0.33	0.48	133
<b>accuracy</b>			<b>0.66</b>	1755
macro avg	0.71	0.54	0.56	1755
weighted avg	0.73	0.66	0.65	1755

- ResNet152 (completamente re-entrenado)





	precision	recall	f1-score	support
Abstract Expressionism	0.00	0.00	0.00	5
Baroque	0.52	0.52	0.52	117
Byzantine Art	0.00	0.00	0.00	20
Cubism	0.31	0.35	0.33	88
Early Renaissance	0.00	0.00	0.00	33
Expressionism	0.51	0.40	0.45	94
High Renaissance	0.49	0.60	0.54	111
Impressionism	0.77	0.59	0.66	329
Mannerism	0.00	0.00	0.00	17
Neoplasticism	1.00	0.12	0.21	17
Northern Renaissance	0.63	0.85	0.72	202
Pop Art	0.44	0.19	0.27	36

Post-Impressionism	0.56	0.52	0.54	210
Primitivism	0.31	0.81	0.44	86
Proto Renaissance	0.83	0.21	0.33	24
Realism	0.00	0.00	0.00	30
Romanticism	0.61	0.53	0.57	77
Social Realism	0.00	0.00	0.00	14
Suprematism	0.50	0.04	0.07	25
Surrealism	0.28	0.69	0.40	87
Symbolism	0.67	0.35	0.46	133
<b>accuracy</b>			<b>0.51</b>	1755
macro avg	0.40	0.32	0.31	1755
weighted avg	0.54	0.51	0.50	1755

#### 6.1.4. Comparativa

Con los resultados obtenidos, se construyó la siguiente tabla comparativa, de la que podemos concluir que el modelo VGG tuvo un performance considerablemente rezagado comparado, inclusive, con el baseline propuesto. Adicionalmente, el modelos ResNet tuvo un buen rendimiento es sus versiones parcialmente entrenadas.

ModelName	Precision Avg Weighed	Recall Avg Weighed	f1-score
Starter CNN	0.46	0.43	0.43
VGG19(Non Trainable)	0.16	0.26	0.26
VGG19(Trainable [:-5])	0.04	0.19	0.19
VGG19(Trainable [:-10])	0.04	0.19	0.19
VGG19(Trainable [:-15])	0.04	0.19	0.19
VGG19(Fully Trainable)	0.04	0.19	0.19
ResNet152v2(NonTrainable)	0.57	0.57	0.57
ResNet152v2([:-114])	<b>0.71</b>	<b>0.67</b>	<b>0.67</b>
ResNet152v2([:-30])	0.73	0.66	0.66
ResNet152v2(Trainable)	0.54	0.51	0.51

## 7. CONCLUSIONES

Teniendo en cuenta la diversidad de los datos, y la variabilidad de obras dentro de nuestro dataset, podemos concluir que los

Adicionalmente, se evidenció un fuerte sesgo en el conjunto de datos inicial, dado por el desbalance de los datos, y por la suposición realizada sobre la derivación de estilos a las pinturas. Inclusive con esto en mente, se obtuvo un f1-score sobresaliente, de 0.75, sobre la clase con menor número de muestras (Abstract Expressionism) y de 0.71 sobre los datos con mayor cantidad de ejemplos del dataset (Impressionism).

Se propone continuar con la investigación de la identificación de Movimientos artísticos haciendo scrapping de la web [Google Arts & Culture](#) que cuenta con una galería mucho más extensa y diversa de obras de arte.

# REFERENCIAS

Papi, L. R. (2018). The Aesthetics of Art. In *The Aesthetics of Art*.

Isrow, Zachary. "Defining Art and Its Future." *Journal of Arts and Humanities*, vol. 6, no. 6, 2017, p. 84., <https://doi.org/10.18533/journal.v6i6.1207>.

Masilamani, G. K., & Valli, R. (2021). Art Classification with Pytorch Using Transfer Learning. *2021 International Conference on System, Computation, Automation and Networking, ICSCAN 2021*. <https://doi.org/10.1109/ICSCAN53069.2021.9526457>

Gultepe, E., Edward. Conturo, T., & Makrehchi, M. (2018). Predicting and grouping digitized paintings by style using unsupervised feature learning. *Journal of Cultural Heritage*, 31. <https://doi.org/10.1016/j.culher.2017.11.008>

Lu, J., Behbood, V., Hao, P., Zuo, H., Xue, S., & Zhang, G. (2015). Transfer learning using computational intelligence: A survey. *Knowledge-Based Systems*, 80, 14–23. <https://doi.org/10.1016/j.knosys.2015.01.010>

Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*. <https://doi.org/10.1109/CVPR.2016.90>