

Krešimir Markota⁽¹⁾

Andrija Petrović⁽²⁾

Ante Javor⁽³⁾

Tomislav Adamović⁽⁴⁾

(1) Veleučilište u Bjelovaru,
Trg Eugena Kvaternika 4,
HR-43000 Bjelovar
kmarkota@vub.hr

(2) Veleučilište u Bjelovaru,
Trg Eugena Kvaternika 4,
HR-43000 Bjelovar
apetrovic1@vub.hr

(3) Veleučilište u Bjelovaru,
Trg Eugena Kvaternika 4,
HR-43000 Bjelovar
ajavor@vub.hr

(4) Veleučilište u Bjelovaru,
Trg Eugena Kvaternika 4,
HR-43000 Bjelovar
tadamovic@vub.hr

Zaprimljeno / Received
16. veljače 2026. / 16 February 2026
Prihvaćeno / Accepted
23. veljače 2026. / 23 February 2026

Autor za korespondenciju /
Corresponding author
Krešimir Markota
kmarkota@vub.hr

DOI: 10.70856/p.3.1.2



Usporedba generativnih suparničkih mreža za sintezu slika listova vinove loze

Sažetak: Ovaj rad istražuje primjenu generativnih suparničkih mreža za generiranje slika listova vinove loze te provodi usporednu analizu triju arhitektura baziranih na generativnim suparničkim mrežama, a to su osnovni model generativnih suparničkih mreža, duboke konvolucijske suparničke mreže i Wasserstein generativne suparničke mreže s gradijentnim penalom. Eksperimentalni dio rada s generativnim suparničkim mrežama temelji se na skupu stvarnih slika listova vinove loze koje su prethodno normalizirane i pripremljene za treniranje modela. Svaki od promatranih modela treniran je zasebno, nakon čega su generirane sintetičke slike korištene za kvantitativnu evaluaciju kvalitete generiranja. Za procjenu sličnosti između stvarnih i generiranih slika korištene su standardne metrike: Frechet Inception Distance, Kernel Inception Distance i Inception Score, koje se često primjenjuju u analizi generativnih modela.

Dobiveni rezultati pokazuju da duboka konvolucijska generativna suparnička mreža ostvaruje najbolje performanse među analiziranim modelima, s najnižom vrijednošću Frechet Inception Distance i Kernel Inception Distance metrike te najvišim Inception Score rezultatom, što upućuje na stabilnije treniranje i bolju kvalitetu generiranih slika. Wasserstein generativna suparnička mreža s gradijentnim penalom postiže srednje rezultate, dok osnovni model generativne suparničke mreže pokazuje najslabije performanse, što je u skladu s nalazima sličnih istraživanja u literaturi. Zaključno, rezultati potvrđuju da naprednije arhitekture generativnih suparničkih mreža pružaju značajne prednosti u generiranju realističnih slika listova vinove loze te imaju potencijal za daljnju primjenu u poljoprivrednim i računalno-vidnim sustavima.

Ključne riječi: generativne suparničke mreže, DCGAN, WGAN, sinteza slika, list vinove loze, evaluacija kvalitete

1. Uvod

Razvoj dubokog učenja značajno je unaprijedio područje računalnog vida, posebice u zadacima analize i obrade slika. Među suvremenim pristupima ističu se generativni modeli, čiji je cilj naučiti raspodjelu podataka i generirati nove uzorke koji su slični stvarnim podacima. Posebno mjesto među njima zauzimaju generativne suparničke mreže (engl. Generative Adversarial Networks, dalje u tekstu GAN) koje su od svog uvođenja postale jedno od najistraživanijih područja u dubokom učenju. GAN mreže prvi su put predstavljene u radu (Goodfellow i suradnici, 2014) u kojem je predložen koncept dviju arhitektura neuronskih mreža koje se treniraju istodobno u suparničkom odnosu: generatora, koji pokušava generirati realistične uzorke, i diskriminatora, koji nastoji razlikovati stvarne podatke od generiranih. Takav način treniranja omogućuje generatoru postupno poboljšavanje kvalitete generiranih podataka, ali istovremeno donosi izazove poput nestabilnog treniranja, kolapsa modova i osjetljivosti na hiperparametre. Primjena GAN modela posebno je zanimljiva u domeni poljoprivrede i analize biljaka. U tom području često postoji ograničen broj označenih podataka, dok je prikupljanje i anotacija novih slika vremenski i financijski zahtjevna. Slike listova biljaka, uključujući vinovu lozu, koriste se u zadacima prepoznavanja bolesti, procjene stanja usjeva i automatizirane klasifikacije. Generiranje sintetičkih slika listova može doprinijeti augmentaciji skupova podataka i poboljšanju robusnosti modela strojnog učenja.

Cilj je ovoga rada provesti usporednu analizu triju GAN arhitektura, što uključuje:

1. Osnovnu GAN arhitekturu,
2. Duboko konvolucijsku generativnu suparničku mrežu (engl. Deep Convolutional Generative Adversarial Network, dalje u tekstu DCGAN),
3. Wasserstein generativnu suparničku mrežu s gradijentnim penalom (engl. Wasserstein Generative Adversarial Network with Gradient Penalty, dalje u tekstu WGAN-GP).

Prethodno spomenute arhitekture GAN modela korištene su u kontekstu generiranja slika listova vinove loze. Kvaliteta generiranih slika evaluirana je pomoću standardnih kvantitativnih metrika:

1. Frechet Inception Distance (dalje u tekstu FID),
2. Kernel Inception Distance (dalje u tekstu KID),
3. Inception Score (dalje u tekstu IS).

Rezultati dobiveni korištenjem tih triju metrika uspoređeni su s nalazima sličnih radova u literaturi. Time se nastoji dati doprinos razumijevanju prednosti i ograničenja pojedinih GAN arhitektura u praktičnoj primjeni u poljoprivredi.

2. Prethodna i povezana istraživanja

U literaturi se nalaze i drugi radovi koji primjenjuju generativne suparničke mreže za augmentaciju ili generiranje sintetičkih slika biljnih bolesti radi poboljšanja modela strojnog učenja. Han i suradnici trenirali su DCGAN i $\alpha\beta$ GAN modele na slikama biljnih bolesti kako bi generirali realistično uvjerljive uzorke te analizirali utjecaj takvih podataka na klasifikaciju uz pomoć unaprijed treniranog VGG16 modela. Sličan pristup koriste Wang i suradnici (2025), koji su predložili GAN model s dvostrukim diskriminatorima za generiranje dodatnih uzoraka iz PlantVillage dataseta, čime su povećali raznolikost i kvalitetu skupa podataka te poboljšali točnost klasifikacijskih modela u zadacima identifikacije bolesti listova. Ovi radovi potvrđuju da temeljeni pristupi na GAN modelima imaju potencijal ne samo za generiranje vizualno uvjerljivih slika, nego i za značajno poboljšanje performansi modela dubokog učenja u domenu prepoznavanja bolesti biljaka. Nadalje, u radu (Liu, B. i suradnici, 2020) koji se bavi problemom ograničene količine označenih slikovnih podataka za prepoznavanje bolesti listova vinove loze, autori predlažu svoj generativni model nazvan LeafGAN koji je posebno dizajniran za generiranje realističnih slika oboljelih listova. LeafGAN se sastoji od generatora s degresivnim kanalima (engl. degressive channels), koji bolje uči distribuciju lezija, te diskriminatora s gustim povezivanjem i normalizacijom instance (engl. instance normalization), koji učinkovitije razlikuje stvarne od generiranih slika.

Slična istraživanja u području generiranja slika biljnih listova pokazuju da naprednije GAN arhitekture mogu proizvesti realističnije i raznovrsnije uzorke, dok jednostavniji modeli često generiraju zamućene ili uniformne slike. Međutim, rezultati uvelike ovise o kvaliteti podataka, arhitekturi modela i načinu evaluacije, zbog čega je usporedba različitih GAN pristupa i dalje aktualna istraživačka tema.

3. Metodologija

Pravilno definirana metodologija ključna je za ovaj rad jer omogućuje sustavan pristup prikupljanju, obradi i evaluaciji slikovnih podataka te osigurava usporedivost i pouzdanost rezultata pri treniranju i analizi GAN modela.

Spomenuti sustavan pristup obuhvaća tri glavna koraka:

1. Prikupljanje podatkovnog skupa slika i predobrada istih,
2. Odabir i implementacija arhitektura GAN modela,
3. Evaluacija generiranih slika pomoću kvantitativnih metrika.


Takav pristup omogućuje sustavno testiranje različitih GAN modela, kontroliranu usporedbu njihovih performansi i pouzdanu interpretaciju rezultata, čime se osigurava kvaliteta i primjenjivost generiranih sintetičkih uzoraka u praksi. Eksperimenti su provedeni u Python 3.6 okruženju, uz korištenje biblioteka TensorFlow 2.12.0, OpenCV 4.7.0, Matplotlib 3.7.1, Seaborn 0.12.2, Pandas 2.1.0 i Pickle za učitavanje i pohranu podataka. Implementacija svih modela, postupaka predobrade podataka te evaluacijskih metrika javno je dostupna putem Git repozitorija (Markota, 2026).

3.1. Prikupljanje i predobrada podatkovnog skupa

U ovom radu korišten je javno dostupan podatkovni skup slika pod nazivom Grape vine leaf disease koji se nalazi na mrežnoj stranici Kaggle (S. Yeo, 2024). Spomenuti podatkovni skup slika često se primjenjuje u istraživanjima iz područja računalnog vida i analize bolesti vinove loze. Skup podataka sadrži četiri klase slika od kojih se tri odnose na bolesti, a to su klase pod nazivima Black Rot, Esca, Leaf Blight, a jedna se klasa odnosi na zdravu klasu listova koja je nazvana Healthy. Slike u podatkovnom skupu snimane su u kontroliranim uvjetima, s homogenom pozadinom i ujednačenim osvjetljenjem. Takvi uvjeti smanjuju utjecaj vanjskih varijacija, ali istovremeno mogu ograničiti generalizaciju modela na stvarne uvjete u vinogradima, što je važno uzeti u obzir pri interpretaciji završnih rezultata.

Prije treniranja generativnih suparničkih mreža provedena je predobrada slika s ciljem ujednačavanja ulaznih podataka i osiguravanja stabilnog treniranja modela. Izvorne slike podatkovnog skupa učitane su pomoću biblioteke OpenCV u RGB formatu boja. Sve slike skalirane su na jedinstvenu prostornu rezoluciju od 200 x 200 piksela. Ovim postupkom osigurana je konzistentna veličina ulaza za sve modele, što je nužno za ispravan rad neuronskih mreža i omogućuje usporedbu rezultata između različitih GAN arhitektura. Budući da korišteni generatori proizvode RGB slike, zadržana su tri kanala boje. Nakon promjene dimenzija, slikovni podaci pohranjeni su u numeričkom obliku kao polja u rasponu vrijednosti piksela od 0 do 255 te su spremljeni u datoteke korištenjem pickle formata. Za potrebe treniranja generativnih suparničkih mreža, izlaz generatora koristi tanh aktivacijsku funkciju, zbog čega su generirane slike inicijalno u

rasponu vrijednosti $[-1,1]$. S obzirom na generativnu prirodu modela, cjelokupni podatkovni skup korišten je za treniranje modela, dok se evaluacija temeljila na usporedbi generiranih i stvarnih slika pomoću kvantitativnih metrika. Primjeri slika iz korištenog podatkovnog skupa prikazani su na slici 3.1. Spomenuta slika prikazuje listove vinove loze različitih klasa bolesti, uključujući zdrave i zaražene uzorke, te ilustriraju raznolikost vizualnih obilježja prisutnih u podatkovnom skupu.



Slika 3.1: Primjeri slika iz korištenog podatkovnog skupa

3.2. Arhitekture generativnih suparničkih mreža

U ovom radu za generiranje sintetičkih slika listova vinove loze korištene su tri GAN arhitekture: osnovni GAN, DCGAN i WGAN-GP. Svaka od arhitektura odabrana je zbog svojih karakterističnih svojstava i učestalosti primjene u literaturi za generiranje prirodnih i biljnih slika.

Prvi model u nizu koji je korišten jest GAN model koji predstavlja osnovnu GAN arhitekturu koju su predložili Goodfellow i suradnici (2014), a sastoji se od dvaju modela neuronskih mreža: generatora i diskriminatora koji se isključivo sastoje od potpuno povezanih slojeva. Generator pretvara latentni šum u slike, dok diskriminator klasificira slike kao stvarne ili generirane. Za treniranje se koristi standardna binary cross-entropy funkcija gubitka. Iako je arhitektura jednostavna, često pokazuje nestabilno treniranje i osjetljivost na hiperparametre, što je razlog uvođenja naprednijih GAN modela.

Sljedeći generativni model u nizu koji je korišten za generiranje slika jest DCGAN. Arhitektura DCGAN-a nadograđuje osnovnu GAN arhitekturu korištenjem konvolucijskih i transponiranih konvolucijskih slojeva u generatoru i diskriminatoru. Korištenje serijske normalizacije (engl. batch normalization) slojeva i LeakyReLU aktivacija omogućuje stabilnije treniranje i kvalitetnije generirane slike. DCGAN je široko primijenjen u literaturi za generiranje prirodnih i biljnih slika, pri čemu funkcija gubitka ostaje binary cross-entropy, a arhitekturne modifikacije značajno poboljšavaju sposobnost mreže pri generiranju realističnih uzoraka (Radford i suradnici, 2016).

Zadnji korišteni model bio je WGAN-GP, napredna arhitektura koja koristi Wassersteinovu udaljenost umjesto standardne Jensen-Shannon divergencije, što omogućuje stabilnije treniranje i smanjuje problem kolapsa modova (Arjovsky i suradnici, 2017; Gulrajani i suradnici, 2017). Gradijentni penal dodatno stabilizira treniranje tako da prisiljava gradijent kritičara da ima normu blizu 1. Za treniranje se koriste odvojeni koraci za generator i kritičar, s višestrukim ažuriranjima kritičara po jednoj iteraciji generatora. Prema istim autorima, ova arhitektura omogućuje pouzdano treniranje dubokih GAN mreža na složenijim skupovima podataka s više klasa.

Svi modeli koriste latentni vektor dimenzije 100 kao ulaz u generator, dok su izlazne veličine $200 \times 200 \times 3$ piksela, normalizirane u interval $[-1, 1]$. Optimizatori su odabrani u skladu s literaturom: Adam optimizator za GAN i DCGAN, te RMSprop s nižom stopom učenja za WGAN-GP.

3.3. Evaluacija generiranih slika

Kvaliteta generiranih slika u radu evaluirana je pomoću triju standardnih kvantitativnih metrika koje se često koriste u istraživanjima generativnih suparničkih mreža: FID, KID i IS (Heusel i suradnici, 2017; Bińkowski i suradnici, 2018; Salimans i suradnici, 2016). Navedene metrike omogućuju objektivnu usporedbu različitih GAN arhitektura te procjenu sličnosti između stvarnih i sintetički generiranih slika.

FID mjeri udaljenost između distribucija značajki stvarnih i generiranih slika u prostoru značajki izvučenih pomoću unaprijed trenirane Inception mreže (Heusel i suradnici, 2017). Pretpostavlja se da se te značajke mogu aproksimirati višedimenzionalnom Gaussovom distribucijom, pri čemu se udaljenost između dviju distribucija računa Frechetovom metrikom. Niže vrijednosti FID metrike ukazuju na veću sličnost generiranih slika stvarnim podacima te se u literaturi smatraju pokazateljem bolje vizualne kvalitete i raznolikosti uzoraka (Heusel i suradnici, 2017).

KID također koristi značajke iz Inception mreže, no (za razliku od FID metrike) ne pretpostavlja parametarski oblik distribucije podataka. Umjesto toga primjenjuje metodu maksimalne srednje razlike (engl. Maximum Mean Discrepancy, dalje u tekstu MMD) u prostoru jezgri kako bi se procijenila razlika između stvarnih i generiranih uzoraka (Bińkowski i suradnici, 2018). KID je nepristrana metrika i pokazuje veću stabilnost pri manjem broju uzoraka, zbog čega je pogodna za evaluaciju GAN modela treniranih na ograničenim skupovima podataka. Kao i kod FID metrike, niže vrijednosti KID metrike označavaju bolju kvalitetu generiranih slika, navode isti autori.

Zadnja korištena mjera, IS, mjeri istovremeno kvalitetu i raznolikost generiranih slika analizirajući izlaze Inception klasifikatora (Salimans i suradnici, 2016). Visoka vrijednost IS metrike postiže se kada generirane slike imaju jasnu pripadnost jednoj klasi te kada je distribucija klasa raznolika. U literaturi se rezultat najčešće prikazuje kao središnja vrijednost s pripadajućom varijacijom, primjerice 1.61 ± 0.15 , pri čemu simbol \pm označava standardnu devijaciju IS metrike izračunatu preko više serija generiranih slika. Manja vrijednost standardne devijacije upućuje na stabilniji i konzistentniji generator, dok veća vrijednost ukazuje na veću varijabilnost kvalitete ili raznolikosti među serijama slika. Iako je IS metrika široko korištena u ranim GAN istraživanjima, ograničenja spomenute metrike uključuju neusporedivost sa stvarnim podacima i osjetljivost na korišteni klasifikacijski model (Salimans i suradnici, 2016).

Kombiniranom primjenom FID, KID i IS metrika u ovome radu omogućena je sveobuhvatna procjena kvalitete generiranih slika, pri čemu FID i KID pružaju izravnu usporedbu sa stvarnim uzorcima iz skupa podataka, dok IS dodatno mjeri raznolikost i prepoznatljivost generiranih uzoraka. Dobiveni rezultati korišteni su za usporedbu performansi GAN, DCGAN i WGAN-GP arhitektura.

4. Rezultati

Procjena sposobnosti generativnih arhitektura GAN, DCGAN i WGAN-GP u generiranju realističnih slika listova vinove loze provedena je korištenjem kvantitativnih metrika (Heusel i suradnici, 2017; Bińkowski i suradnici, 2018; Salimans i suradnici, 2016) i vizualne analize sintetiziranih uzoraka. Kvantitativni rezultati prikazani su u tablici 4.1.

Tablica 4.1: Prikaz rezultata evaluacije korištenih generativnih modela

	<i>FID</i>	<i>KID</i>	<i>IS</i>
<i>GAN</i>	383.86	0.4841	1.17 ± 0.12
<i>WGAN-GP</i>	200.14	0.2181	1.30 ± 0.10
<i>DCGAN</i>	96.94	0.0869	1.61 ± 0.15

Osnovni model GAN ostvario je najslabije performanse, s FID vrijednošću od 383.86 i KID vrijednošću od 0.4841, dok je IS iznosio 1.17 ± 0.12 . Generirane slike često su zamućene, s neprirodnim bojama i slabije izraženom strukturom listova.


WGAN-GP postigao je srednje rezultate, s FID vrijednošću od 200.14 i KID vrijednošću od 0.2181 te IS od 1.30 ± 0.10 . Generirane slike stabilnije su i oštrije nego kod osnovnog GAN-a, no i dalje sadrže određene artefakte i manju razinu detalja.

DCGAN model postigao je najbolje rezultate, s FID vrijednošću od 96.94, KID vrijednošću od 0.0869 i IS od 1.61 ± 0.15 . Vizualno, DCGAN generira jasnije obrise listova, prirodnije prijelaze boja i realističnije teksture, što je posljedica uporabe konvolucijskih slojeva i stabilnijeg procesa treniranja.

Iako je WGAN-GP arhitektura naprednija i omogućuje stabilnije treniranje, u ovom eksperimentu ostvarila je slabije rezultate od DCGAN-a. To može biti posljedica homogenog i kontroliranog skupa podataka, gdje DCGAN konvolucijski pristup učinkovitije uči lokalne teksture listova. Također, WGAN-GP zahtijeva pažljivo podešavanje hiperparametara, a njegova orijentacija prema stabilnosti treniranja može dovesti do izgubljenih finih detalja koje DCGAN uspješno reproducira.

Uz kvantitativne metrike, provedena je i vizualna analiza generiranih slika za sve promatrane modele. Slika 4.1 prikazuje uzorke sintetiziranih slika raspoređene u tri reda po pet primjera. Prvi red prikazuje slike generirane osnovnim GAN modelom, drugi red odgovara DCGAN arhitekturi, dok treći red prikazuje uzorke generirane pomoću WGAN-GP modela.

Vizualni rezultati dodatno potvrđuju nalaze dobivene kvantitativnom evaluacijom. Osnovni GAN generira slike slabije kvalitete, s izraženim zamućenjima, neprirodnim bojama i nedovoljno definiranom strukturom listova. DCGAN pokazuje znatno poboljšanje u oštadini i realističnosti uzoraka, s jasnije izraženim oblicima i teksturama. WGAN-GP generira stabilnije i konzistentnije slike u odnosu na osnovni GAN, no u usporedbi s DCGAN-om zadržava manju razinu detalja i povremene vizualne artefakte.



Slika 4.1: Prikaz generiranih slika u tri reda, svaki red predstavlja jedan model

5. Zaključak

U radu je provedena usporedna analiza triju generativnih suparničkih mreža, osnovnog GAN-a, DCGAN-a i WGAN-GP, u kontekstu generiranja slika listova vinove loze. Rezultati pokazuju da osnovni GAN ostvaruje najslabije performanse, dok WGAN-GP omogućuje stabilnije treniranje i umjereno poboljšanje kvalitete generiranih slika. Najbolje rezultate postigao je DCGAN, s najnižim vrijednostima FID i KID te najvišom IS vrijednosti, čime se potvrđuje učinkovitost konvolucijskih arhitektura u generiranju slikovnih podataka.

Važno je istaknuti da su korištene slike snimane u kontroliranim uvjetima s homogenom pozadinom i ujednačenim osvjetljenjem, što može ograničiti generalizaciju modela na stvarne terenske uvjete vinograda, gdje su prisutne varijacije u osvjetljenju, pozadini i položaju listova.

Buduća istraživanja mogu se usmjeriti na treniranje generativnih modela na realističnijim skupovima podataka prikupljenima u prirodnim uvjetima, primjenu naprednijih arhitektura poput StyleGAN arhitekture i difuzijskih modela te analizu utjecaja sintetičkih slika na poboljšanje performansi klasifikacijskih sustava za detekciju bolesti vinove loze. Dodatna optimizacija hiperparametara i evaluacija na većem broju uzoraka također bi mogla doprinijeti pouzdanijim rezultatima.

6. Popis literature

1. Arjovsky, M., Chintala, S., & Bottou, L. (2017). Wasserstein GAN. In Proceedings of the International Conference on Machine Learning (ICML).
2. Bińkowski, M., Sutherland, D. J., Arbel, M., & Gretton, A. (2018). Demystifying MMD GANs. In International Conference on Learning Representations (ICLR).
3. Douarre, S., Le Guen, M., Maréchal, M., Bouvier, A., & Bensmail, M. (2019). Plant disease detection using generative adversarial networks. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.heliyon.2025.e43002>
4. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. In *Advances in Neural Information Processing Systems (NeurIPS)*.
5. Han, G., Asiedu, D. K. P., & Bennin, K. E. (2025). Plant disease detection with generative adversarial networks. *Heliyon*, 11(7), e43002. <https://doi.org/10.1016/j.heliyon.2025.e43002>
6. Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs trained by a two time-scale update rule converge to a local Nash equilibrium. In *Advances in Neural Information Processing Systems*, 30, 6626–6637.
7. Liu, B., Tan, C., Li, S., He, J., & Wang, H. (2020). A data augmentation method based on generative adversarial networks for grape leaf disease identification. *IEEE Access*, 8, 102188–102198. <https://doi.org/10.1109/ACCESS.2020.2998839>
8. Markota, K., Gan_Paper, GitHub repozitorij, 2026. Dostupno na: https://github.com/kresimirmarkota/Gan_Paper
9. Metz, L., Poole, B., Pfau, D., & Sohl-Dickstein, J. (2017). Unrolled generative adversarial networks. In International Conference on Learning Representations (ICLR).
10. Radford, A., Metz, L., & Chintala, S. (2016). Unsupervised representation learning with deep convolutional generative adversarial networks. In International Conference on Learning Representations (ICLR).
11. Salimans, T., Goodfellow, I., Zaremba, W., Cheung, V., Radford, A., & Chen, X. (2016). Improved techniques for training GANs. In *Advances in Neural Information Processing Systems*, 29, 2234–2242.
12. Wang, C., Xia, Y., Xia, L., Wang, Q., & Gu, L. (2025). Dual discriminator GAN-based synthetic crop disease image generation for precise crop disease identification. *Plant Methods*, 21, Article 46. <https://doi.org/10.1186/s13007-025-01361-0>
13. Yeo, S. (2024). Grape vine leaf disease dataset. Kaggle. <https://www.kaggle.com/datasets/stefanyeo/grape-vine-leaf-disease>
14. Zhang, Y., Yang, H., Li, X., Chen, Y., & Zhang, D. (2021). Super-resolution generative adversarial networks for wheat stripe rust disease classification. *Computers and Electronics in Agriculture*, 186, Article 106208. <https://doi.org/10.1016/j.compag.2021.106208>

15. Zhao, Y., Wang, M., Zhang, H., Li, J., & Huang, C. (2022). A two-step machine learning approach for crop disease detection using GAN and UAV imagery. *Remote Sensing*, 14(19), Article 4765. <https://doi.org/10.3390/rs14194765>
16. Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., & Hochreiter, S. (2017). GANs trained by a two time-scale update rule converge to a local Nash equilibrium. In *NeurIPS 2017*, 6626–6637.
17. Salimans, T., et al. (2016). Improved techniques for training GANs. In *NeurIPS 2016*, 2234–2242.

Comparison of Generative Adversarial Networks for Grapevine Leaf Image Synthesis

Abstract: *In recent years, Generative Adversarial Networks (GANs) have become one of the most significant approaches for image synthesis in the field of deep learning. Their application is particularly interesting in agriculture, where artificially generated data can contribute to the development of more robust systems for classification, disease detection, and dataset augmentation. This study investigates the use of GANs for generating images of grapevine leaves and conducts a comparative analysis of three GAN-based architectures: the basic GAN, Deep Convolutional GAN (DCGAN), and Wasserstein GAN with gradient penalty (WGAN-GP). The experimental part of the study is based on a dataset of real grapevine leaf images that were preprocessed and normalized for model training. Each model was trained separately, and the generated synthetic images were used for quantitative evaluation of generation quality. Standard metrics were employed to assess the similarity between real and generated images: Frechet Inception Distance (FID), Kernel Inception Distance (KID), and Inception Score (IS), which are commonly used in the analysis of generative models.*

The results show that DCGAN achieves the best performance among the analyzed models, with the lowest FID and KID values and the highest Inception Score, indicating more stable training and higher quality generated images. WGAN-GP achieves intermediate results, while the basic GAN model exhibits the lowest performance, consistent with findings reported in similar studies. In conclusion, the results confirm that advanced GAN architectures provide significant advantages in generating realistic grapevine leaf images and have potential for further application in agricultural and computer vision systems.

Keywords: *Generative Adversarial Networks, DCGAN, WGAN, image synthesis, grapevine leaf, quality evaluation*