
Avançant el diagnòstic de l'Alzheimer amb AH_Ad: un model de classificació basat en imatges d'MRI

Autor: Marc Jordán de la Cruz (mjordan@virolai.com)

Tutora: Sandra Entrena Ortega ([sentrena@virolai.com](mailto:sentren@virolai.com))

Abstract

Les xarxes neuronals convolucionals (CNN) han demostrat un èxit notable en diverses tasques de reconeixement d'imatges, fet que ha provocat la seva aplicació en el diagnòstic mèdic. En aquest estudi, es presenta un model CNN ampliat basat en EfficientNet-B0 capaç de detectar i classificar amb precisió la malaltia d'Alzheimer a partir de ressonàncies magnètiques cerebrals. Mitjançant el desenvolupament iteratiu, el model aconsegueix una precisió impressionant del 96%, subratllant el seu potencial en el diagnòstic en fase inicial amb una precisió del 95%. El conjunt de dades inclou 40.384 imatges categoritzades en quatre classes: NoDemented, VeryMildDemented, MildDemented i ModerateDemented. A més, aquesta investigació incorpora un OSM (Occlusion Sensivity Map), el qual permet visualitzar les àrees morfològiques del cervell on la malaltia de l'Alzheimer podria estar present. Aquesta eina no només ajuda a entendre millor les deteccions del model, sinó que també permet avançar en el diagnòstic precoç i el seu tractament, identificant àrees cerebrals clau per a la medicina individualitzada. Així, els pacients podrien ser tractats amb medicaments dirigits (targeted drugs), millorant l'eficàcia del tractament i obrint noves perspectives per a la medicina personalitzada.

Key words: Machine Learning, Alzheimer, EfficientNetB0, Diagnòstic en fase lleu, OSM, MRI

1. Introducció

L'Alzheimer és una malaltia neurodegenerativa progressiva que afecta de manera significativa a les funcions cognitives i al comportament dels individus, especialment la memòria. La detecció precoç de la malaltia és fonamental per implementar tractaments i intervencions que puguin alleugerar els seus efectes i, en alguns casos, retardar la seva progressió. No obstant això, els mètodes de diagnòstic es basen principalment en símptomes visibles i proves cognitives, que poden no ser prou sensibles per identificar l'Alzheimer en les seves etapes inicials, quan l'aplicació dels remeis actuals és molt més eficaç.

Gràcies a l'evolució de les tecnologies mèdiques, les tècniques d'imatge com la ressonància magnètica (MRI) s'han consolidat com a eines essencials per identificar canvis morfològics en el cervell. Aquests canvis, tot i no ser perceptibles a simple vista en les fases més lleus de la malaltia, poden ser detectats mitjançant intel·ligència artificial. Com es demostra en aquesta investigació, l'ús d'algoritmes avançats de machine learning permet identificar patrons subtils en les imatges cerebrals, possibilitant així la diferenciació entre les diverses etapes de l'Alzheimer i, per tant, podent fer un diagnòstic precoç de la malaltia.

2. Metodologia

(En aquest resum només es fa referència a la darrera versió del model AH_Ad, per veure el progrés i informació sobre les altres versions contacteu mjordan@virolai.com)*

En l'última versió del model AH_Ad, s'ha desenvolupat un model de xarxa neuronal convolucional (CNN) basat en EfficientNet-B0 per la detecció precoç de la malaltia de l'alzheimer mitjançant imatges de ressonància magnètica (MRI). Aquest model s'ha entrenat amb un conjunt de dades extens s'han aplicat tècniques de preprocessament per millorar el rendiment i s'ha incorporat un mecanisme d'interpretabilitat mitjançant OSM (Occlusion Sensivity Map) per identificar les regions cerebrals més rellevants en la detecció de la malaltia

a) Dades i preprocessament

El conjunt de dades utilitzat per l'entrenament i validació del model consta de 40.384 imatges de ressonància magnètica obtingudes de Kaggle, classificades en quatre categories segons el grau de deteriorament cognitiu: Non Demented, Very Mild Demented, Mild Demented and Moderate Demented.

Per garantir una millor capacitat de generalització del model i evitar el sobreajustament, s'han aplicat diverses tècniques de preprocessament. En primer lloc, s'han normalitzat les imatges, transformant els valors de píxels a un rang de [0,1]. També, s'han implementat tècniques d'augmentació de dades, com ara rotacions aleatòries ($\pm 15^\circ$), canvis d'escala ($\pm 10\%$), desplaçaments horitzontals i verticals (± 10 píxels), amb l'objectiu d'augmentar la variabilitat de les dades i millorar la capacitat del model per identificar patrons més enllà de variacions en la postura o orientació de les imatges.

b) Arquitectura del model

AH_Ad v4, es basa en EfficientNet-B0, una xarxa neuronal convolucional optimitzada per obtenir un alt rendiment amb un nombre reduït de paràmetres. La seva arquitectura es va modificar per millorar l'extracció de característiques i la capacitat de classificació.

En primer lloc, es va mantenir l'estructura original d'EfficientNet-B0, aprofitant les seves capes convolucionals. Aquestes capes inicials són responsables d'identificar patrons visuals bàsics, com ara vores i textures. Posteriorment, es va afegir una capa de GAP (Global Average Pooling), que permet reduir la dimensió de les característiques extretes i centrar-se en els patrons més rellevants de cada imatge.

A continuació, es va incorporar una capa completament connectada amb 512 neurones i activació ReLU, que permet modelar relacions complexes entre les característiques extretes per les capes convolucionals. Per reduir el risc de sobreajustament, es va aplicar un mecanisme de dropout del 50%, eliminant aleatòriament la meitat de les connexions durant l'entrenament. Finalment, la sortida del model consisteix en una capa densa amb quatre neurones, corresponents a les 4 classes del problema, amb una activació Softmax per calcular la probabilitat d'assignació de cada imatge a una categoria específica.

c) Filtres aplicats i característiques extretes

A les primeres capes de la xarxa, els filtres detecten elements bàsics com vores i contrastos de llum, mentre que les capes més profundes identifiquen estructures anatòmiques més complexes, com les regions afectades per la neurodegeneració.

Matemàticament, el procés de convolució es pot descriure amb la següent equació:

$$Y(i, j) = \sum_m \sum_n X(i - m, j - n) \cdot K(m, n)$$

On $X(i, j)$ representa la intensitat del píxel a la coordenada (i, j) , $K(m, n)$ és el filtre convolucional aplicat i $Y(i, j)$ és la nova imatge després de la convolució.

Per establir l'entrenament, s'ha utilitzat Batch Normalization, que normalitza les activacions internes amb l'expressió següent:

$$\hat{I}_i = \frac{I_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}; y_i = \gamma \hat{I}_i + \beta$$

Aquest procés millora la convergència i evita problemes derivats de la variabilitat en les distribucions de les dades.

d) OSM (Occlusion Sensivity Map)

Per interpretar millor les decisions del model, s'ha implementat un sistema d'OSM, una tècnica que permet identificar quines regions de la imatge són més rellevants per a la classificació. Aquest mètode consisteix a dividir la imatge en segments i bloquejar temporalment determinades àrees per observar com afecta la predicció del model.

L'aplicació d'OSM no només contribueix a una millor comprensió del funcionament del model, sinó que també té implicacions clíniques, ja que pot ajudar els professionals mèdics a centrar-se en àrees específiques durant l'anàlisi d'imatges.




Fig1: OSM aplicat a 3 mostres diferents.

e) Entrenament del model

El model ha estat entrenat utilitzant l'optimitzador Adam, amb una taxa d'aprenentatge inicial de 0.001. La funció de pèrdua seleccionada ha estat Categorical Crossentropy, que es defineix com:

$$L = - \sum_{i=1}^N I_i \log(\hat{I}_i)$$

On I_i representa la classe real i \hat{I}_i la probabilitat assignada pel model

L'entrenament s'ha dut a terme durant 150 èpoques, amb un batch size de 32 i validació fent ús de K-Fold Cross Validation (K=5) per garantir la robustesa del model.

3. Resultats

El model AH_Ad v4, ha demostrat resultats excepcionals després d'un entrenament extensiu amb un conjunt de dades compost per 40.384 imatges etiquetades en quatre classes (NonDemented, VeryMildDemented, MildDemented i ModerateDemented). Els resultats obtinguts reflecteixen la capacitat del model per classificar amb precisió les diferents etapes de la malaltia de l'Alzheimer, destacant l'alta capacitat per detectar-la en fases primerenques.

Classification Report:				
	precision	recall	f1-score	support
MildDemented	0.98	0.99	0.98	896
ModerateDemented	1.00	1.00	1.00	64
NonDemented	0.96	0.98	0.97	3200
VeryMildDemented	0.97	0.93	0.95	2240
accuracy			0.96	6400
macro avg	0.98	0.98	0.98	6400
weighted avg	0.96	0.96	0.96	6400

Fig2: Classification report de AH_Ad v4.

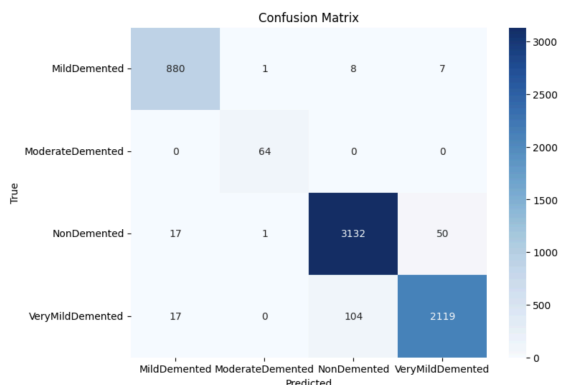


Fig3: Confusion matrix de AH_Ad v4.

a) Precisió global del model

El model final ha aconseguit una precisió global del 96%, el que significa que, en el conjunt de dades de test, el model va ser capaç de classificar correctament el 96% de les imatges en les seves respectives categories. A més a més, es va comprovar amb un dataset extern acabant verificant aquest valor d'encert. Aquest percentatge remarca l'alta capacitat del model per identificar amb exactitud les diferències entre els diferents estats de la malaltia des de mostres sanes fins a casos més avançats d'Alzheimer.

b) Precisió en estadi inicial de la malaltia

Un aspecte fonamental en el diagnòstic de l'Alzheimer és la seva detecció precoç, quan els tractaments poden ser més eficaços.

En aquest sentit, com es pot veure a les Fig 2 i Fig 3, el model ha aconseguit una f1-score de 0.95 en la classificació de pacients en estadi inicial (VeryMildDemented). Aquesta elevada precisió les etapes primerenques de la malaltia és un dels punts més destacats de l'estudi, ja que el model pot identificar estructures morfològiques subtils en les imatges de ressonància magnètica que indiquin la presència de la malaltia en el pacient. Aquestes estructures poden ser molt complicades de veure fins i tot per a un ull expert, ja que no es veuen a simple vista.

4. Discussió

Els resultats obtinguts amb el model AH_Ad v4 mostren un rendiment excepcional en la classificació de la malaltia de l'Alzheimer mitjançant imatges de ressonància magnètica, amb una precisió global del 96% i una detecció en fase inicial del 95%. Aquestes xifres no només superen les d'altres arquitectures convencionals com VGG16 o el Siamese Network, sinó que també demostren una gran generalització quan es prova amb dades externes.

a) Comparació amb altres models

Ref	Dataset	Modalitat	ACC	F1-score
AH_Ad (V4)	Kaggle (4 class)	MRI	96	96
DEMNET [1]	Kaggle (4 class)	MRI	95.23	95.27
Ensemble based classifier [2]	GARD (2 class)	sMRI	90.05	98.35
VGG16 [3]	ADNI (3 class)	MRI	95.73	95
Siamese Network [4]	ADNI (2 class)	MRI	92.72	93.72
MLP [5]	ADNI (3 class)	MRI	89	89
CBLSTM + GAIN [5]	ADNI (3 class)	MRI	82	82
CBLSTM + SMOTE [5]	ADNI (3 class)	MRI	82	82

Taula 1: Comparació d'AH_Ad amb altres models.

b) Fiabilitat i robustesa del model

L'ús de K-fold Cross Validation (K=5) ha garantit que el model no es sobre-ajusti al conjunt de dades d'entrenament, millorant la seva capacitat de generalització. A més, la incorporació d'augmentació de dades ha ajudat el model a identificar patrons rellevants malgrat les variacions en la postura i orientació de les imatges. Això es veu reflectit en la macro average de 0.98, la qual suggereix un equilibri adequat entre les diferents classes.

Malgrat això, tot i que encara és bona, s'observa una lleugera disminució en la precisió per a la classe VeryMildDemented (amb un f1-score de 0.95, però només un 0.93 de recall), la qual cosa indica que alguns pacients en les primeres fases de la malaltia poden ser classificats erròniament en altres categories. Aquesta tendència és consistent amb la dificultat de la detecció de les primeres etapes de l'Alzheimer, on les diferències morfològiques en les imatges poden ser mínimes.

c) Eficiència computacional

Un altre factor clau a discutir és l'eficiència computacional del model. Tot i que arquitectures més profundes com ResNet50 poden aconseguir una precisió una mica més alta, aquestes requereixen un nombre de paràmetres considerablement més gran. En canvi, EfficientNet-B0, la base d'AH_Ad v4, optimitza la relació entre precisió i eficiència computacional, fent-lo més adequat per aplicacions en entorns clínics amb recursos limitats, on la rapidesa i la reducció del consum computacional són prioritàries.

5. Conclusió

Aquest estudi ha demostrat l'eficiència del model AH_Ad, basant en EfficientNet-B0, per a la detecció i classificació de la malaltia d'Alzheimer mitjançant imatges d'MRI.

Amb una precisió global del 96% i una f1-score del 95% en la detecció precoç, el model es consolida com una eina prometedora per a la identificació de l'Alzheimer en les seves fases inicials.

Comparant altres arquitectures com VGG16 o ResNet50, el model proposat no només ha superat aquestes xarxes neuronals sinó que també ha destacat per la seva eficiència computacional, fet que el fa més adequat per aplicacions mèdiques en entorns amb recursos limitats. A més, la implementació de l'Oclusion Sensivity Map (OSM) permet millorar la interpretabilitat del model, facilitant la comprensió de les seves prediccions i proporcionant informació útil per als professionals mèdics.

Tot i els resultats prometedors, cal mencionar que s'ha observat una lleugera disminució en el recall de la classe VeryMildDemented (93%), la qual cosa indica que alguns pacients en etapes molt inicials podrien ser classificats erròniament. Aquest és un repte lligat a la detecció precoç de la malaltia, que es podria millorar amb conjunts de dades més grans i focalitzats en aquesta etapa de la malaltia.

Ah_Ad v4, es presenta com un pas endavant cap a l'automatització del diagnòstic de l'Alzheimer, obrint la porta a sistemes de suport clínic basats en intel·ligència artificial. Futures línies de recerca podrien explorar la seva integració en fluxos de treball clínics, així com la integració multimodal per tindre més referències sobre el pacient i millorar el diagnòstic.

6. Agraïments

En primer lloc, vull donar les gràcies a la Sandra Entrena Ortega, la meva tutora, per la seva dedicació i suport constant durant tot el procés del treball. La seva orientació, consell i motivació han estat essencials.

També vull expressar la meva gratitud als professors de l'Escola Virolai, en particular al José Luis Touron Rivadulla, per la seva ajuda en l'àmbit matemàtic i tecnològic. El seu suport ha estat fonamental per corroborar la informació més tècnica.

A més, agraeixo especialment a la Montse Ballarín Andreu per proporcionar-me contactes valuosos que han enriquit el meu treball i ampliat les meves oportunitats de recerca.

Igualment, vull expressar el meu agraïment a la Montserrat Brau Altés per la seva mentoria en l'àmbit emprenedor. El seu suport i consell m'han ajudat a entendre millor el món empresarial i a explorar noves oportunitats.

Finalment, desitjo expressar el meu reconeixement a tot l'equip de l'Escola Virolai per oferir-me un entorn d'aprenentatge enriquidor durant tots aquests anys.

La vostra dedicació i suport han estat fonamentals en el meu creixement acadèmic i personal.

Gràcies de tot cor a cadascuna de les persones i institucions mencionades per la seva ajuda i orientació.

7. Referències

- [1] S. Murugan *et al.*, "DEMNET: A Deep Learning Model for Early Diagnosis of Alzheimer Diseases and Dementia From MR Images," in *IEEE Access*, vol. 9, pp. 90319-90329, 2021, doi: 10.1109/ACCESS.2021.3090474. keywords: {Magnetic resonance imaging;Feature extraction;Alzheimer's disease;Brain modeling;Deep learning;Neuroimaging;Computational modeling;Deep learning;Alzheimer's Disease;MRI image;convolutional neural network;Cohen's kappa}
- [2] Ahmed, S., Choi, K. Y., Lee, J. J., Kim, B. C., Kwon, G. R., Lee, K. H., & Jung, H. Y. (2019). Ensembles of patch-based classifiers for diagnosis of Alzheimer diseases. *IEEE Access*, 7, 73373-73383.
- [3] Jain, R., Jain, N., Aggarwal, A., & Hemanth, D. J. (2019). Convolutional neural network based Alzheimer's disease classification from magnetic resonance brain images. *Cognitive Systems Research*, 57, 147-159.
- [4] Liu, C. F., Padhy, S., Ramachandran, S., Wang, V. X., Efimov, A., Bernal, A., ... & Alzheimer's Disease Neuroimaging Initiative. (2019). Using deep Siamese neural networks for detection of brain asymmetries associated with Alzheimer's disease and mild cognitive impairment. *Magnetic resonance imaging*, 64, 190-199.
- [5] Stamate, D., Smith, R., Tsygancov, R., Vorobev, R., Langham, J., Stahl, D., & Reeves, D. (2020). Applying deep learning to predicting dementia and mild cognitive impairment. In *Artificial Intelligence Applications and Innovations: 16th IFIP WG 12.5 International Conference, AIAI 2020, Neos Marmaras, Greece, June 5-7, 2020, Proceedings, Part II 16* (pp. 308-319). Springer International Publishing.
- [98] Wikipedia contributors. (2023, desembre 8). *Cross-entropy*. Wikipedia, The Free Encyclopedia. <https://en.wikipedia.org/wiki/Cross-entropy>

**Per veure la llista completa de referències de l'estudi contacteu mjordan@virolai.com*