Simulacijska optimizacija konstrukcije u svrhu smanjenja mase

Golešić, Maja

Undergraduate thesis / Završni rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Karlovac University of Applied Sciences / Veleučilište u Karlovcu**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:128:650649

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

VELEUČILIŠTE U KARLOVCU
Karlovac University of Applied Sciences

Repository / Repozitorij:

Repository of Karlovac University of Applied Sciences - Institutional Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

VELEUČILIŠTE U KARLOVCU
STROJARSKI ODJEL
Stručni studij Strojarstva

Maja Golešić

SIMULACIJSKA OPTIMIZACIJA KONSTRUKCIJE U SVRHU SMANJENJA MASE

Završni rad

Karlovac, 2015.

VELEUČILIŠTE U KARLOVCU
STROJARSKI ODJEL
Stručni studij Strojarstva

Maja Golešić

SIMULACIJSKA OPTIMIZACIJA KONSTRUKCIJE U SVRHU SMANJENJA MASE

Završni rad

Mentor:
Mag.ing.stroj. Josip Groš

Karlovac, 2015.

Izjavljujem da sam ovaj rad izradila samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem se svojim roditeljima na beskrajnom strpljenju i potpori tjekom svih ovih godina studiranja.

Zahvaljujem se svim kolegama i prijateljima na savijetima i pomoći tijekom studiranja.

Maja Golešić

Mjesto gdje se postavlja zadatak završnog rada kojeg dobivate kod mentora!

SADRŽAJ

SADRŽAJ I
POPIS SLIKA III
SAŽETAK VI
1. UVOD 1
1.1 Općenito 1
1.2 CATIA 1
2. CATIA MODUL 3
2.1 CATIA modul „ Product Engineering Optimizer“ 3
2.2 Optimization 5
2.2.1 Kartica „Problem“ 6
2.2.2. Kartica „Constraints“ 8
2.2.3. Kartica „Computations results“ 11
2.3 Design Of Experiments 14
2.3.1. Kartica „Settings“ 15
2.3.2. Kartica „Results“ 17
2.3.3. Kartica „Prediction“ 19
3. PRIMJERI OPTIMIZACIJE 22
3.1 Optimiranje grede 22
3.2 Optimiranje boce 33
3.3 Optimiranje nosača 39
3.4 Optimiranje I-grede 46
3.5 Optimiranje viličastog nosača 51
4. ZAKLJUČAK 62

PRILOZI..... 63
LITERATURA 64

POPIS SLIKA

Slika 1. Odabir modula PEO 4
Slika 2. Alatna traka PEO-a 4
Slika 3. Izgled prozora za optimiranje 6
Slika 4. Definiranje raspona i koraka 7
Slika 5. Izgled kartice „Constraints“ 9
Slika 6. Odabir parametara ograničenja 10
Slika 7. Izgled kartice „Computations results“ 11
Slika 8. Sortiranje rezultata 12
Slika 9. Odabir parametra krivulja 13
Slika 10. Prikaz krivulja 13
Slika 11. Povezanost sustava 14
Slika 12. Izgled kartice „Settings“ 15
Slika 13. Odabir parametara 16
Slika 14. Prikaz čvora 17
Slika 15. Izgled kartice „Results“ 18
Slika 16. Prikaz krivulja u DOE 19
Slika 17. Prikaz kartice „Prediction“ 20
Slika 18. Dimenzije grede 22
Slika 19. Izgled grede 22
Slika 20. Izgled alatne trake i ikone „Formula“ 23
Slika 21. Izrada parametara 23
Slika 22. Prikaz parametara u drvu 24
Slika 23. Povezivanje parametra i dimenzija 25
Slika 24. Prikaz povezanih parametara s dimenzijama 26
Slika 25. Prikaz raspodijele opterećenja na gredi 27
Slika 26. Prikaz odabranih „Sensors“ 27
Slika 27. Prikaz parametara u DOE 28
Slika 28. Definiranje raspona i koraka 29

Slika 29. Rezultati DOE u Micorsoft Excel tablici 29
Slika 30. Utjecaj ulaznih parametara na naprezanje 30
Slika 31. Uvjeti optimizacije grede 31
Slika 32. Izgled optimirane grede 32
Slika 33. Izgled i parametri boce 34
Slika 34. Rezultati za „Gradient Algorithm Without Constrain“ 36
Slika 35. Rezultati za „Simulated Annealing Algorithm“ 37
Slika 36. Usporedba konačnih rezultata optimiranja za oba algoritma 38
Slika 37. Prikaz dimenzija koje će se optimirati 39
Slika 38. FEM analiza nosača 40
Slika 39. Izgled nosača i rezultati dobiveni „fast“ brzinom 41
Slika 40. Prikaz krivulja dobivenih „fast“ brzinom 42
Slika 41. Izgled nosača i rezultati dobiveni „medium“ brzinom 42
Slika 42. Prikaz krivulja dobivenih „medium“ brzinom 43
Slika 43. Izgled nosača i rezultati dobiveni „slow“ brzinom 43
Slika 44. Prikaz krivulja dobivenih „slow“ brzinom 44
Slika 45. Izgled nosača i rezultati dobiveni „infinite“ brzinom 44
Slika 46. Prikaz krivulja dobivenih „infinite“ brzinom 45
Slika 47. Prikaz izgleda i parametara I-grede 46
Slika 48. Rezultati optimizacije I-grede u Micorsoft Excel tablici 48
Slika 49. Prikaz odstupanja rezultata od traženih zahtjevima 49
Slika 50. Konačan izgled i rezultati optimirane I-grede 50
Slika 51. Izgled i parametri viličastog nosača 51
Slika 52. Prikaz parametara „veliki r“ i „ mali r“ 52
Slika 53. Prikaz parametra „dubina utora“ 52
Slika 54. FEM analiza viličastog nosača 53
Slika 55. Izgled i rezultati prve optimizacije viličastog nosača 55
Slika 56. Tablica s rezultatima prve optimizacije 56
Slika 57. Izgled i rezultati druge optimizacije viličastog nosača 57

Slika 58. Tablica s rezultatima druge optimizacije 58
Slika 59. Izgled i rezultati treće optimizacije viličastog nosača 59
Slika 60. Tablica s rezultatima treće optimizacije 60
Slika 61. Rezultati nakon ponovljene FEM analize 61

SAŽETAK

U završnom radu opisan je i analiziran CATIA modul za optimiranje„Product Engineering Optimizer“.

Prvi dio podijeljen je u dvije velike cjeline „Optimization“ i „Design Of Experiments“. U obje cjeline su detaljno opisani i objašnjeni svrha i značenje svakog dijela prilikom postavljanja problema bilo optimizacije u „Optimization“ ili virtualnog testa u „Design Of Experiments“.

U drugom dijelu je kroz primjere prikazan rad u „Optimization“ i „Design Of Experiments“. Prikazane su mogućnosti i varijacije u konačnim rezultatima optimizacije s obzirom na odabir postavki.

1. UVOD

1.1 Općenito

U današnje vrijeme zbog globalne konkurentnosti traži se da projektirani proizvod osim bezprijekorne funkcionalnosti bude i najbolji među konkurentima.

Kriteriji koji igraju veliku ulogu u tome su: dimenzije, vrijeme izrade, kompatibilnost, pouzdanost, trajnost, težina i cijena.

Stoga veliku važnost u izradi proizvoda ima optimizacija. Osnovni cilj optimizacije je naći najbolje rješenje za zadane uvjete..

Optimiranje nije samo proces i način postavljanja inženjerskog zadatka već i alat koji pomaže u donošenju odluka u najširem smislu. Inženjeri su oduvijek pokušavali intuitivnim putem optimirati procese, no takav način je vrlo subjektivan i podložan greškama. Postupci intuitivnog optimiranja baziraju se na intuiciji, profesionalnom iskustvu, brojnim pokušajima itd.

Danas je uz odgovarajuće algoritme, programske alate i uz primjenu računala velike snage moguće je optimiranje temeljeno na računalnoj simulaciji fizičkih modela.

Prednosti virtualnih modela je ta što su izrada i analiza naspram fizičkih modela jeftiniji i ušteda vremena je velika.

Postupci optimiranja primjenjuju se u cijelom nizu linearnih i nelinearnih problema, takvi su i problemi optimiranja mehaničkih konstrukcija.

U završnom radu prikazati će se mogućnosti optimiranja u programskom paketu Catia.

1.2 CATIA

CATIA je skraćenica od Computer-aided Three-dimensional Interactive Application (računalom podržan, trodimenzionalni interaktivni programski paket). [1]

Program je razvijen od strane tvrtke pod imenom Dassault Systemes u ranim osamdesetim godinama prošlog stoljeća, prvenstveno za potrebe avio industrije.

Program je dalje razvijan uz podršku tvrtke IBM.

Mogućnosti CATIA-e su ogromne jer osim crtanja strojnih elemenata omogućuje njihovo proračunavanje s obzirom na čvrstoću odabranih materijala, izradu NC programa za NC i CNC strojeve, simulaciju obrade i niz drugih pogodnosti važnih u zamišljanju određenog proizvoda i njegovoj izradi.

Najviše se koristi u brodogradnji, avio i auto industriji, te drugim industrijskim granama.

2. CATIA MODUL

CATIA se sastoji od modula. Svaki modul je specijaliziran za određeno područje dizajna. Najpoznatiji moduli su Sketcher, Part Design, Assembly, Stress Analysis, Drafting, Simulation...[2]

2.1 CATIA modul „ Product Engineering Optimizer“

„Product Engineering Optimizer“ je modul namjenjen za optimizaciju. Koristeći se iterativnim metodama omogućuje optimiranje bilo kojeg parametra.[3]

Nudi mogućnost: -optimiranja baziranog na geometriji modela

-optimiranja baziranog na metodi konačnih elemenata

-virtualnih testiranja (DOE) u svrhu dobivanja informacija o ponašanju modela u zadanim uvjetima

-rješavanje problema ispunjenjem zadanih ograničenja [4]

Pristup „Product Engineering Optimizer“ radnom okruženju je preko Start menija, spuštanjem mišem do Knowledgeware, otvara se dodatni padajući meni u kojem će se kliknuti na „Product Engineering Optimizer“ (Slika 1).

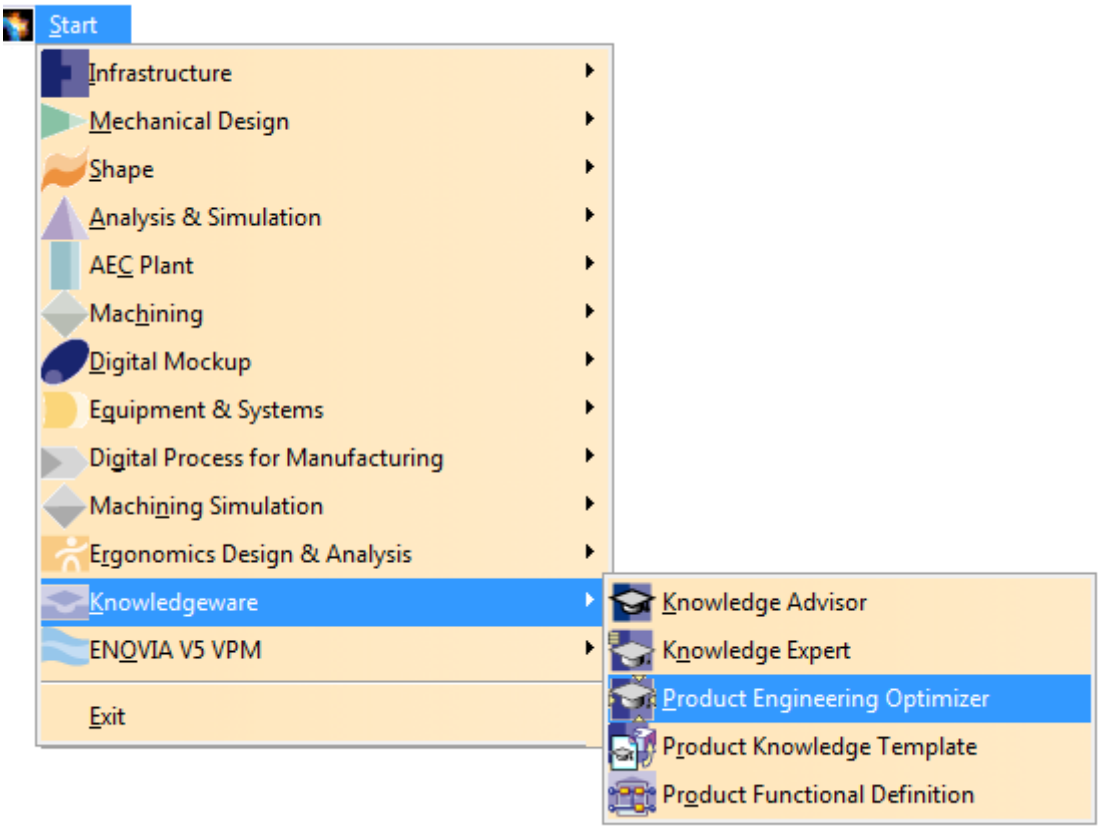

Slika 1. Odabir modula PEO

Izgled samog radnog okruženja je promijenjen u smislu novih alatnih traka, na kojima se nalaze alati čija svrha je pomoći korisniku da na što lakši način dođe do traženih rezultata. U ovom slučaju optimira željeni model.

Na slici (Slika 2) vidi se izgled alatne trake i ikona za „Product Engineering Optimizer“.

Slika 2. Alatna traka PEO-a

2.2 Optimization

Ovaj alat omogućuje optimiranje modela, na način da mu se nađe najmanja, najveća ili tražena vrijednost određenog parametra. To može biti masa, volumen, naprezanje i sl.

Kako bi se došlo do traženog rezultata, zadati će se koje dimenzije se smiju mijenjati i kojih se uvjeta mora pridržavati.

Nakon što se pristupilo „Product Engineering Optimizer“ radnoj površini, mišem će se kliknuti na ikonu „Optimization“.

Automatski se otvara prozor na kojem se nalaze tri kartice: „Problem“, „Constraints“ i „Computated results“ (Slika 3)

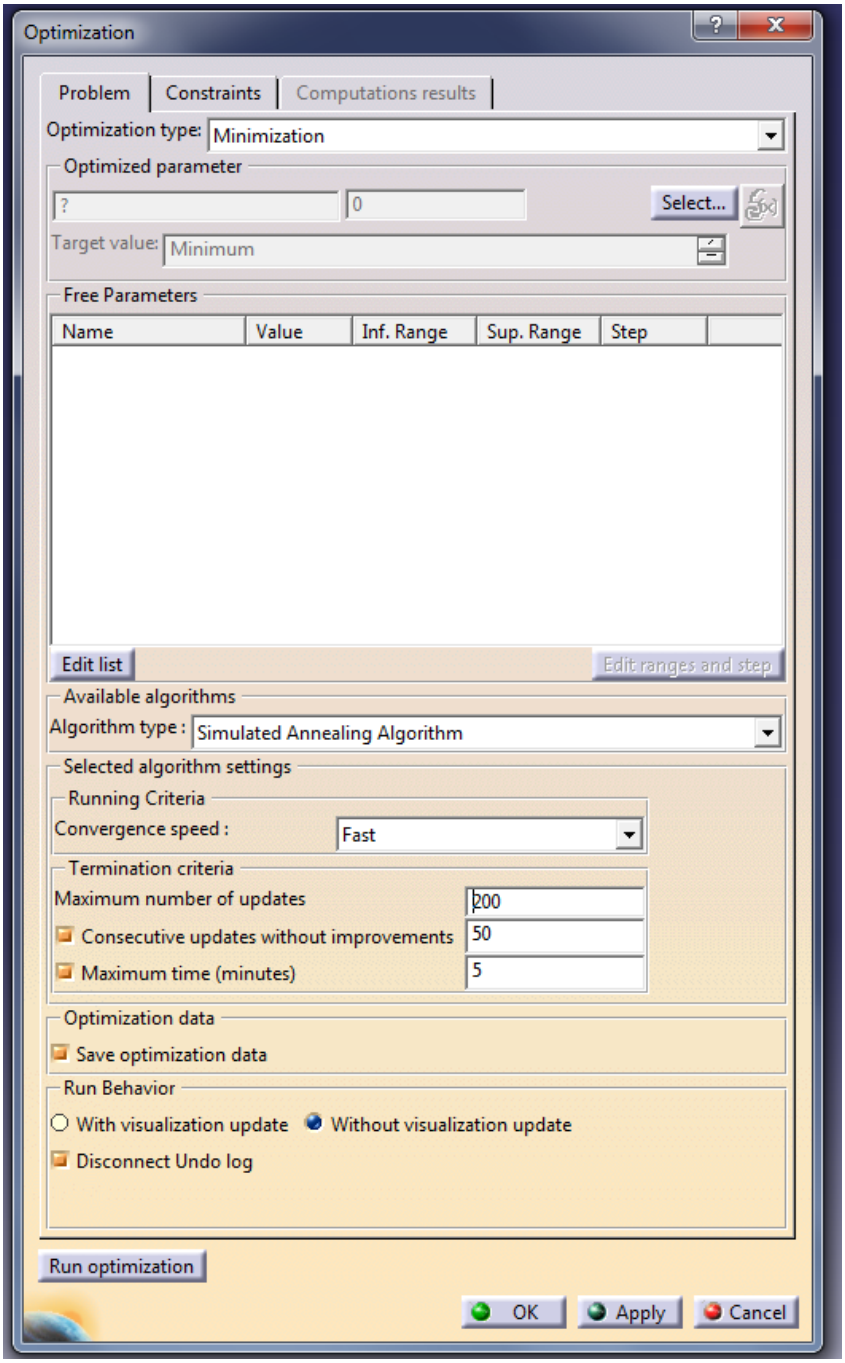

Slika 3. Izgled prozora za optimiranje

2.2.1 Kartica „Problem“

Na kartici „Problem“ pod „Optimization type“ definira se tip optimizacije („Minimization“, „Maximization“ , „Target Value“ ili „Only constraints“). Time se određuje da li je tražena najmanja, najveća, ciljana (točna) vrijednost ili optimiranje se vrši isključivo bazirajući se na zadane uvjete.

Nakon toga bira se parametar koji će se optimirati, tj. čija maksimalna, minimalna ili ciljana vrijednost se traži.

Pod „Free Parameters“ se definiraju dimenzije čijom promjenom vrijednosti će se doći do željenog rezultata.

Za svaku od dimenzija može se definirati raspon (vrijednost „od-do“) (na slici označeno s 1) i korak (podijela) (na slici označeno s 2) (Slika 4). Podjelom se određuje kako će se ta dimenzija uzeti u obzir prilikom proračuna optimizacije. Prevelik korak je beskoristan a mali korak može spriječiti brzu konvergenciju rješenja. Ako nismo sigurni, ne definiramo korak , ali odredimo raspone dimenzija.

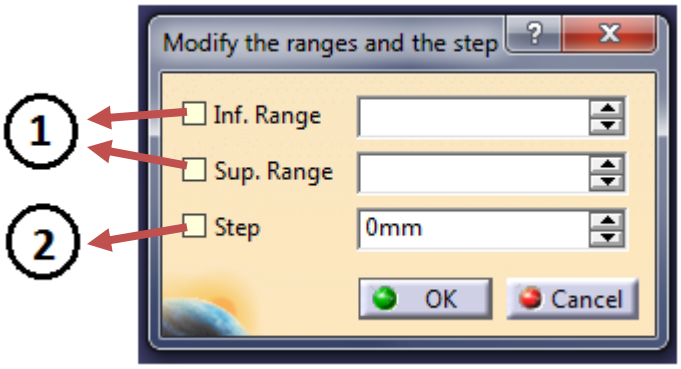

Slika 4. Definiranje raspona i koraka

Nakon toga definira se tip algoritma po kojem će se optimirati.

Na raspolaganju ima pet tipova algoritama, koje se može podijeliti na dvije velike cjeline s obzirom na način pretraživanja podataka.

To je „Simulated Annealing Algorithm“ koji vrši globalnu pretragu podataka koja kako vrijeme prolazi prelazi u lokalno pretraživanje. Svi uvjeti i ograničenja u algoritam se uvode odjednom. Obično se koristi kod nelinearnih, diskontinuiranih funkcija, te se preporučuje korištenje kada je nepoznat oblik funkcije.

„Local Algorithm For Constraints and Priorities“, „Algorithm For Constraints and Derevities Providers“, „Gradient Algorithm Without Constraint“ i „Gradient Algorithm With Constraint(s)“ su algoritmi koji vrše lokalno pretraživanje podataka. Za korištenje ovih algoritama sva ograničenja moraju biti diferencijabilna i svojstva funkcije poznata. Dolaze brže do rezultata nego „Simulated Annealing Algorithm“, ali rade na manjem opsegu funkcija.

Idući korak je odabir brzine konvergencije. Što je brzina sporija rezultati optimizacije su točniji, ali ukupan broj rješenja je manji.

Pod „Termination Criteria“ određuje se maksimalni broj iteracija, broj iteracija bez poboljšanja rezultata i maksimalno vrijeme trajanja optimizacije.

Označavanjem „Save optimization data“ svi rezultati će biti spremljeni u excel datoteku.

Također može se izabrati između „With vizualization update“ ili „Without vizualization update“ s čime se određuje, da li će se vidjeti proces optimizacije na modelu u toku samog proračuna.

2.2.2. Kartica „Constraints“

Na ovoj katrici određuju se uvjeti i ograničenja koja se uzimaju u obzir prilikom proračuna, a bitna su za konačni rezultat optimizacije (Slika 5).

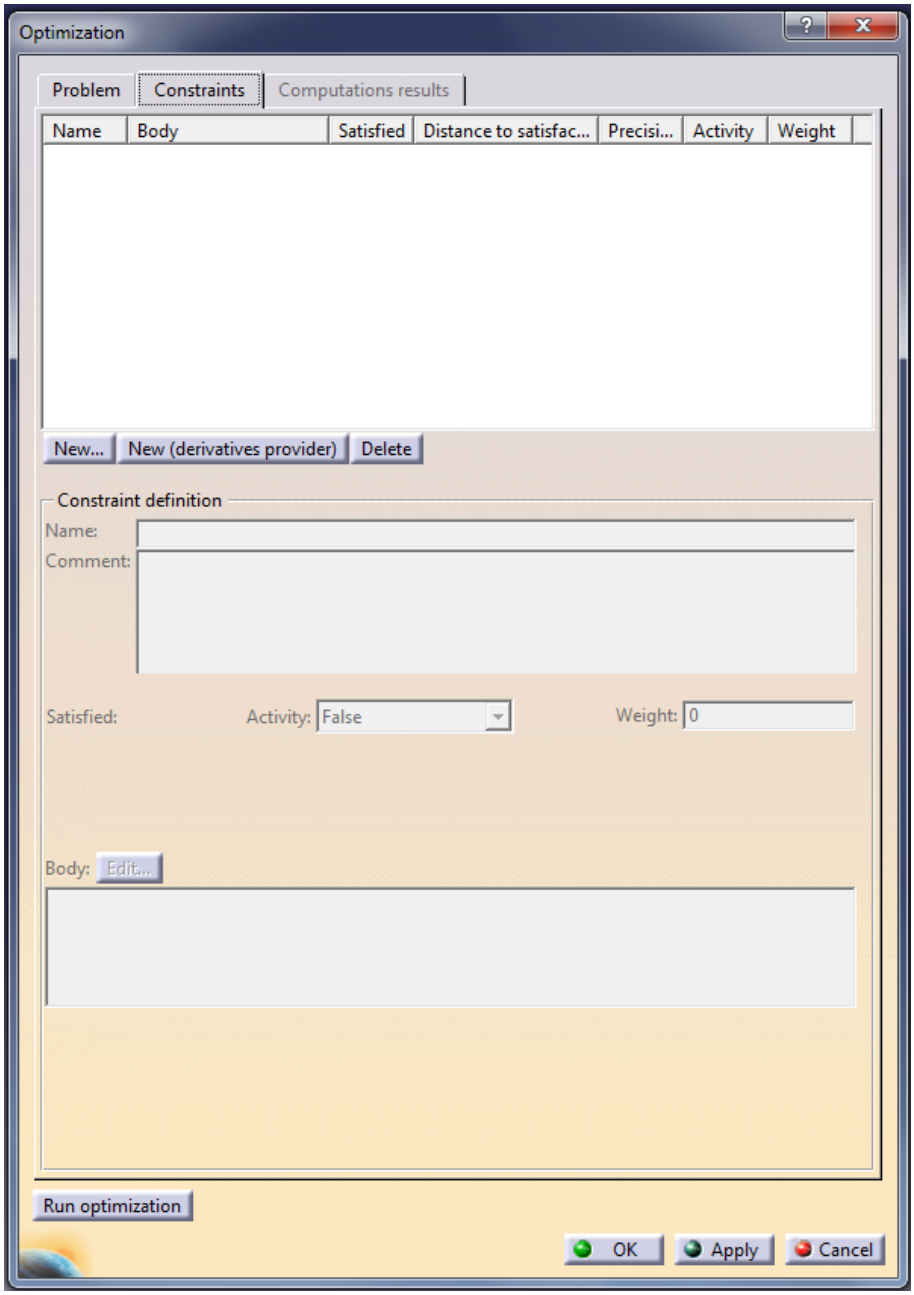

Slika 5. Izgled kartice „Constraints“

Pritiskom na „New“ otvara se novi prozor s popisom svih parametara koji se mogu iskoristiti za definiranje ograničenja (Slika 6).

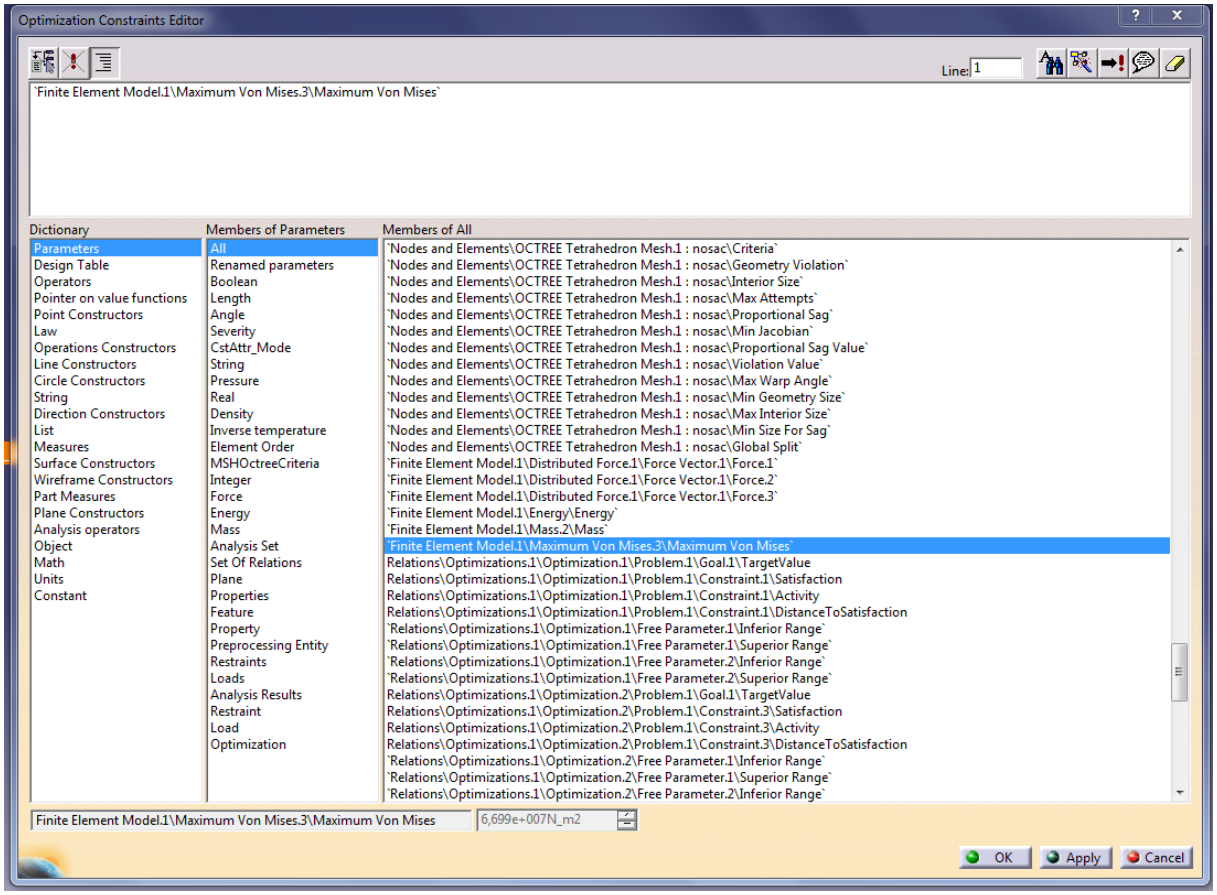

Slika 6. Odabir parametara ograničenja

Nakon što je parametar izabran, znakovima (<, > ili ==) definira se odnos trenutne veličine s onom koju želimo postići.

Također može se postaviti odnos između parametra među sobom (npr. Visina-Širina>0mm). Pritiskom na „OK“ ograničenje je upisano u glavni prozor na kartici „Constraints“.

Uz ograničenje može se vidjeti da li je ono ispunjeno i prije početka same optimizacije. Ako nije, kolika je brojčana razlika do ispunjenja tog uvjeta.

Za svako ograničenje može se definirati odstupanje od traženog rezultata.

Aktivirati, odnosno deaktivirati pojedina ograničenja. Ako su deaktivirana, neće biti uzeta u obzir prilikom proračuna.

Pod „weight“ se određuje važnost pojedinog ograničenja upisivanjem broja. Povećanjem broja raste i prioritet ograničenja.

Ograničenja se upisuju isključivo pojedinačno, jedno po jedno. Jednom kada su upisana redoslijed im se ne može mjenjati (jedino izbrisati).

2.2.3. Kartica „Computations results“

Nakon što je optimiranje završeno, na kartici „Computations results“ mogu se vidjeti dobivena rješenja (Slika 7).

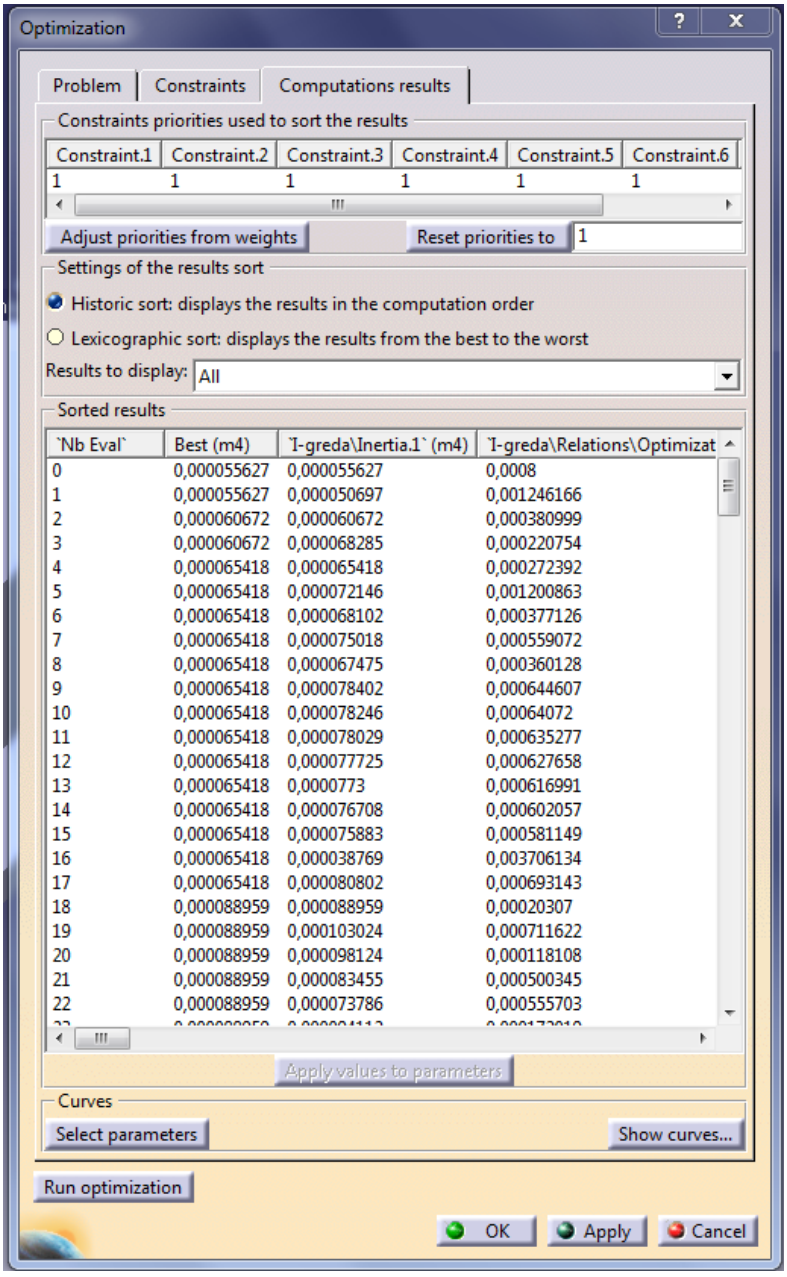

Slika 7. Izgled kartice „Computations results“

Rješenja su vidljiva jedino ako je prije početka optimiranja označen „Save optimization data“.

Označavanjem „Historic sort“ ili „Lexicographic sort“ određuje se prikaz rezultata. Da li će biti posloženi po redosljedu kojim su dobiveni prilikom optimiranja ili od najboljeg prema najgorem rješenju.

Lista s rezultatima može se dodatno sortirati odabirom koje od rezultata želimo vidjeti (Slika 8).

Slika 8. Sortiranje rezultata

„Apply these values to parameters“ omogućava da jedno od ponuđenih rješenja s liste (označi se red u kojem je) bude primjenjeno na model.

Pritiskom na „Select parameters“ otvara se prozor u kojem se odabiru parametri čije krivulje želimo vidjeti. Izabrati se mogu samo oni koji su bili u procesu optimizacije (Slika 9).

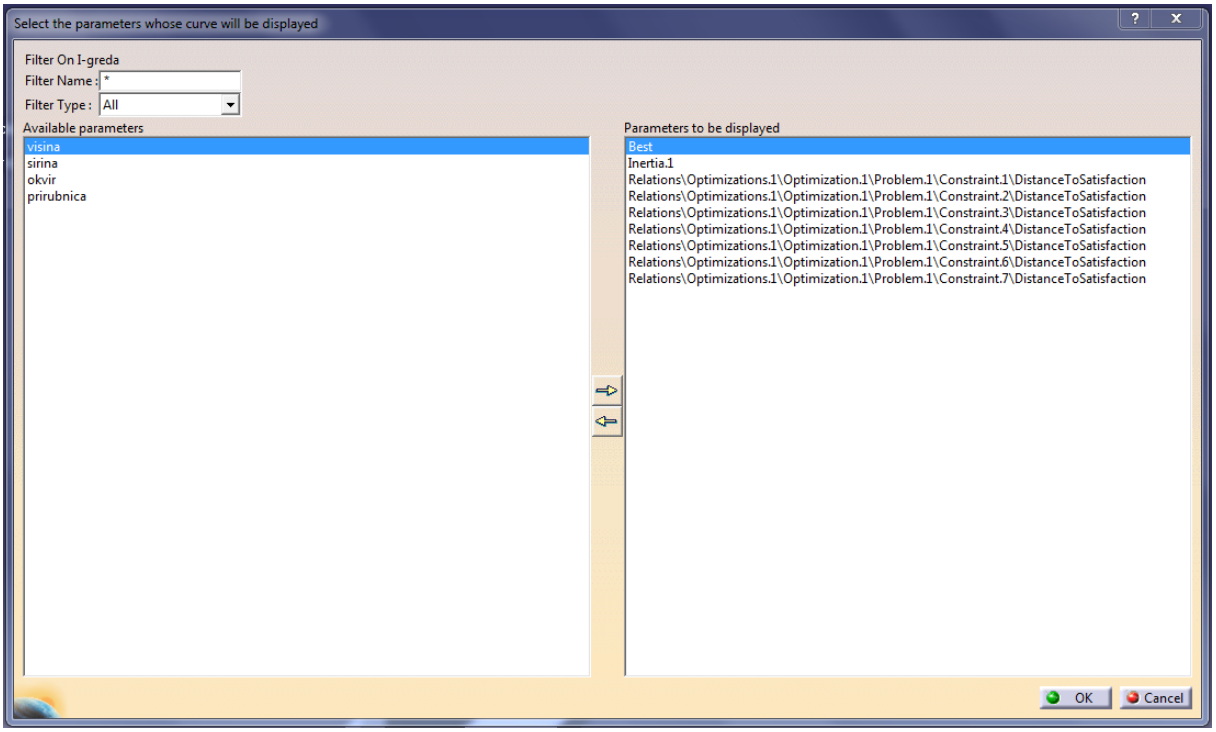

Slika 9. Odabir parametra krivulja

Pritiskom na „Show curves“ otvara se prozor u kojem su prikazane krivulje parametara, tj. kako su se njihove vrijednosti mjenjale kroz proces proračuna optimizacije (Slika 10).

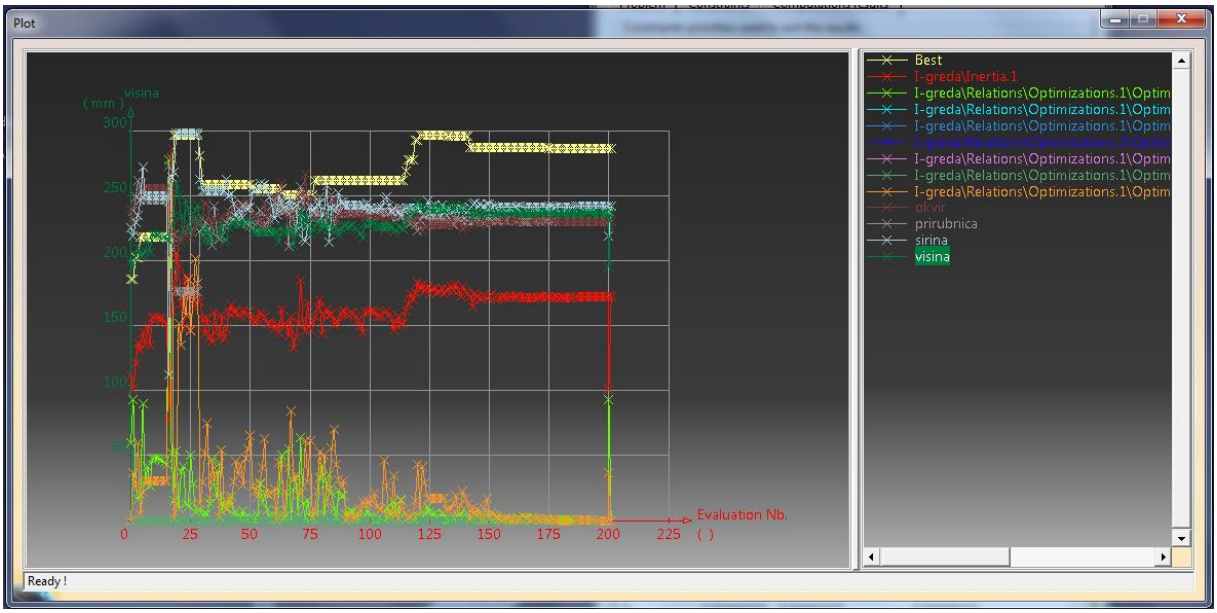

Slika 10. Prikaz krivulja

Na desnoj strani se nalazi popis svih parametara čije krivulje su prikazane. Svaki od parametara je označen posebnom bojom, tj. bojom kojom je napisan na desnoj strani, tom bojom je prikazan na lijevoj. Klikom na parametar na desnoj strani, naziv parametra se prikazuje na vrhu ordinate.

Grafikoni pomažu analizirati ponašanje funkcija i parametra tijekom optimizacije.

Zumiranjem dijagrama može se vidjeti da je sastavljen od točaka koje su međusobno povezane linijama. Svaka točka predstavlja jedno od rješenja s liste. Duplim klikom na točku otvara se prozor u kojem je usporedba trenutnih vrijednosti parametara s odabranima.

Također postoji mogućnost da se odabrani parametri iz dijagrama primjene na model.

2.3 Design Of Experiments

Ovaj alat daje mogućnost izrade virtualnih eksperimenata s proizvoljnim brojem parametara.

Daje uvid u: - međusobnu povezanost parametara

-radi predviđanja rezultata

- prepoznaje koji od parametara je najutjecajniji

Prikazuje kako promjena ulaznih parametara djeluje na cijeli sustav, odnosno na izlazne parametre (Slika 11).

Slika 11. Povezanost sustava

Pritiskom na ikonu „Design Of Experiments“ otvara se prozor s tri kartice: „Settings“, „Results“ i „Perdiction“.

2.3.1. Kartica „Settings“

Na ovoj kartici definira se koji su ulazni parametri i njihov raspon, odnosno od koje najmanje, pa do koje najveće brojčane vrijednosti će se provesti analiza. Također se određuje broj razina (čvorova) pojedinog ulaznog parametra, te izlazne parametre (Slika 12).

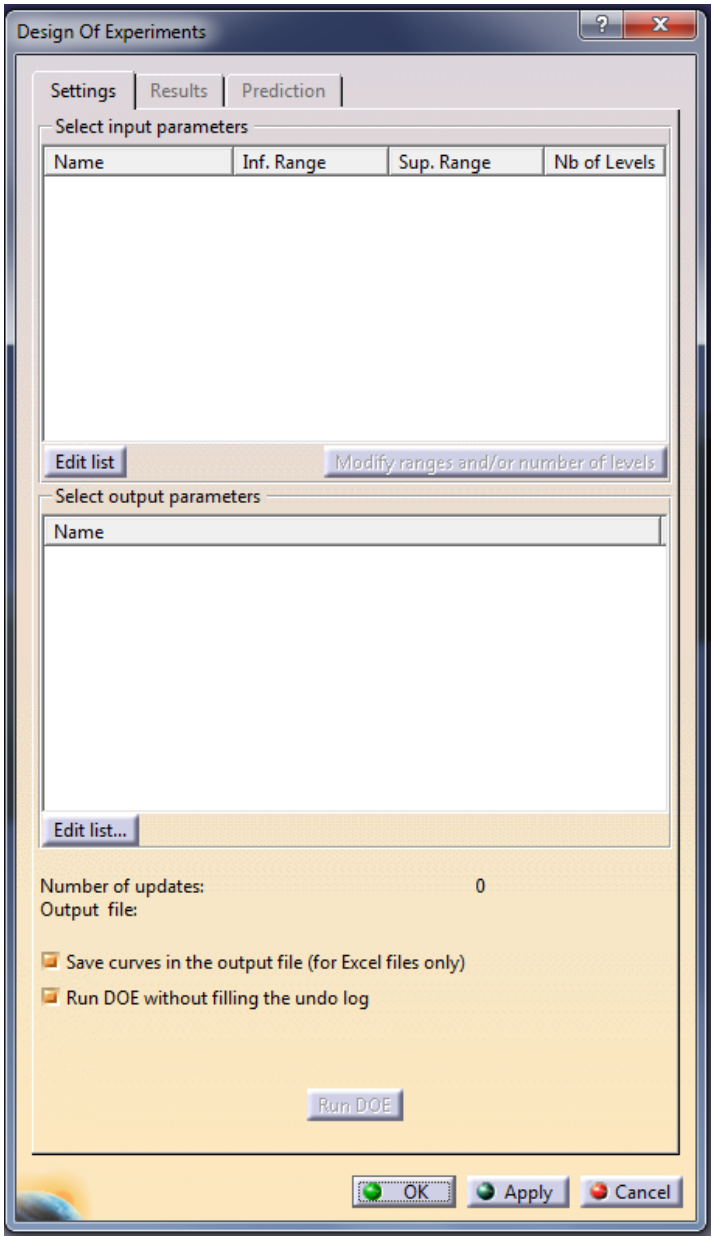

Slika 12. Izgled kartice „Settings“

Ulazni parametri su izabrani pritiskom na gumb „Edit list“.

Otvara se prozor na čijoj lijevoj strani se nalazi popis svih parametara. S popisa se označe željeni parametri, te uz pomoć strelice prebace na desnu stranu i potvrde s „OK“ (Slika 13).

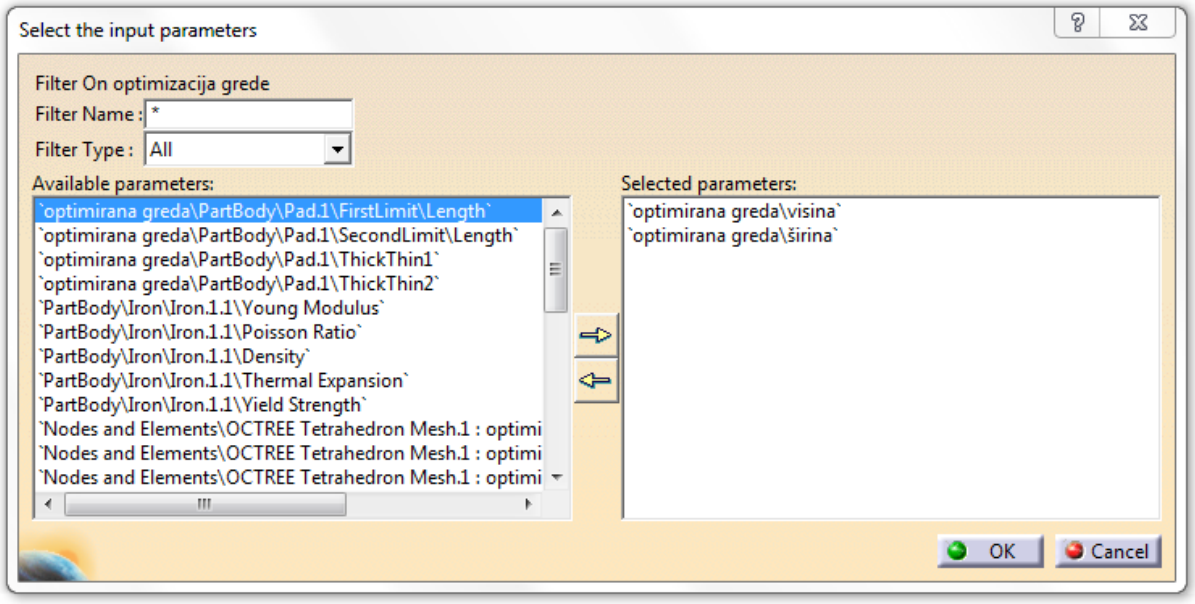

Slika 13. Odabir parametara

Nakon toga označiti će se ulazni parametar i kliknuti na gumb „Modify ranges and/or number of levels“ da bi se definirao raspon minimalne i maksimalne vrijednosti i broj razina (čvorova) (Slika 14).

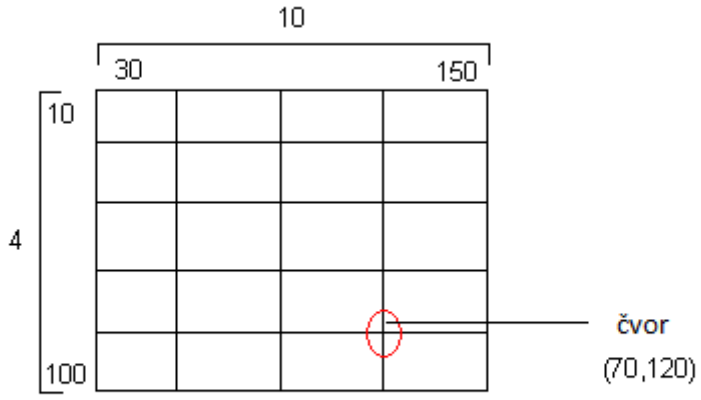

Slika 14. Prikaz čvora

Ukupan broj rješenja u analizi je jednak umnošku svih brojeva razina. Na slici (Slika 14) to je 40.

Izlazni parametri izabrani su na jednak način kao i ulazni.

Označavanjem „Save curves in the output file“ svi dobiveni rezultati biti će spremljeni u excel datoteku.

2.3.2. Kartica „Results“

Ova katrica je jedino viđljiva nakon što je analiza završena (Slika 15).

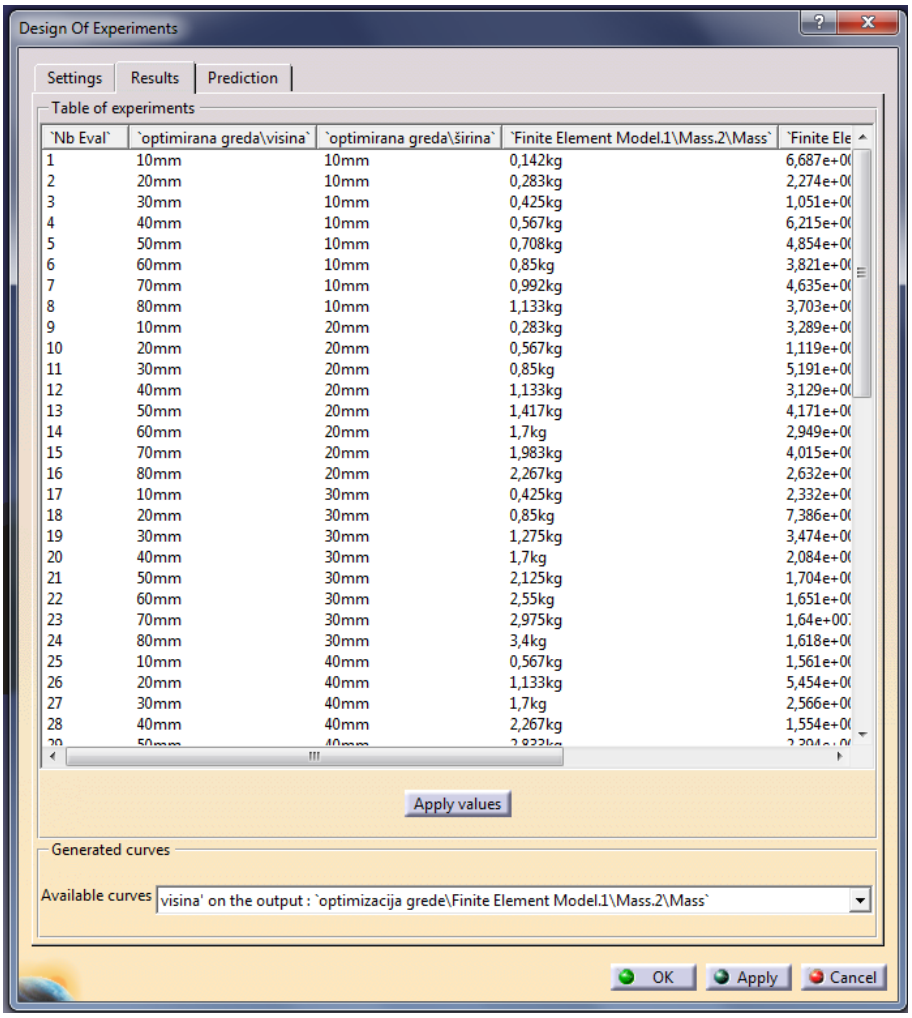

Slika 15. Izgled kartice „Results“

Prikazani rezultati su dobiveni analizom svakog čvora.

Označavanjem željenog rezultata s liste i klikom na gumb „Apply values“, dobivene vrijednosti su primjenjene na model.

Također pomoću krivulja moguće je vidjeti kako pojedini ulazni parametar ima utjecaj na pojedini izlazni i/ili kako svi ulazni parametri imaju utjecaj na pojedini izlazni. Krivulje se izabiru pod „Available curves“. Traženi prikaz krivulja vidi se u zasebnom prozoru (Slika 16).

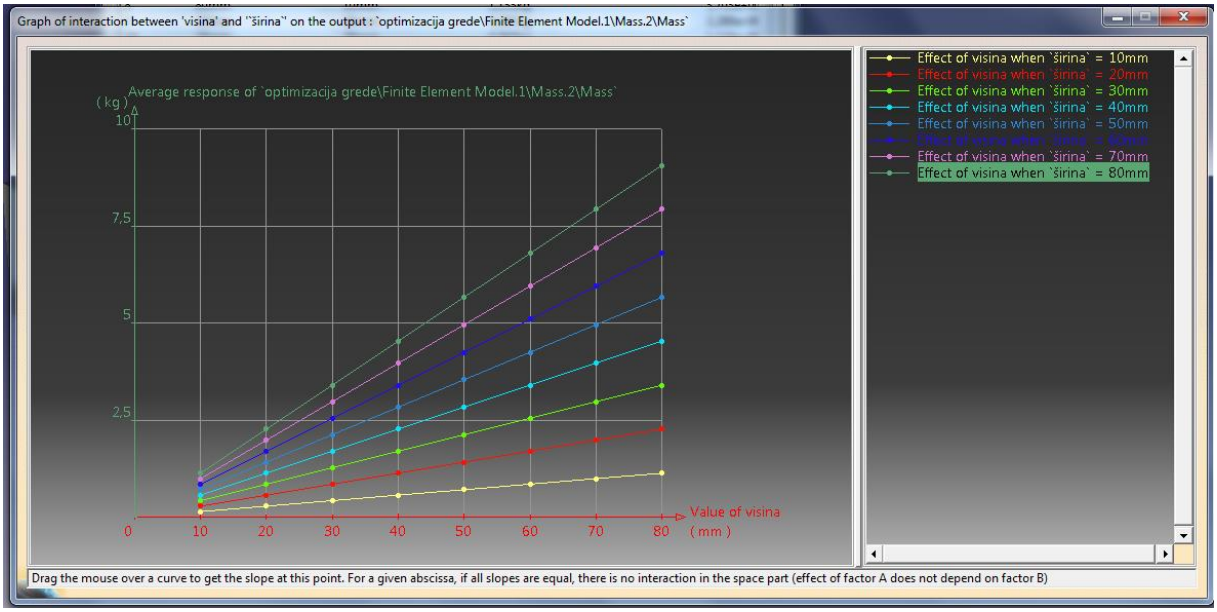

Slika 16. Prikaz krivulja u DOE

2.3.3. Kartica „Prediction“

Ova kartica predstavlja matematički model koji se koristi za dobivanje teorijske vrijednosti izlazog parametra obzirom na specifičnu konfiguraciju ulaznih parametara.

Ona je također dostupna jedino nakon završene analize (Slika 17).

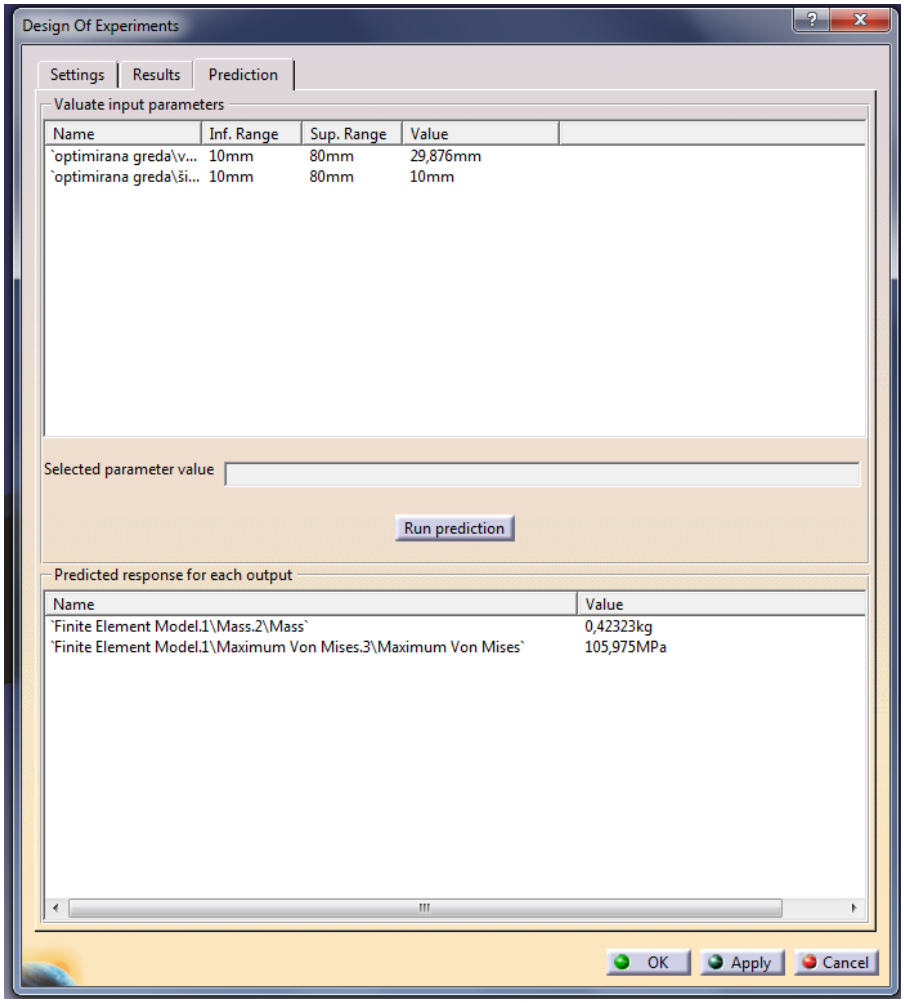

Slika 17. Prikaz kartice „Prediction“

Predviđanja se mogu dobiti na dva načina:

1. računanjem teorijske vrijednosti čvora:

   -na kartici „Results“ odabrati će se redak i kliknuti na „Apply values“

   -zatim na kartici „Prediction“ kliknuti na „Run prediction“

   -rezultati izlaznih parametara biti će prikazani u doljnjem prozoru (Slika 17)

2. računanje teorijske vrijednosti čvora unutar definiranog raspona (izvan mreže):

   -na kartici „Prediction“ označiti će se željeni parametar

-pod „Selected Parametar value“ upisati će se željena vrijednost i potvrditi s enter

-postupak se ponovlja na svim parametrima čija vrijednost se želi promjeniti

-nakon toga će se pritisnuti gumb „Run prediction“

-rezultati izlaznih parametara biti će prikazani u doljnjem prozoru (Slika 17)

3. PRIMJERI OPTIMIZACIJE

3.1 Optimiranje grede

U ovom primjeru će se na najednostavniji način pokazati kako optimirati gredu koja je na jednom kraju uklještena, a na drugom opterećena silom. Ali prvo će se u „Design Of Experiments“ provjeriti međusobni odnos i utjecaj parametara koji se kasnije žele iskoristiti u samom procesu optimizacije [5].

Prvi korak je modeliranje grede u „Part Design“ (Slika 18 i Slika 19).

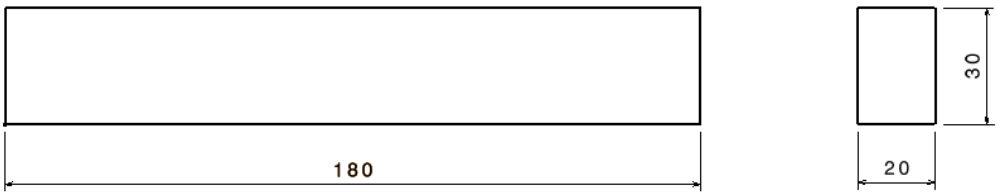

Slika 18. Dimenzije grede

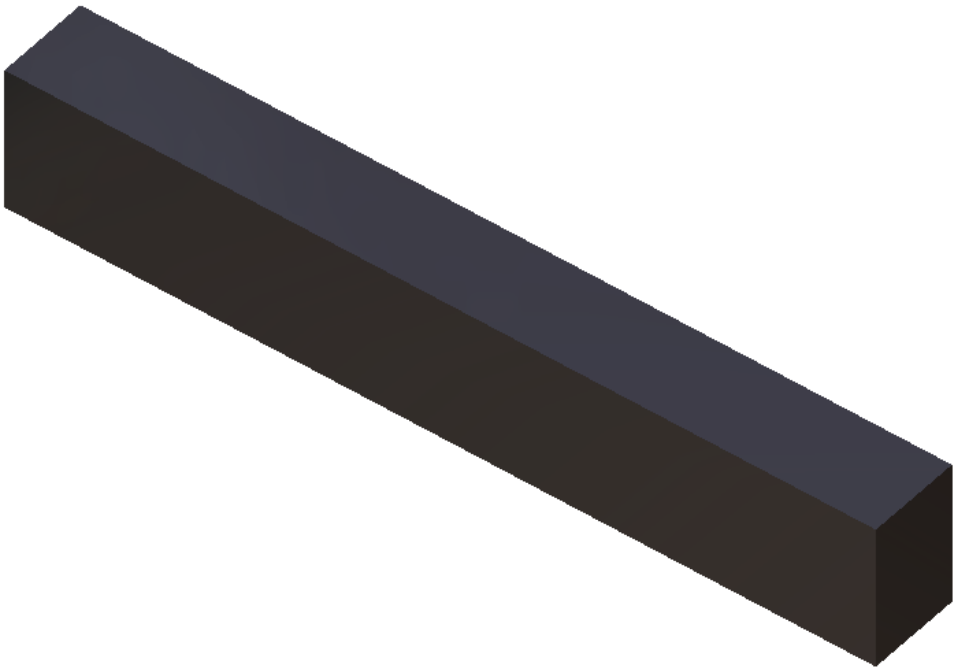

Slika 19. Izgled grede

Radi lakšeg snalaženja i boljeg pregleda, napravljeni su parametri za dimenzije koji će se kasnije optimirati. Parametri su kreirani na način da klikom miša na ikonu „Formula“ u prozoru će se izabrati tip parametra koji se želi napraviti (Slika 20 i Slika 21).

Slika 20. Izgled alatne trake i ikone „Formula“

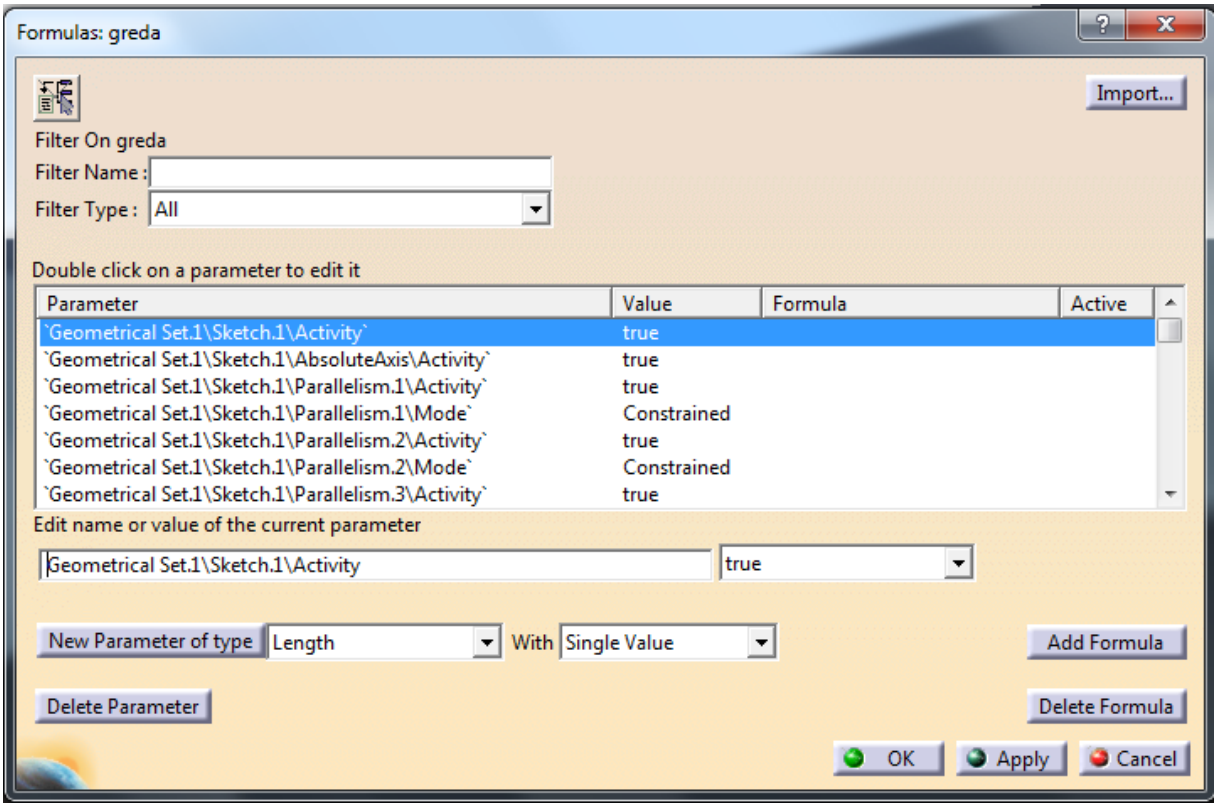

Slika 21. Izrada parametara

U ovom slučaju izabrani parametri su vezani za duljinu (lenght). Imena su im „visina“ i „širina“, te su im upisane željene brojčane vrijednosti. (Slika 22).

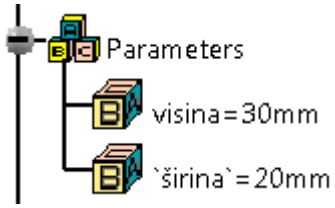

Slika 22. Prikaz parametara u drvu

Da bi se povezalo parametre s dimenzijama crteža, u „Sketcher“-u s desnim klikom tipke miša na dimenziju selektirati će se strelica uz „Offset object“ pa zatim kliknuti na „Edit Formula“. Otvorio se prozor u kojemu će se odrediti s kojim parametrom je ta dimenzija povezana (Slika 23).

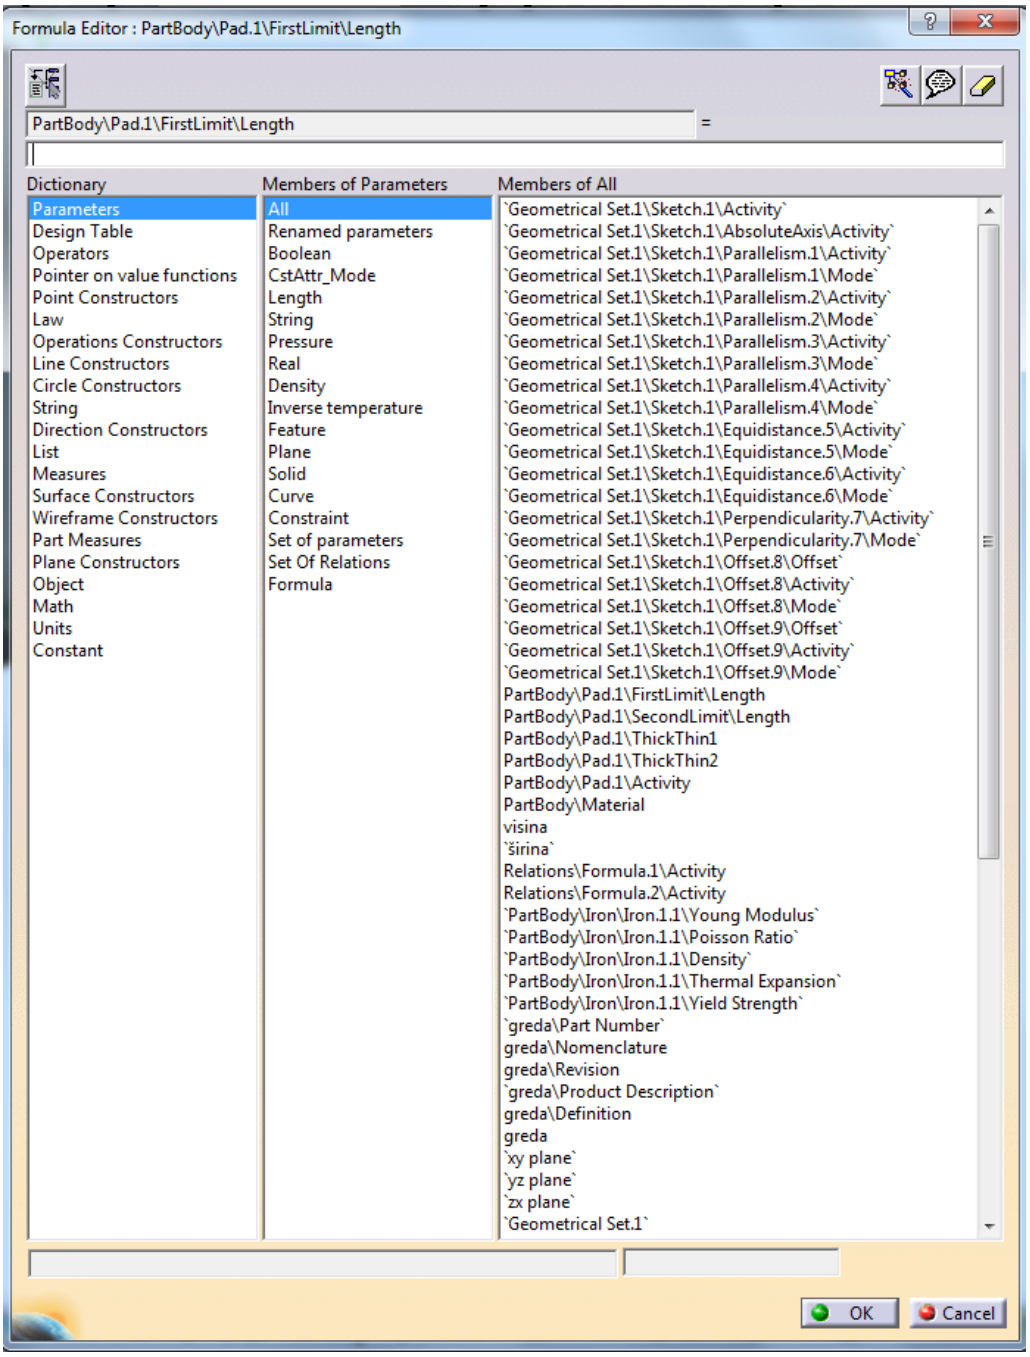

Slika 23. Povezivanje parametra i dimenzija

Zna se da su parametri povezani s dimenzijama ako se uz dimenzije vidi f(x) (Slika 24).

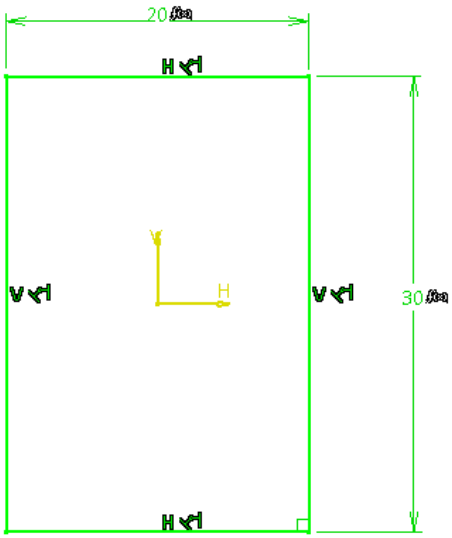

Slika 24. Prikaz povezanih parametara s dimenzijama

Nakon toga će se na „Apply Material“ izabrati željezo (iron) kao materijal za gredu.

U „Generative Structural Analysis“ za konačne elemente su izabrani linearni tetraedri čiji parametri (veličina i gustoća) mesha su 5mm i 1mm.

Greda je na jednom kraju uklještena, a na drugom opterećena silom od 1000 N. U drvetu će se pod „Sensors“ osim „Energy“ odabrati „Maximum von Mises“ i „Mass“ (Slika 25 i Slika 26).

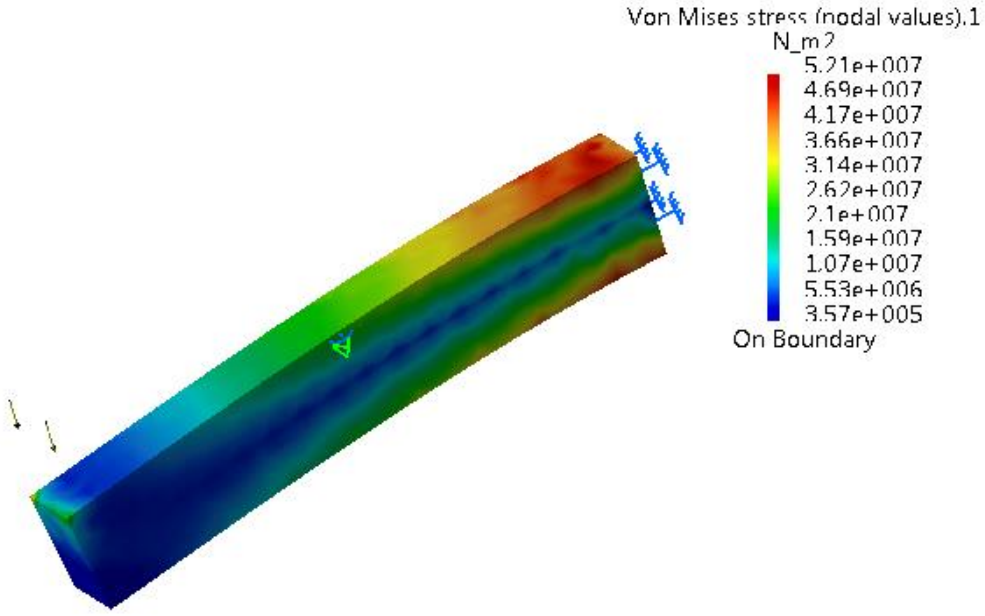

Slika 25. Prikaz raspodijele opterećenja na gredi

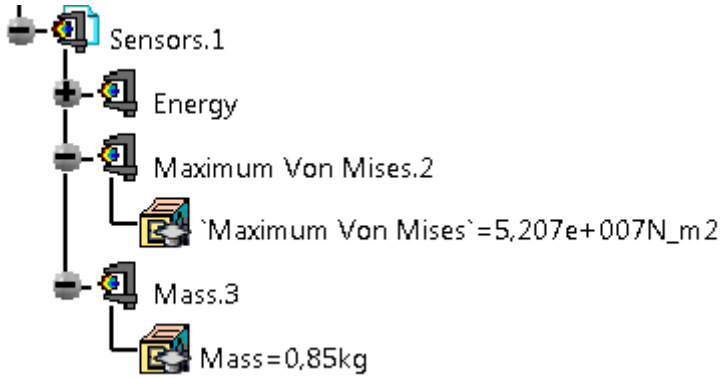

Slika 26. Prikaz odabranih „Sensors“

U „Product Engineering Optimizer“ mišem će se kliknuti na ikonu „Design of Experiments“.

Pojavio se prozor u kojemu se izaberu ulazni, odnosno izlazni parametri. Za ulazne parametre su izabrani visina i širina, a za izlazne masa i naprezanje (Maximum Von Mises). Za ulazne parametre određeno je da mogu biti najmanje 10mm, a najviše

80mm duljine. Taj raspon duljine je podijeljen na 8 dijelova. Catia je automatski izračunala da će biti maksimalno 64 kombinacija rješenja, što je dobila umnoškom svih podjela ulaznih parametara (u našem slučaju 8*8) (Slika 27 i Slika 28).

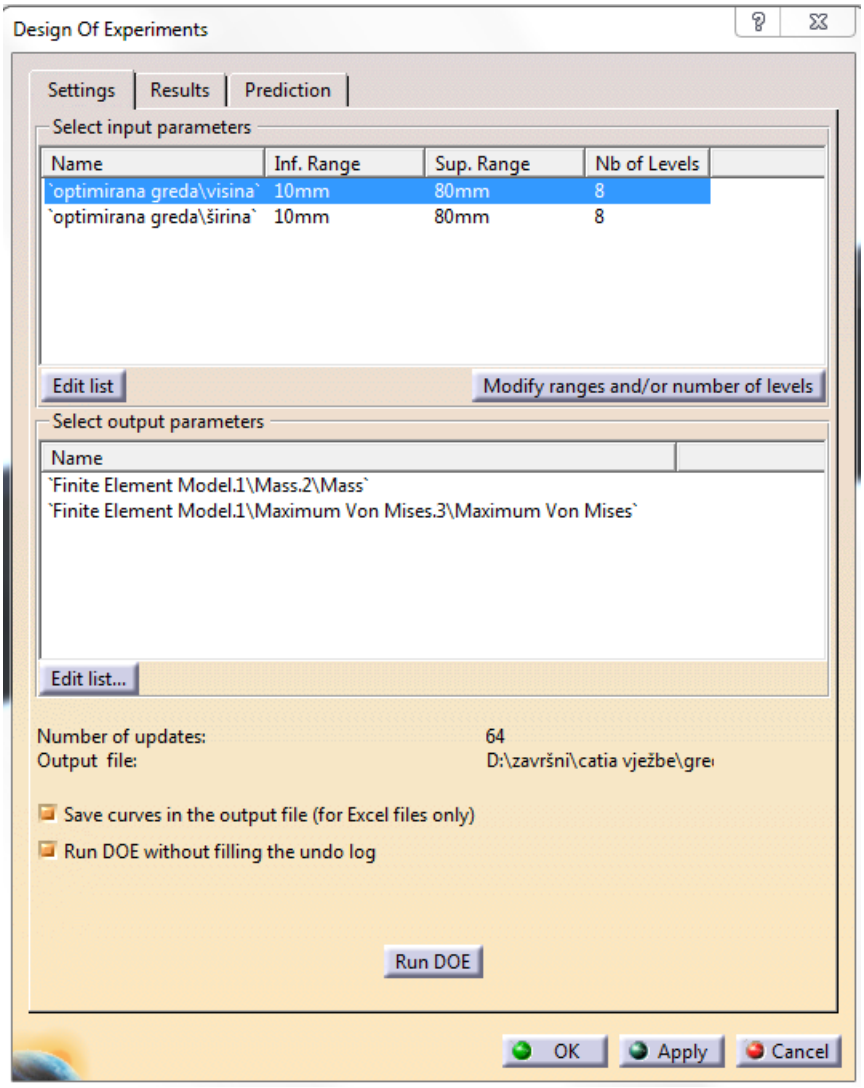

Slika 27. Prikaz parametara u DOE

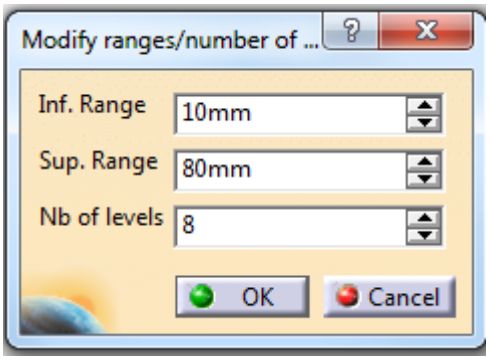

Slika 28. Definiranje raspona i koraka

Klikom na „Run DOE“, pojavio se prozor u kojem će se upisati ime i odrediti mjesto gdje će CATIA spremiti rezultate u obliku Microsoft Excel tablice.

U tablici se može vidjeti kako će se mjenjati masa i naprezanje s obzirom na promjenu dimenzija, tj. na koji način promjena ulaznih parametara utječe na izlazne (Slika 29).

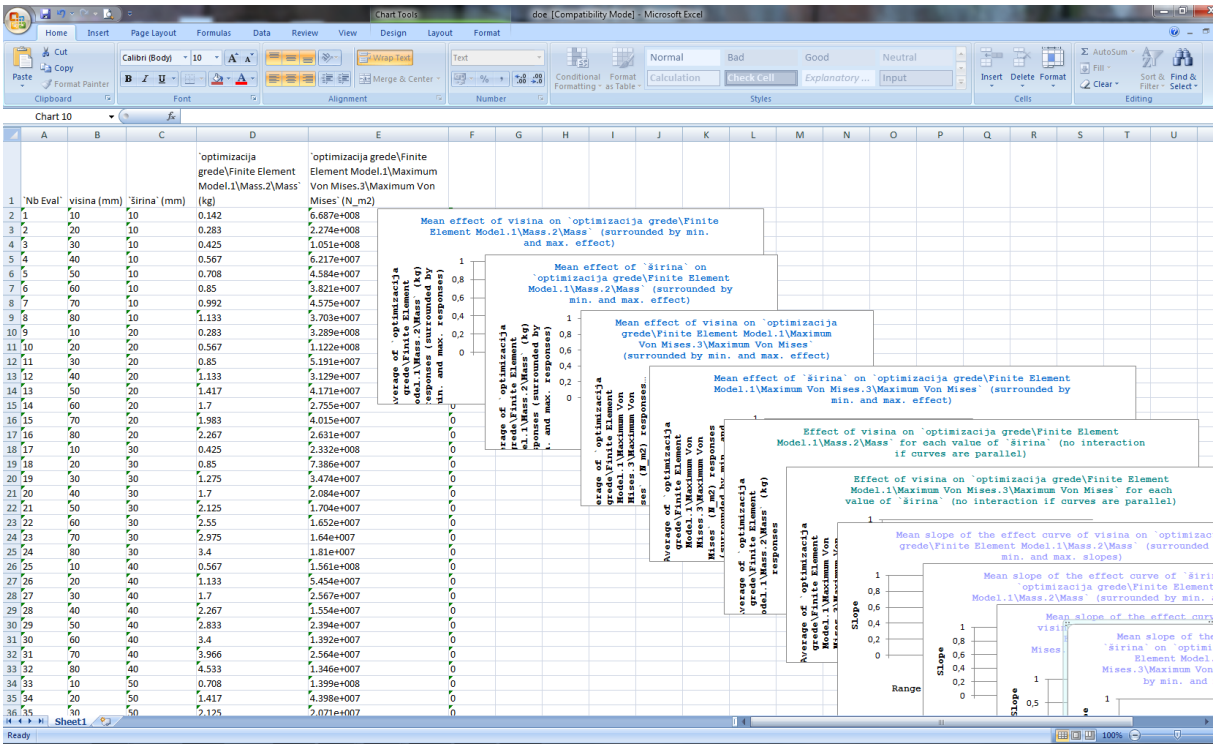

Slika 29. Rezultati DOE u Micorsoft Excel tablici

Na slici (Slika 30) vidimo kako oba ulazna parametra utječu na naprezanje (Maximum Von Mises).

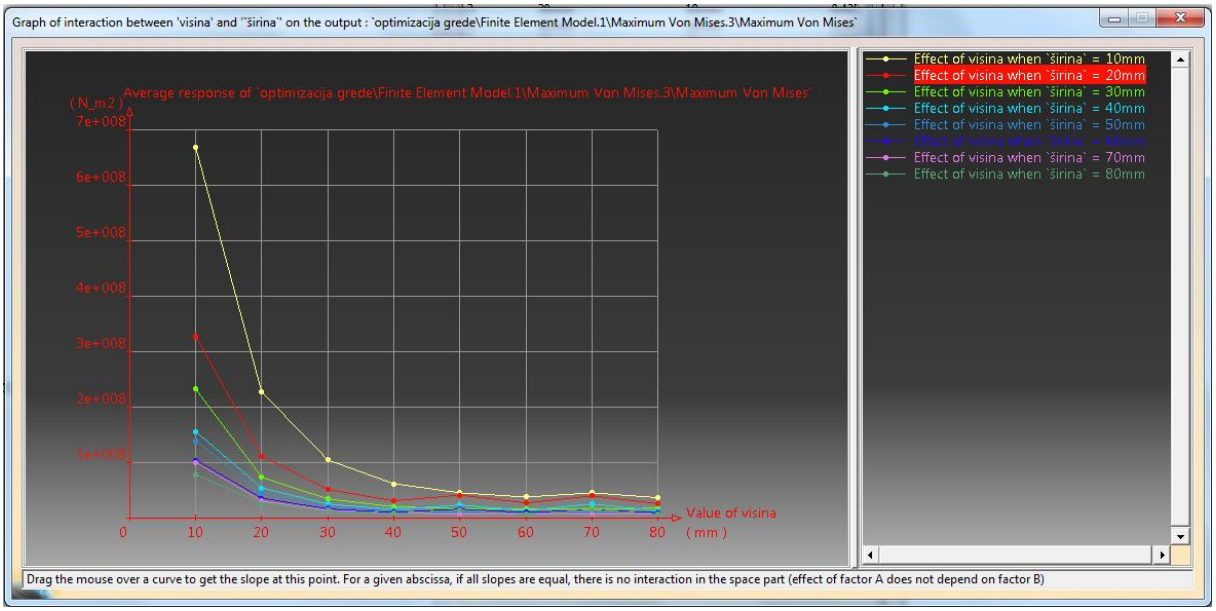

Slika 30. Utjecaj ulaznih parametara na naprezanje

Nakon što je završena analiza u „Design of Experiments“ klikom na ikonu „Optimization“ u prozoru će se definirati uvjeti optimizacije (Slika 31).

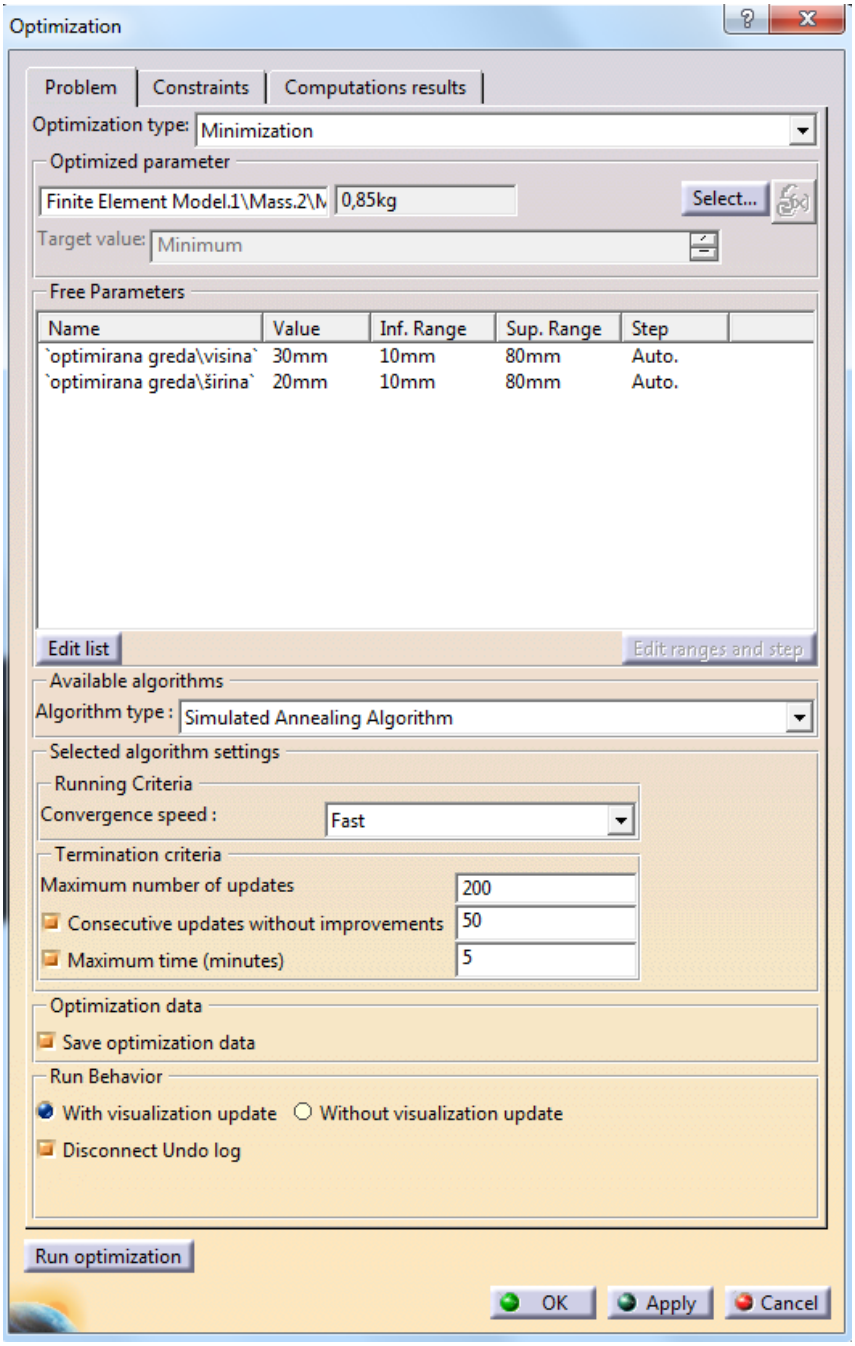

Slika 31. Uvjeti optimizacije grede

Cilj je pronaći najmanju moguću masu uz zadana ograničenja. Parametri čijom promjenom dimenzija će se to ostvariti su: visina i širina. Njihov raspon je jednak kao i u analizi „Design of Experiments“, ali ovoga puta je podjela raspona ostavljena da bude automatska.

Pod ograničenja je stavljeno da masa bude manja od 0.5kg uz odstupanje 0.01kg, te da Maximum Von Mises bude manji ili jednak 100MPa (100e+006N_m2) uz odstupanje od 1e+006N_m2.

Greda koja je konstruirana zadovoljava jedan od dva uvjeta, a to je da je naprezanje manje od 100MPa.

Klikom na „Run optimization“ u prozoru koji se pojavio će se odrediti ime i mjesto gdje će se spremiti rezultati optimizacije u obliku Microsoft Excel tablice.

Nakon što je proces optimiranja završen, izabrano je najbolje rješenje i primjenjeno na gredu (Slika 32).

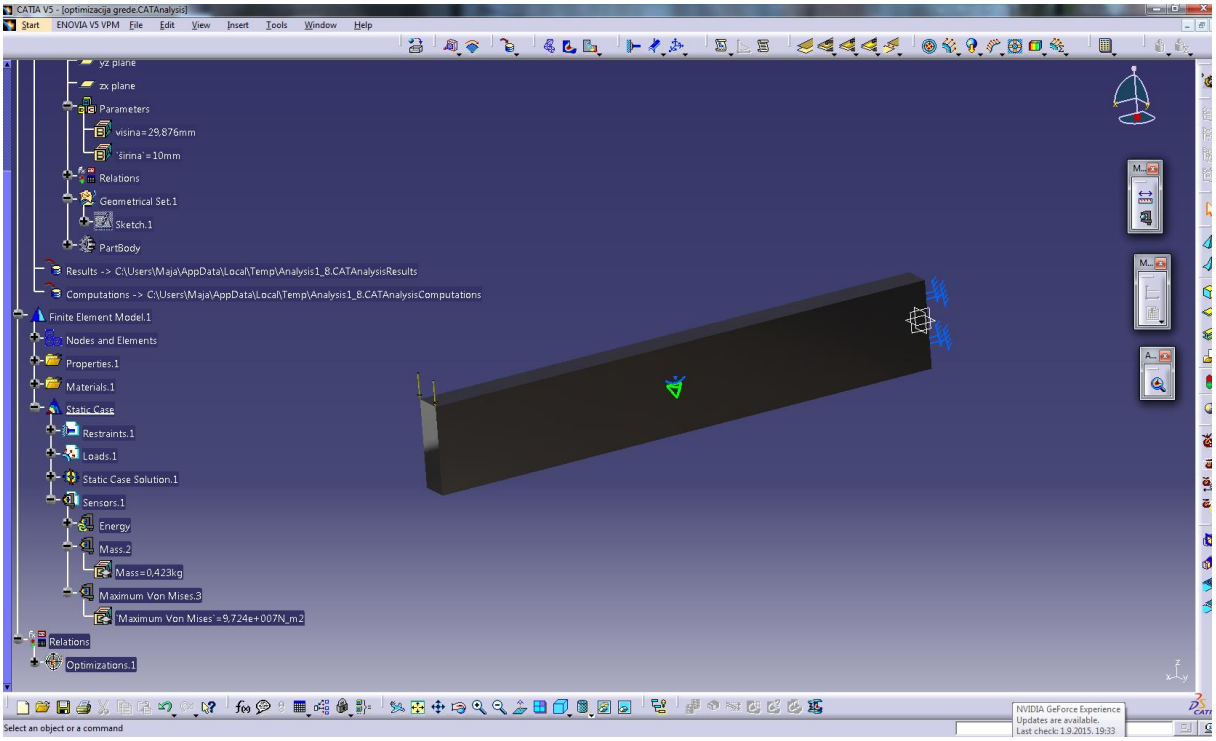

Slika 32. Izgled optimirane grede

3.2 Optimiranje boce

U ovom primjeru će se pokazati da je moguće optimirati bez analize konačnih elemenata. Usporediti će se rezultati dviju optimizacija koje se međusobno razlikuju u odabiru algoritma po kojem će se vršiti proračun. Jedan radi po principu globalnog pretraživanja podataka, a drugi lokalnog.

U „Part Design“ je modelirana boca i napravljeni su parametri za dimenzije koje će se koristiti prilikom optimiranja. Za materijal boce je izabrano staklo (Smoked glass). Uz pomoć ikone „Measure Intertia“ izmjereni su masa i volumen boce (Slika 33).

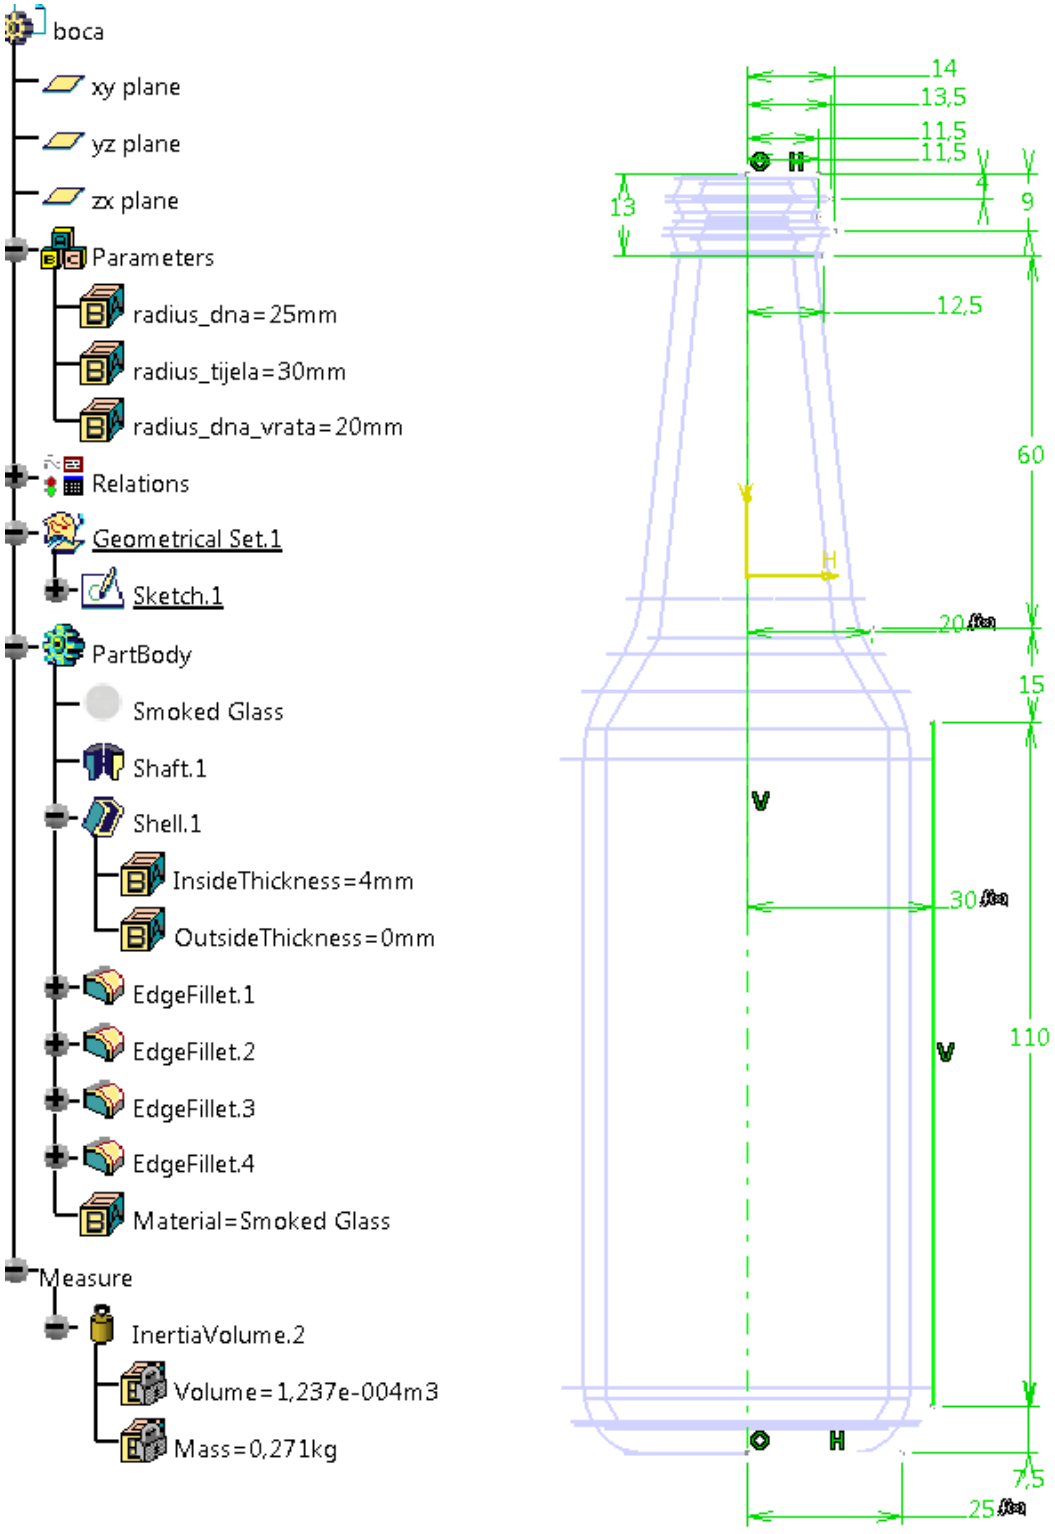

Slika 33. Izgled i parametri boce

Parametri za optimiranje u oba slučaja su jednaki.

Na kartici za optimiranje su: pod Optimization type izabran Target Value,

pod Optimized parameter: InertiaVolume.2\Mass,

pod Target value 0,2kg,

pod Free Parameters: radius_dna čija je vrijednost 25mm; da bude u granici od 23-27mm;

radius_tijela čija je vrijednost 30mm, da bude između 28-32mm;

radijus_dna_vrata čija je vrijednost 20mm, da bude između 18-22mm;

te PartBody/Shell.1\InsideThickness čija je vrijednost 4mm, da bude između 2-5mm.

pod vrijeme je zadano 5 min

Razlika je jedino što je u jednom izabran „Simulated Annealing Algorithm“ i pod convergence speed „fast“ (to je ono što prvo ponudi kod odabira tog algoritma), a u drugome „Gradient Algorithm Without Constrain“ i pod convergence speed „slow“ (jer je to automatski izabrao prilikom odabira tog algoritma).

Svaka od optimizacija je spremljena u zasebnu excel datoteku.

Usporedbom rezultata i načina na koji svaki od algoritama vodi tijek proračuna optimizacije vidi se kako „Gradient Algorithm Without Constrain“ ima finu razradu proračuna, u smislu da su brojčane razlike parametara kojima optimiramo između dvaju rješenja u tablici jako male. U proračunu od cijelog zadanog raspona (najveće i najmanje dimenzije) parametra čije vrijednosti se optimiraju, algoritam koristi isključivo one koje teže minimumima unutar zadanih parametra (Slika 34).

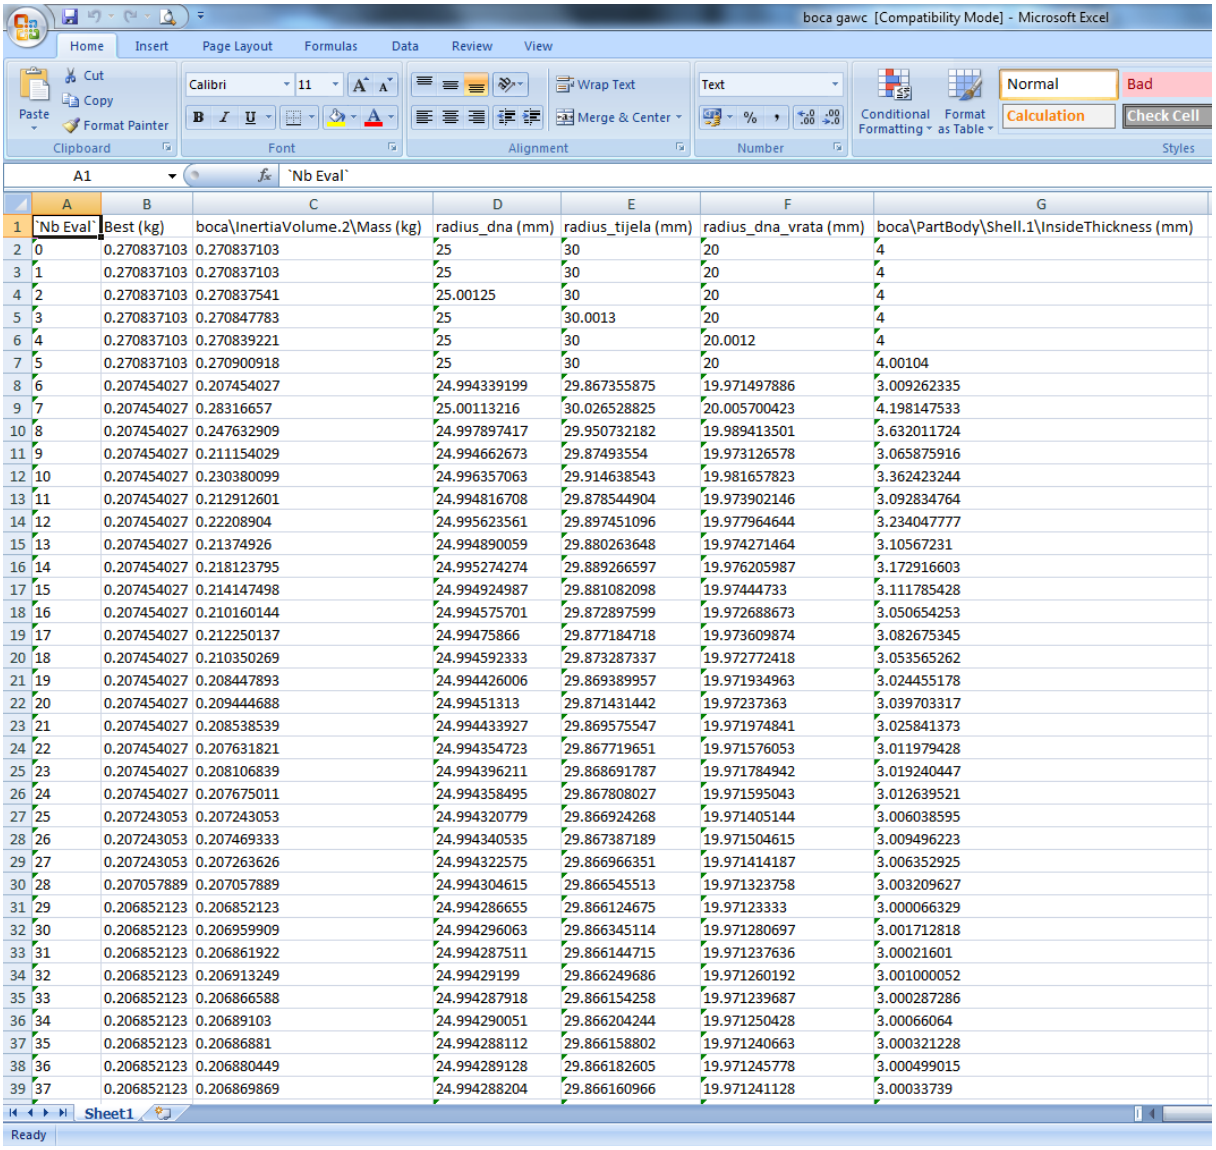

boca gawc [Compatibility Mode] - Microsoft Excel

`Nb Eval`	Best (kg)	boca\InertiaVolume.2\Mass (kg)	radius_dna (mm)	radius_tijela (mm)	radius_dna_vrata (mm)	boca\PartBody\Shell.1\InsideThickness (mm)
0	0.270837103	0.270837103	25	30	20	4
1	0.270837103	0.270837103	25	30	20	4
2	0.270837103	0.270837541	25.00125	30	20	4
3	0.270837103	0.270847783	25	30.0013	20	4
4	0.270837103	0.270839221	25	30	20.0012	4
5	0.270837103	0.270900918	25	30	20	4.00104
6	0.207454027	0.207454027	24.994339199	29.867355875	19.971497886	3.009262335
7	0.207454027	0.28316657	25.00113216	30.026528825	20.005700423	4.198147533
8	0.207454027	0.247632909	24.997897417	29.950732182	19.989413501	3.632011724
9	0.207454027	0.211154029	24.994662673	29.87493554	19.973126578	3.065875916
10	0.207454027	0.230380099	24.996357063	29.914638543	19.981657823	3.362423244
11	0.207454027	0.212912601	24.994816708	29.878544904	19.973902146	3.092834764
12	0.207454027	0.22208904	24.995623561	29.897451096	19.977964644	3.234047777
13	0.207454027	0.21374926	24.994890059	29.880263648	19.974271464	3.10567231
14	0.207454027	0.218123795	24.995274274	29.889266597	19.976205987	3.172916603
15	0.207454027	0.214147498	24.994924987	29.881082098	19.97444733	3.111785428
16	0.207454027	0.210160144	24.994575701	29.872897599	19.972688673	3.050654253
17	0.207454027	0.212250137	24.99475866	29.877184718	19.973609874	3.082675345
18	0.207454027	0.210350269	24.994592333	29.873287337	19.972772418	3.053565262
19	0.207454027	0.208447893	24.994426006	29.869389957	19.971934963	3.024455178
20	0.207454027	0.209444688	24.99451313	29.871431442	19.97237363	3.039703317
21	0.207454027	0.208538539	24.994433927	29.869575547	19.971974841	3.025841373
22	0.207454027	0.207631821	24.994354723	29.867719651	19.971576053	3.011979428
23	0.207454027	0.208106839	24.994396211	29.868691787	19.971784942	3.019240447
24	0.207454027	0.207675011	24.994358495	29.867808027	19.971595043	3.012639521
25	0.207243053	0.207243053	24.994320779	29.866924268	19.971405144	3.006038595
26	0.207243053	0.207469333	24.994340535	29.867387189	19.971504615	3.009496223
27	0.207243053	0.207263626	24.994322575	29.866966351	19.971414187	3.006352925
28	0.207057889	0.207057889	24.994304615	29.866545513	19.971323758	3.003209627
29	0.206852123	0.206852123	24.994286655	29.866124675	19.97123333	3.000066329
30	0.206852123	0.206959909	24.994296063	29.866345114	19.971280697	3.001712818
31	0.206852123	0.206861922	24.994287511	29.866144715	19.971237636	3.00021601
32	0.206852123	0.206913249	24.99429199	29.866249686	19.971260192	3.001000052
33	0.206852123	0.206866588	24.994287918	29.866154258	19.971239687	3.000287286
34	0.206852123	0.20689103	24.994290051	29.866204244	19.971250428	3.00066064
35	0.206852123	0.20686881	24.994288112	29.866158802	19.971240663	3.000321228
36	0.206852123	0.206880449	24.994289128	29.866182605	19.971245778	3.000499015
37	0.206852123	0.206869869	24.994288204	29.866160966	19.971241128	3.00033739

Slika 34. Rezultati za „Gradient Algorithm Without Constrain“

„Simulated Annealing Algorithm“ za razliku od „Gradient Algorithm Without Constrain“ ostavlja dojam kako prilikom optimizacije, dimenzije mjenja bez ikakve logike. Njihove vrijednosti konstantno variraju i za razliku od „Gradient Algorithm Without Constrain“ u obzir uzima veći raspon dimenzija, čak i one veće od nazivnih (vrijednosti koje su bile prije optimizacije) (Slika 35).

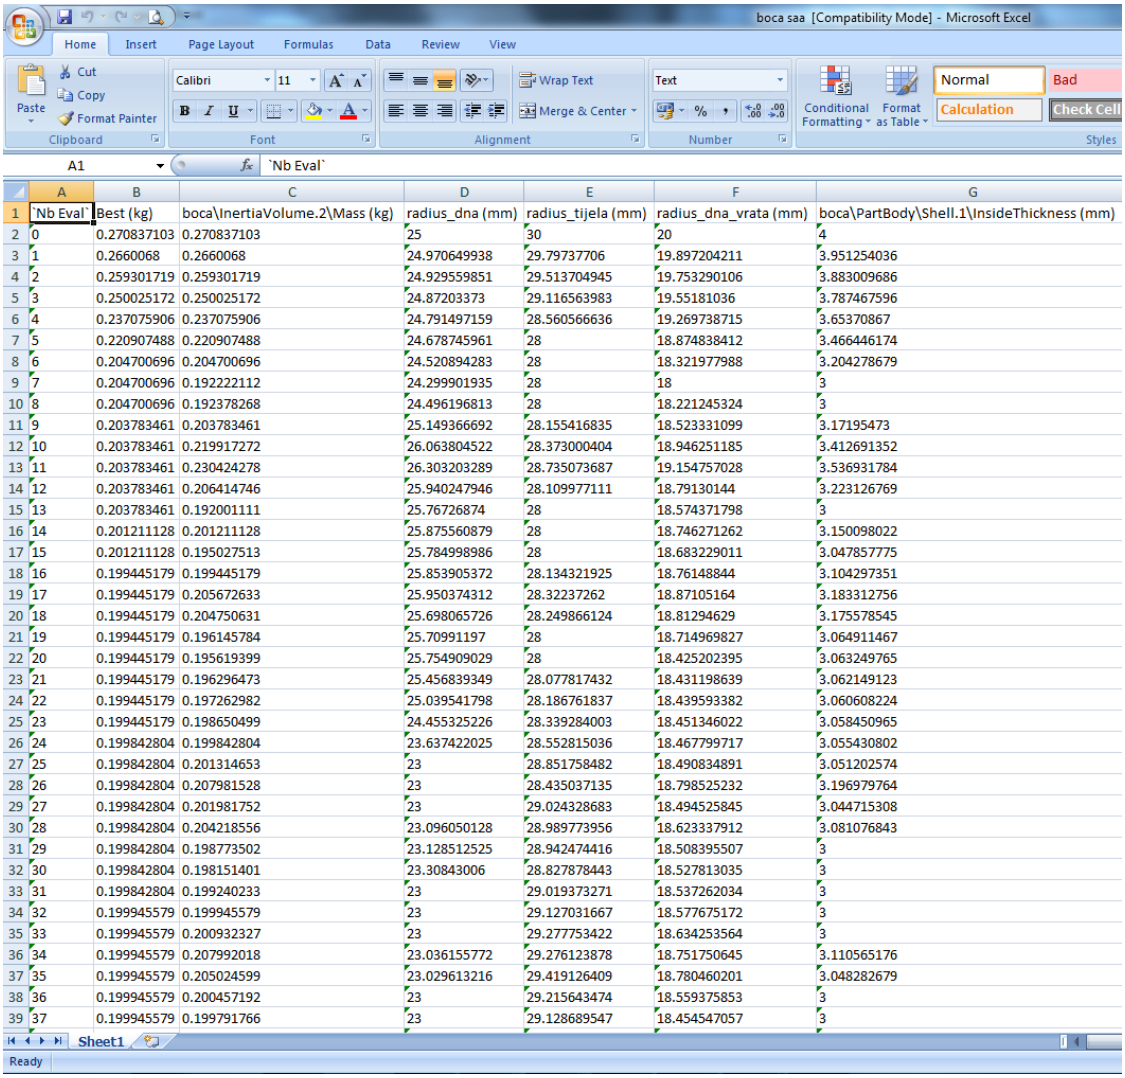

boca saa [Compatibility Mode] - Microsoft Excel

	A	B	C	D	E	F	G
1	`Nb Eval`	Best (kg)	boca\InertiaVolume.2\Mass (kg)	radius_dna (mm)	radius_tijela (mm)	radius_dna_vrata (mm)	boca\PartBody\Shell.1\InsideThickness (mm)
2	0	0.270837103	0.270837103	25	30	20	4
3	1	0.2660068	0.2660068	24.970649938	29.79737706	19.897204211	3.951254036
4	2	0.259301719	0.259301719	24.929559851	29.513704945	19.753290106	3.883009686
5	3	0.250025172	0.250025172	24.87203373	29.116563983	19.55181036	3.787467596
6	4	0.237075906	0.237075906	24.791497159	28.560566636	19.269738715	3.65370867
7	5	0.220907488	0.220907488	24.678745961	28	18.874838412	3.466446174
8	6	0.204700696	0.204700696	24.520894283	28	18.321977988	3.204278679
9	7	0.204700696	0.192222112	24.299901935	28	18	3
10	8	0.204700696	0.192378268	24.496196813	28	18.221245324	3
11	9	0.203783461	0.203783461	25.149366692	28.155416835	18.523331099	3.17195473
12	10	0.203783461	0.219917272	26.063804522	28.373000404	18.946251185	3.412691352
13	11	0.203783461	0.230424278	26.303203289	28.735073687	19.154757028	3.536931784
14	12	0.203783461	0.206414746	25.940247946	28.109977111	18.79130144	3.223126769
15	13	0.203783461	0.192001111	25.76726874	28	18.574371798	3
16	14	0.201211128	0.201211128	25.875560879	28	18.746271262	3.150098022
17	15	0.201211128	0.195027513	25.784998986	28	18.683229011	3.047857775
18	16	0.199445179	0.199445179	25.853905372	28.134321925	18.76148844	3.104297351
19	17	0.199445179	0.205672633	25.950374312	28.32237262	18.87105164	3.183312756
20	18	0.199445179	0.204750631	25.698065726	28.249866124	18.81294629	3.175578545
21	19	0.199445179	0.196145784	25.70991197	28	18.714969827	3.064911467
22	20	0.199445179	0.195619399	25.754909029	28	18.425202395	3.063249765
23	21	0.199445179	0.196296473	25.456839349	28.077817432	18.431198639	3.062149123
24	22	0.199445179	0.197262982	25.039541798	28.186761837	18.439593382	3.060608224
25	23	0.199445179	0.198650499	24.455325226	28.339284003	18.451346022	3.058450965
26	24	0.199842804	0.199842804	23.637422025	28.552815036	18.467799717	3.055430802
27	25	0.199842804	0.201314653	23	28.851758482	18.490834891	3.051202574
28	26	0.199842804	0.207981528	23	28.435037135	18.798525232	3.196979764
29	27	0.199842804	0.201981752	23	29.024328683	18.494525845	3.044715308
30	28	0.199842804	0.204218556	23.096050128	28.989773956	18.623337912	3.081076843
31	29	0.199842804	0.198773502	23.128512525	28.942474416	18.508395507	3
32	30	0.199842804	0.198151401	23.30843006	28.827878443	18.527813035	3
33	31	0.199842804	0.199240233	23	29.019373271	18.537262034	3
34	32	0.199945579	0.199945579	23	29.127031667	18.577675172	3
35	33	0.199945579	0.200932327	23	29.277753422	18.634253564	3
36	34	0.199945579	0.207992018	23.036155772	29.276123878	18.751750645	3.110565176
37	35	0.199945579	0.205024599	23.029613216	29.419126409	18.780460201	3.048282679
38	36	0.199945579	0.200457192	23	29.215643474	18.559375853	3
39	37	0.199945579	0.199791766	23	29.128689547	18.454547057	3

Slika 35. Rezultati za „Simulated Annealing Algorithm“

Oba algoritma su došla do nekog konačnog rješenja. Rješenja se međusobno razlikuju, a ta razlika u konačnim dimenzijama može se vidjeti na slici (Slika 36).

Na slici lijevo vidi se najbolje rješenje dobiveno proračunom s algoritmom „Gradient Algorithm Without Constrain“ , a na slici desno dobiveno sa „Simulated Annealing Algorithm“.

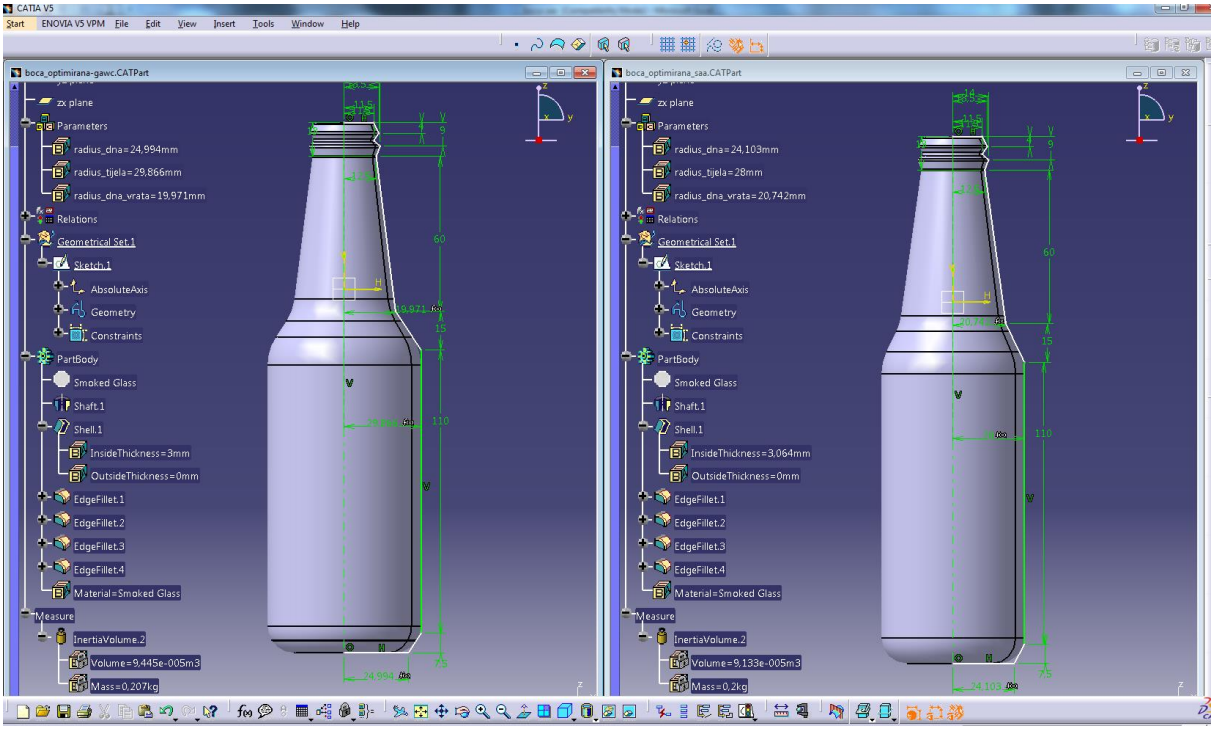

Slika 36. Usporedba konačnih rezultata optimiranja za oba algoritma

3.3 Optimiranje nosača

U ovom primjeru osim što se optimiranjem želi postići najmanja masa koja će izdržati zadano opterećenje, također se želi vidjeti kakav utjecaj brzina optimiranja ima na konačne rezultate.

U „Part Design“ je modeliran nosač, a dimenzije koje su izabrane za parametre s kojima će se optimirati vide se na slici (Slika 37).

Parametre su nazvani „sirina rebara“ i „udaljenost rebara“.

Za materijal nosača izabran je aluminij (Aluminium).

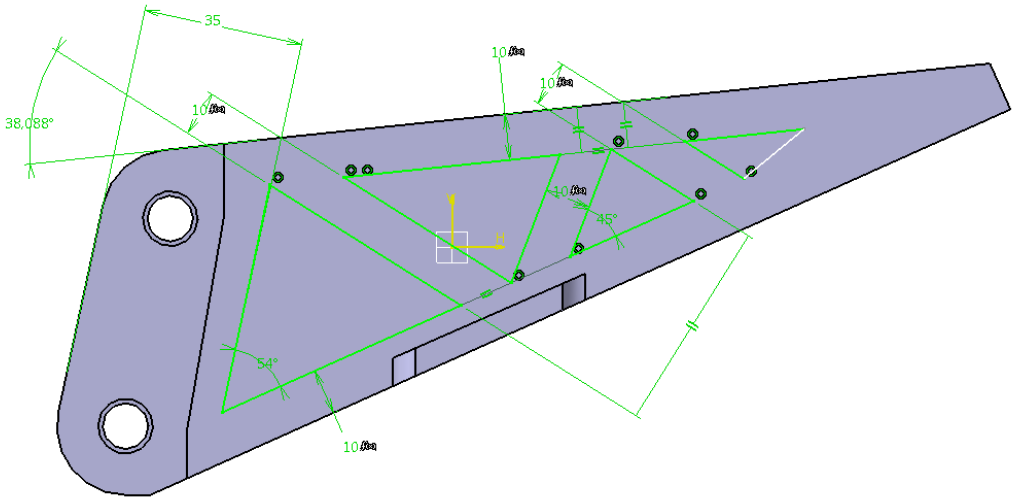

Slika 37. Prikaz dimenzija koje će se optimirati

U „Generative Structural Analysis“ za konačne elemente izabrani su parabolični tetraedri čiji parametri (veličina i gustoća) mesha su 5mm i 2mm.

Tetraedar je osnovni konačni element koji se koristi u analizi 3D modela, a parabolični tetraedri daju preciznije rezultate od linijskih [6].

Nosač je na jednom kraju uklješten, a na drugom opterećen silom od 800 N. U drvetu pod „Sensors“ osim „Energy“ izabrani su „Maximum von Mises“ i „Mass“ (Slika 38).

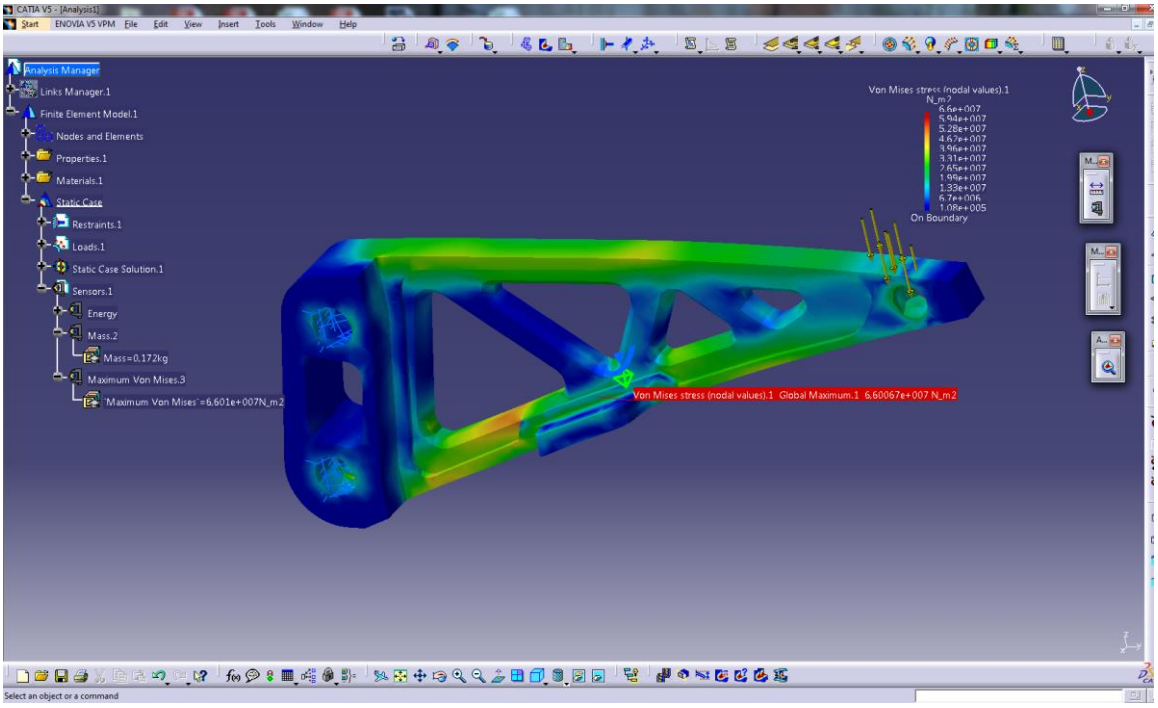

Slika 38. FEM analiza nosača

Sveukupno su napravljene četiri optimizacije. Uvjeti i parametri po kojima su optimirani su jednaki, jedina razlika je u brzini optimiranja (fast, medium, slow ili infinite).

Na kartici Problem:

-Optimization type: minimization

-Optimized parameter: mass

-Free parameters: sirina_rebara od 2 do 13mm

udaljenost_rebara od 2 do 13mm

-Algorithm type: Simulated Anealling Algorithm

-Termination criteria: maximum number of updates: 100

-Consecutive updates without improvements: 20

-Maximum time: 15min

Na kartici Constraints

- Maximum Von Misses< 9.2e7N_m2

Svako od rješenja je spremljeno u zasebnu excel datoteku.

Sva optimiranja su uspješno obavljena i konačni rezultati su im unutar zadanih ograničenja.

Na slikama se vide usporedbe najboljih konačnih rješenja dobivenih različitim brzinama optimiranja.

Na slikama (Slika 39 i Slika 40) vidimo rezultate dobivene optimiranjem s „fast“ brzinom. Ukupni broj rješenja je 100.

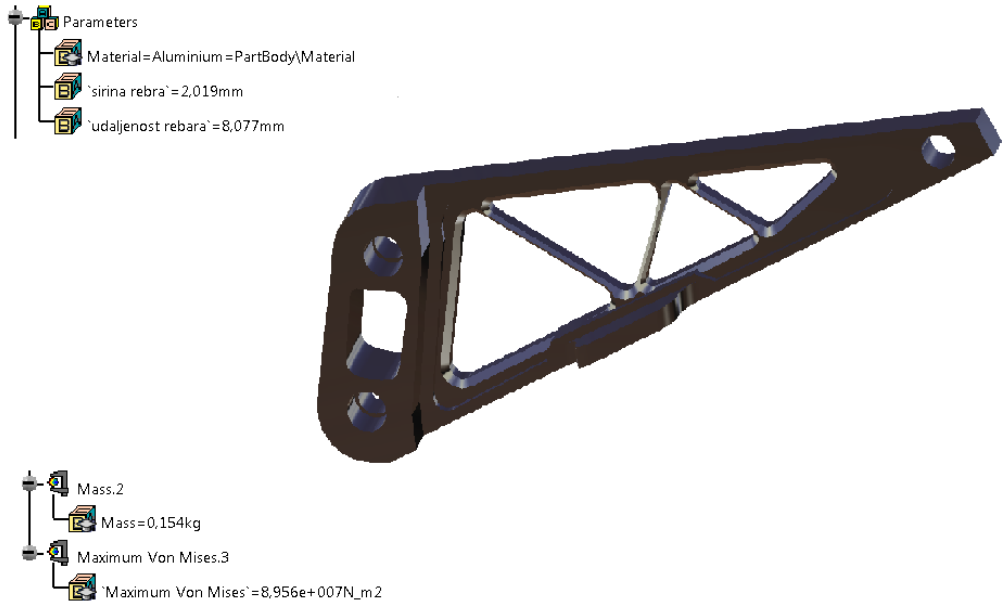

Slika 39. Izgled nosača i rezultati dobiveni „fast“ brzinom

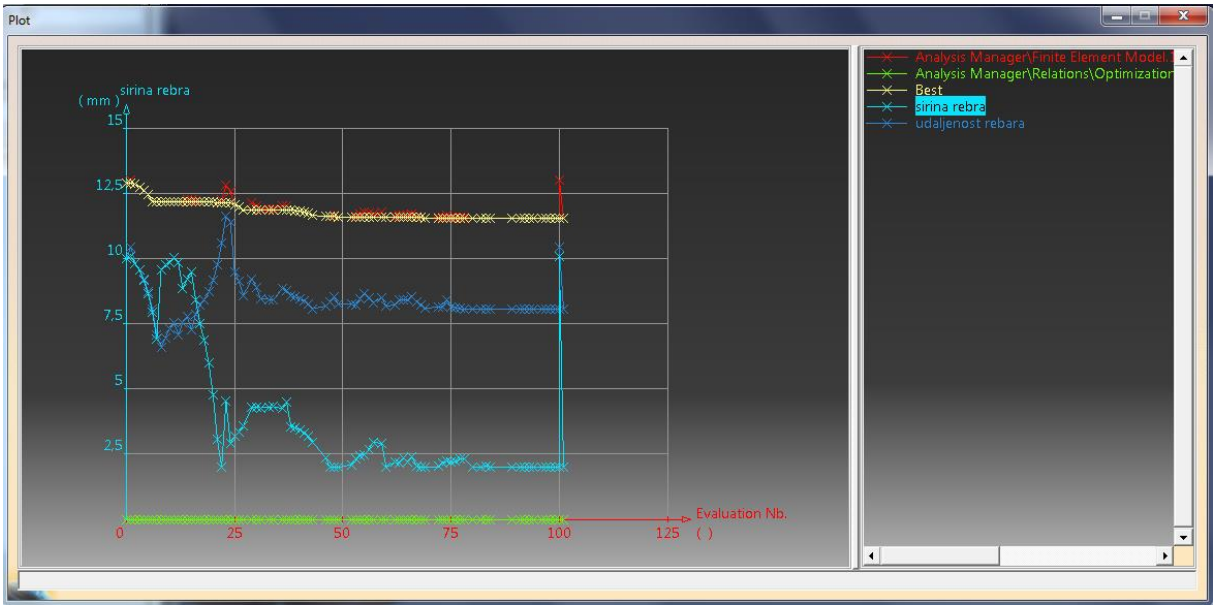

Slika 40. Prikaz krivulja dobivenih „fast“ brzinom

Na slikama (Slika 41 i Slika 42) su prikazani najbolji konačni rezultati dobiveni optimiranjem s „medium“ brzinom. Ukupni broj rješenja je 83.

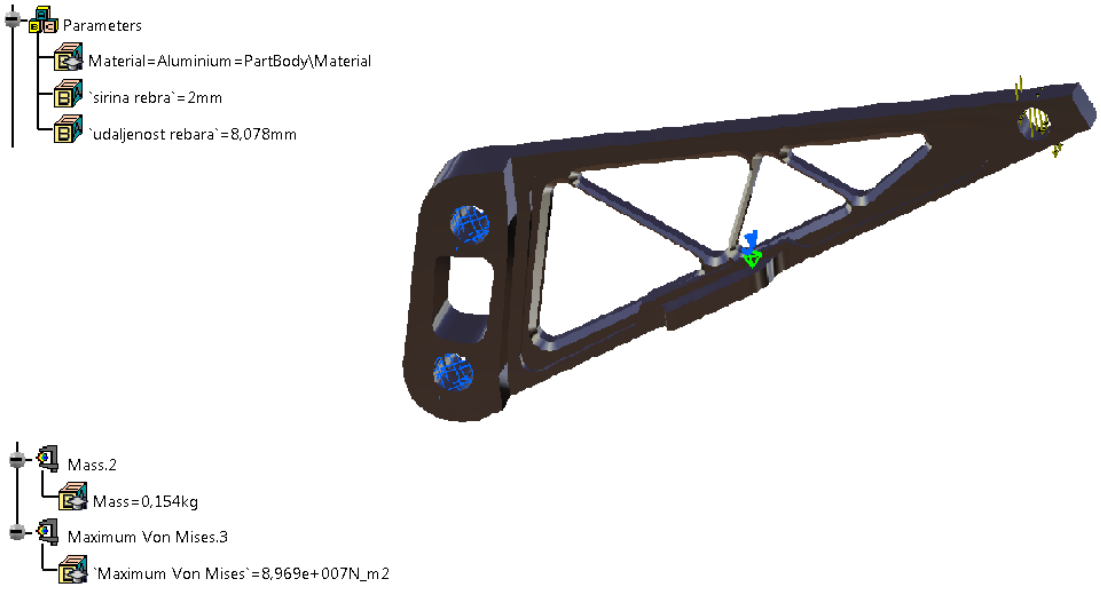

Slika 41. Izgled nosača i rezultati dobiveni „medium“ brzinom

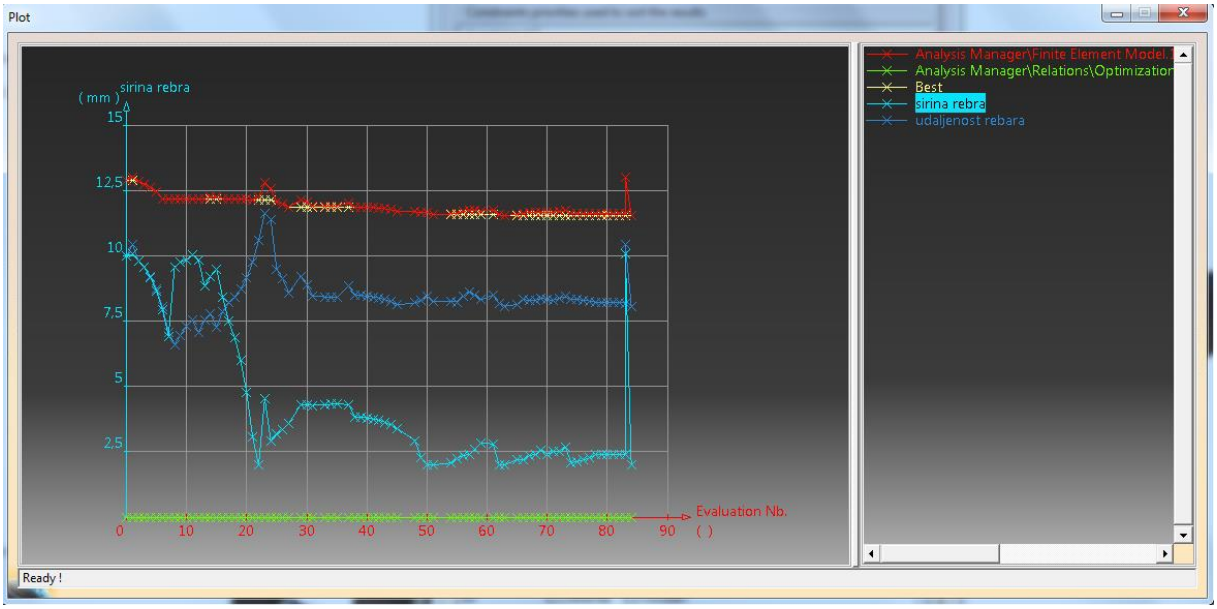

Slika 42. Prikaz krivulja dobivenih „medium“ brzinom

Na slikama (Slika 43 i Slika 44) se vide najbolja rješenja dobivena optimiranjem sa „slow“ brzinom. Ukupni broj rješenja je 80.

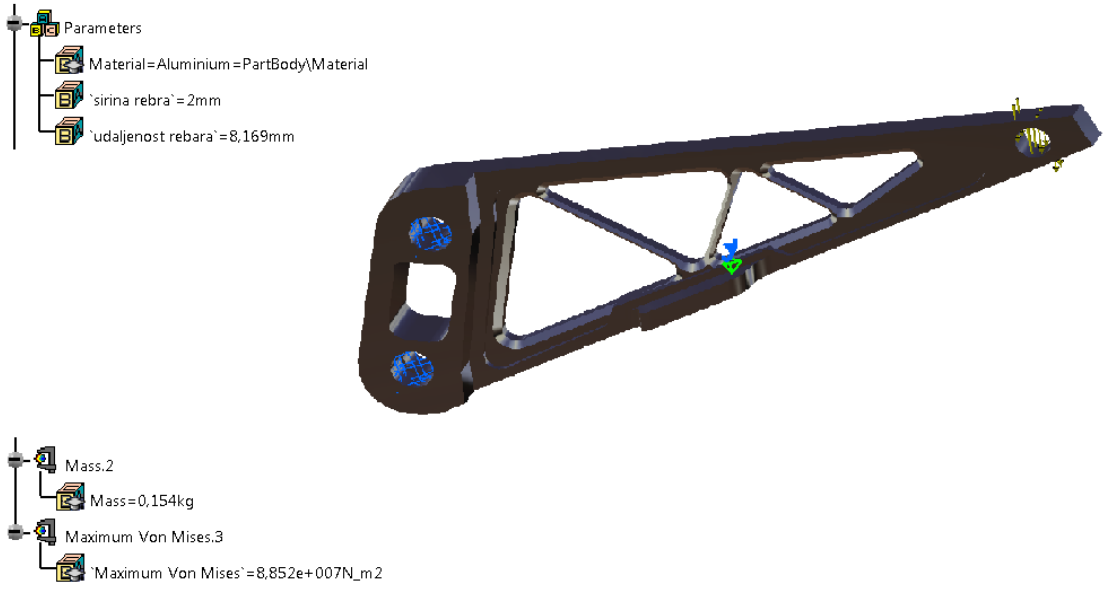

Slika 43. Izgled nosača i rezultati dobiveni „slow“ brzinom

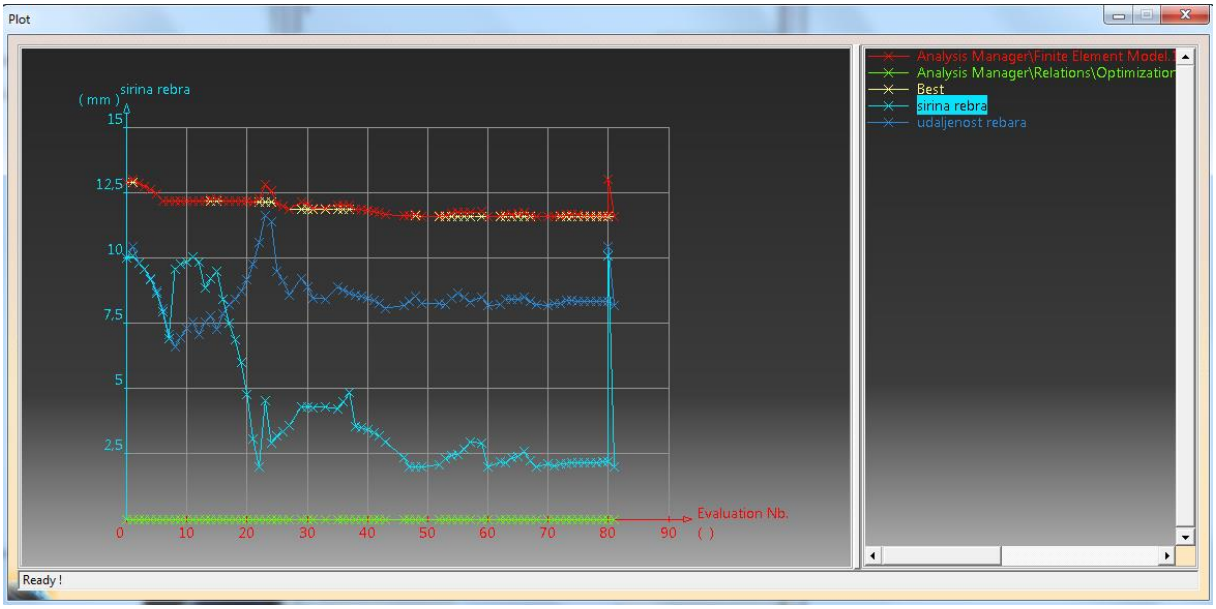

Slika 44. Prikaz krivulja dobivenih „slow“ brzinom

I na slikama (Slika 45 i Slika 46) se vidi najbolje konačno rješenje dobiveno optimiranjem s „infinite“ brzinom. Ukupni broj rješenja je 98.

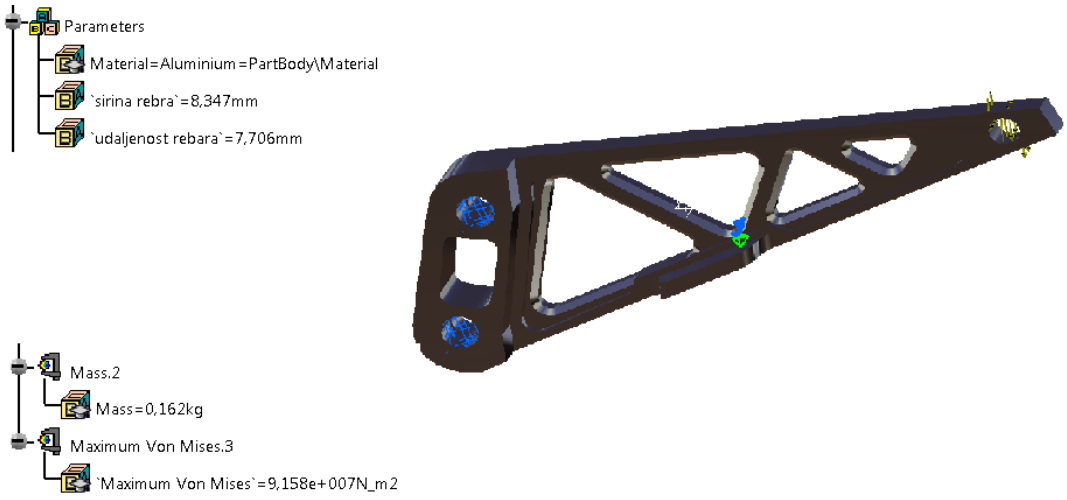

Slika 45. Izgled nosača i rezultati dobiveni „infinite“ brzinom

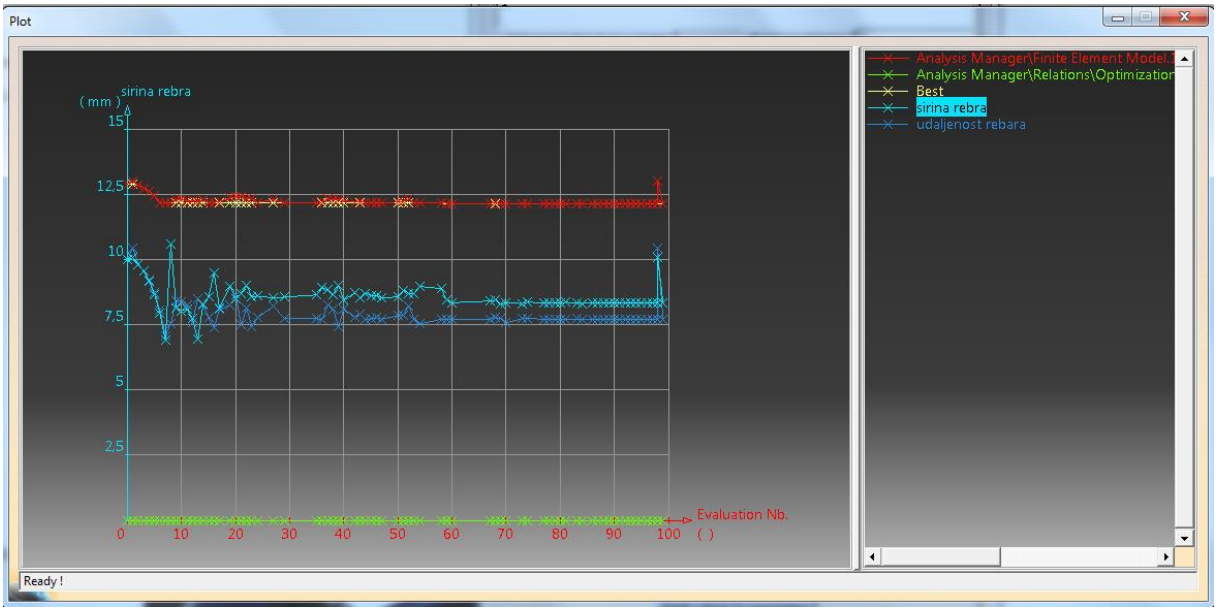

Slika 46. Prikaz krivulja dobivenih „infinite“ brzinom

Usporedbom svih rezultata vidi se kako su rješenja i dijagrami dobiveni optimiranjem brzinama „fast“, „medium“ i „slow“ jako slični. Dok je rješenje dobiveno s „infinite“ drugačije, te da se rezultati dobiveni na taj način dosta razlikuju od ostalih.

Razlog tome je što se brzina „infinite“ koristi za slučajeve kada problem nema lokalnih optimuma. Dok za slučajeve s mnogo lokalnih optimuma koristi se najmanja brzina.

3.4 Optimiranje I-grede

U ovom primjeru optimiranjem htjela se postići maksimalna moguća vrijednost momenta tromosti I-grede za zadane uvjete. Za razliku od prošlih primjera di su uvjeti za optimiranje većinom bili izdefinirani na kartici „Problem“ uz par ograničenja, u ovom primjeru veliku ulogu će imati uvjeti i ograničenja koje će se postaviti na kartici „Constraints“.

U „Part Design“ nacrtana je I-greda čije dimenzije su: širina=150mm, visina=200mm, prirubnica=20mm i okvir=20mm. Ukupna duljina grede je 1000mm.

Za parametre su izabrani volumen (smartvolume) i moment tromosti (inertia).

Formula za moment tromosti I-grede je:

((sirina*visina*visina*visina)/12)-(((sirina-okvir)*(visina-(2*prirubnica))*(visina-(2*prirubnica))*(visina-(2*prirubnica)))/12) (Slika 47)

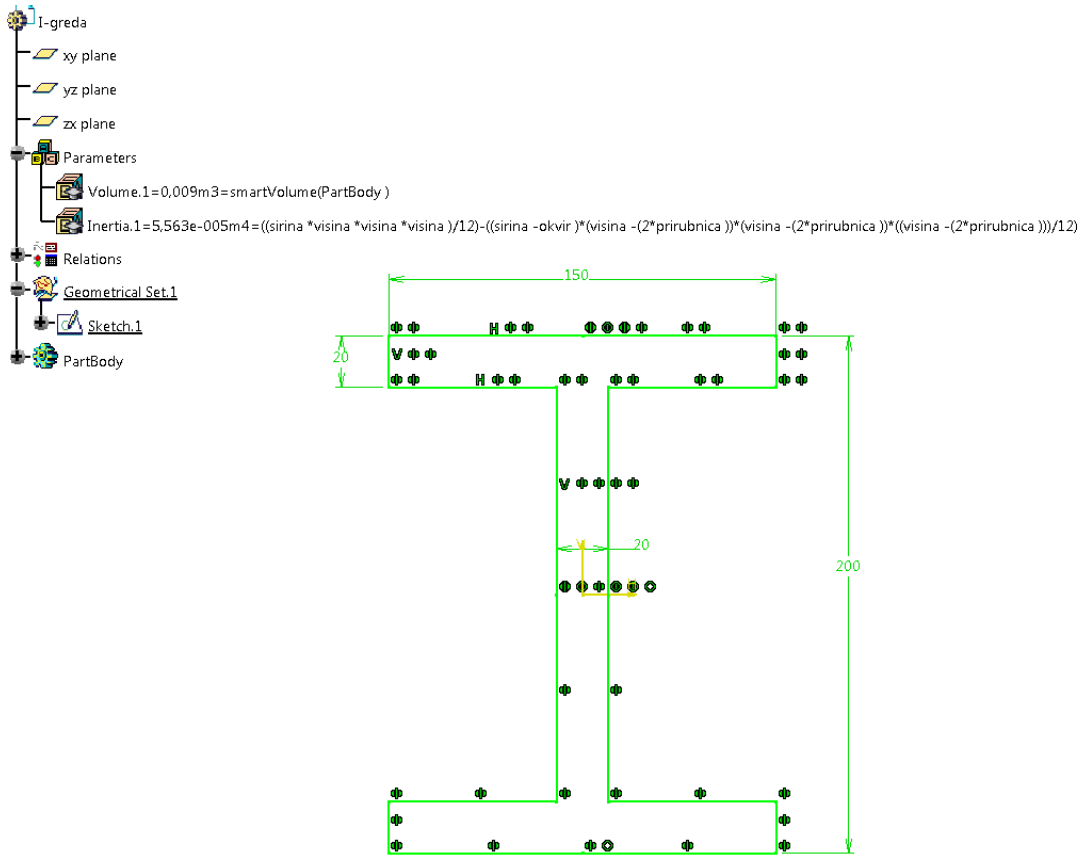

Slika 47. Prikaz izgleda i parametara I-grede

U prozoru Optimization na kartici Problem:

Optimization type: Maximization

Optimized parameter:: Inertia

Free parameters: Visina

Sirina

Prirubnica

Okvir

(za free parameters nije zadan raspon „od-do“, nego je na automatski)

Algorithm type: Simulated Annealing Algorithm

Convergence speed: Fast

Na kartici Constraints:

smartvolume==0.01m3

Sirina-okvir>0mm

Visina-2*okvir>0mm

Sirina>0mm

Okvir>0mm

Visina>0mm

Okvir-prirubnica==0mm

Ovim uvjetima kao prvo želi se postići točno ciljani volumen,. Kako nije zadan raspon dimenzija za pojedini parametar, ostalim formulama je definirano da su vrijednosti veće od nule i da I-greda nakon optimiranja ne izgubi taj svoj I-oblik.

Rezultati optimiranja su spremljeni u excel datoteku (Slika 48).

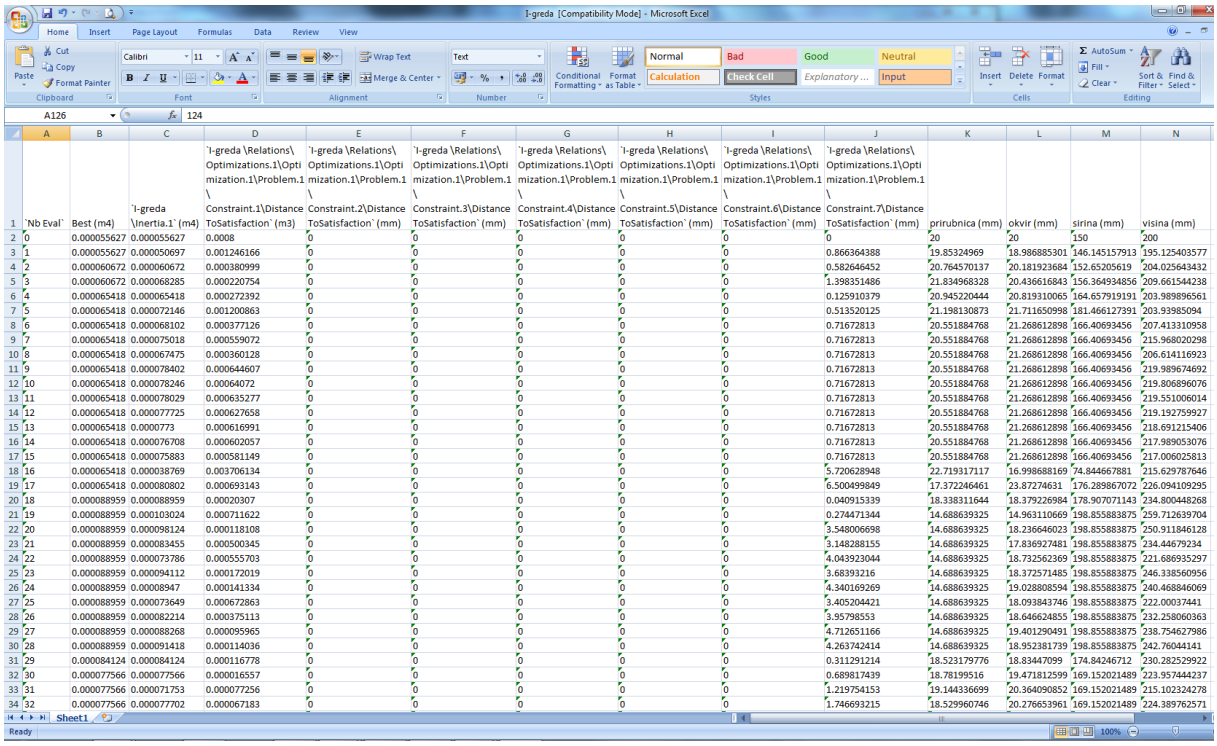

I-greda [Compatibility Mode] - Microsoft Excel

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	`Nb Eval`	Best (m4)	`I-greda \Inertia.1` (m4)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.1\Distance ToSatisfaction` (m3)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.2\Distance ToSatisfaction` (mm)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.3\Distance ToSatisfaction` (mm)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.4\Distance ToSatisfaction` (mm)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.5\Distance ToSatisfaction` (mm)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.6\Distance ToSatisfaction` (mm)	`I-greda \Relations\ Optimizations.1\Optimization.1\Problem.1\ Constraint.7\Distance ToSatisfaction` (mm)	prirubnica (mm)	okvir (mm)	sirina (mm)	visina (mm)
2	0	0.000055627	0.000055627	0.0008	0	0	0	0	0	0	20	20	150	200
3	1	0.000055627	0.000050697	0.001246166	0	0	0	0	0	0.866364388	19.85324969	18.986885301	146.145157913	195.125403577
4	2	0.000060672	0.000060672	0.000380999	0	0	0	0	0	0.582646452	20.764570137	20.181923684	152.65205619	204.025643432
5	3	0.000060672	0.000068285	0.000220754	0	0	0	0	0	1.398351486	21.834968328	20.436616843	156.364934856	209.661544238
6	4	0.000065418	0.000065418	0.000272392	0	0	0	0	0	0.125910379	20.945220444	20.819310065	164.657919191	203.989896561
7	5	0.000065418	0.000072146	0.001200863	0	0	0	0	0	0.513520125	21.198130873	21.711650998	181.466127391	203.93985094
8	6	0.000065418	0.000068102	0.000377126	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	207.413310958
9	7	0.000065418	0.000075018	0.000559072	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	215.968020298
10	8	0.000065418	0.000067475	0.000360128	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	206.614116923
11	9	0.000065418	0.000078402	0.000644607	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	219.989674692
12	10	0.000065418	0.000078246	0.0006402	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	219.806896076
13	11	0.000065418	0.000078029	0.000635277	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	219.551006014
14	12	0.000065418	0.000077725	0.000627658	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	219.192759927
15	13	0.000065418	0.0000773	0.000616991	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	218.691215406
16	14	0.000065418	0.000076708	0.000602057	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	217.989053076
17	15	0.000065418	0.000075883	0.000581149	0	0	0	0	0	0.71672813	20.551884768	21.268612898	166.40693456	217.006025813
18	16	0.000065418	0.000038769	0.003706134	0	0	0	0	0	5.720628948	22.719317117	16.998688169	74.844667881	215.629787646
19	17	0.000065418	0.000080802	0.000693143	0	0	0	0	0	6.500499849	17.372246461	23.87274631	176.289867072	226.094109295
20	18	0.000088959	0.000088959	0.00020307	0	0	0	0	0	0.040915339	18.338311644	18.379226984	178.907071143	234.800448268
21	19	0.000088959	0.000103024	0.000711622	0	0	0	0	0	0.274471344	14.688639325	14.963110669	198.855883875	259.712639704
22	20	0.000088959	0.000098124	0.000118108	0	0	0	0	0	3.548006698	14.688639325	18.236646023	198.855883875	250.911846128
23	21	0.000088959	0.000083455	0.000500345	0	0	0	0	0	3.148288155	14.688639325	17.836927481	198.855883875	234.44679234
24	22	0.000088959	0.000073786	0.000555703	0	0	0	0	0	4.043923044	14.688639325	18.732562369	198.855883875	221.686935297
25	23	0.000088959	0.000094112	0.000172019	0	0	0	0	0	3.68393216	14.688639325	18.372571485	198.855883875	246.338560956
26	24	0.000088959	0.00008947	0.000141334	0	0	0	0	0	4.340169269	14.688639325	19.028808594	198.855883875	240.468846069
27	25	0.000088959	0.000073649	0.000672863	0	0	0	0	0	3.405204421	14.688639325	18.093843746	198.855883875	222.00037441
28	26	0.000088959	0.000082214	0.000375113	0	0	0	0	0	3.95798553	14.688639325	18.646624855	198.855883875	232.258060363
29	27	0.000088959	0.000088268	0.000095965	0	0	0	0	0	4.712651166	14.688639325	19.401290491	198.855883875	238.754627986
30	28	0.000088959	0.000091418	0.000114036	0	0	0	0	0	4.263742414	14.688639325	18.952381739	198.855883875	242.76044141
31	29	0.000084124	0.000084124	0.000116778	0	0	0	0	0	0.311291214	18.523179776	18.83447099	174.84246712	230.282529922
32	30	0.000077566	0.000077566	0.000016557	0	0	0	0	0	0.689817439	18.78199516	19.471812599	169.152021489	223.957444237
33	31	0.000077566	0.000071753	0.000077256	0	0	0	0	0	1.219754153	19.144336699	20.364090852	169.152021489	215.102324278
34	32	0.000077566	0.000077702	0.000067183	0	0	0	0	0	1.746693215	18.529960746	20.276653961	169.152021489	224.389762571

Slika 48. Rezultati optimizacije I-grede u Micorsoft Excel tablici

Problem koji se javlja kod optimiranja u Simulated Annealing Algorithm-u je taj da svi uvjeti zadani sa znakom „==“ (točna vrijednost) nikada neće biti zadovoljeni zbog načina na koji taj algoritam funkcionira (analizira), ali razlika da se dobije „točan rezultat“ je minimalna,tj. skoro pa jednaka nuli.

To se najbolje može vidjeti na slici (Slika 49) na kojoj su pod najboljim rezultatom označene dvije veličine one koje su trebale biti „točna“ vrijednost.

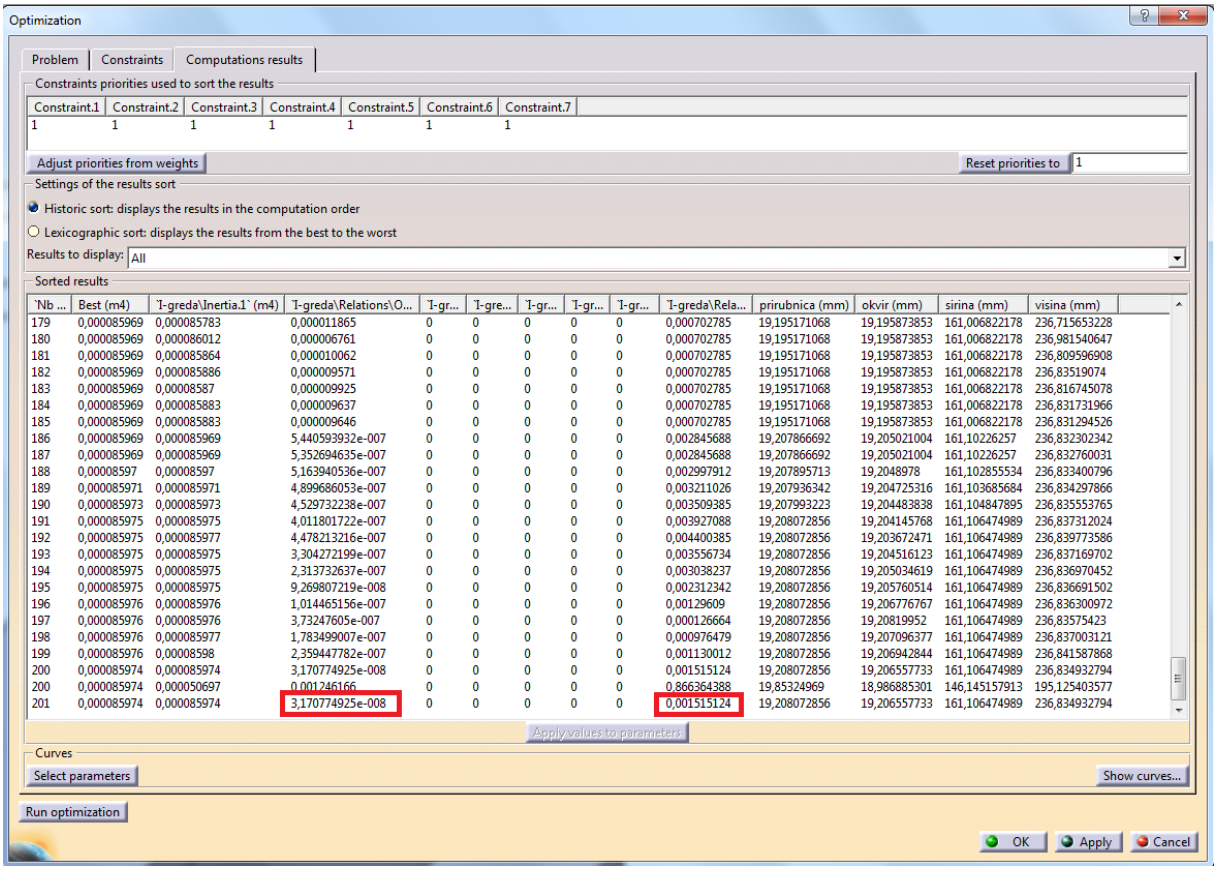

`Nb ...	Best (m4)	`I-greda\Inertia.1` (m4)	`I-greda\Relations\O...	`I-gr...	`I-gre...	`I-gr...	`I-gr...	`I-gr...	`I-greda\Rela...	prirubnica (mm)	okvir (mm)	sirina (mm)	visina (mm)
179	0,000085969	0,000085783	0,000011865	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,715653228
180	0,000085969	0,000086012	0,000006761	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,981540647
181	0,000085969	0,000085864	0,000010062	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,809596908
182	0,000085969	0,000085886	0,000009571	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,83519074
183	0,000085969	0,00008587	0,000009925	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,816745078
184	0,000085969	0,000085883	0,000009637	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,831731966
185	0,000085969	0,000085883	0,000009646	0	0	0	0	0	0,000702785	19,195171068	19,195873853	161,006822178	236,831294526
186	0,000085969	0,000085969	5,440593932e-007	0	0	0	0	0	0,002845688	19,207866692	19,205021004	161,10226257	236,832302342
187	0,000085969	0,000085969	5,352694635e-007	0	0	0	0	0	0,002845688	19,207866692	19,205021004	161,10226257	236,832760031
188	0,00008597	0,00008597	5,163940536e-007	0	0	0	0	0	0,002997912	19,207895713	19,2048978	161,102855534	236,833400796
189	0,000085971	0,000085971	4,899686053e-007	0	0	0	0	0	0,003211026	19,207936342	19,204725316	161,103685684	236,834297866
190	0,000085973	0,000085973	4,529732238e-007	0	0	0	0	0	0,003509385	19,207993223	19,204483838	161,104847895	236,835553765
191	0,000085975	0,000085975	4,011801722e-007	0	0	0	0	0	0,003927088	19,208072856	19,204145768	161,106474989	236,837312024
192	0,000085975	0,000085977	4,478213216e-007	0	0	0	0	0	0,004400385	19,208072856	19,203672471	161,106474989	236,839773586
193	0,000085975	0,000085975	3,304272199e-007	0	0	0	0	0	0,003556734	19,208072856	19,204516123	161,106474989	236,837169702
194	0,000085975	0,000085975	2,313732637e-007	0	0	0	0	0	0,003038237	19,208072856	19,205034619	161,106474989	236,836970452
195	0,000085975	0,000085975	9,269807219e-008	0	0	0	0	0	0,002312342	19,208072856	19,205760514	161,106474989	236,836691502
196	0,000085976	0,000085976	1,014465156e-007	0	0	0	0	0	0,00129609	19,208072856	19,206776767	161,106474989	236,836300972
197	0,000085976	0,000085976	3,73247605e-007	0	0	0	0	0	0,000126664	19,208072856	19,20819952	161,106474989	236,83575423
198	0,000085976	0,000085977	1,783499007e-007	0	0	0	0	0	0,000976479	19,208072856	19,207096377	161,106474989	236,837003121
199	0,000085976	0,00008598	2,359447782e-007	0	0	0	0	0	0,001130012	19,208072856	19,206942844	161,106474989	236,841587868
200	0,000085974	0,000085974	3,170774925e-008	0	0	0	0	0	0,001515124	19,208072856	19,206557733	161,106474989	236,834932794
200	0,000085974	0,000050697	0,001246166	0	0	0	0	0	0,866364388	19,85324969	18,986885301	146,145157913	195,125403577
201	0,000085974	0,000085974	3,170774925e-008	0	0	0	0	0	0,001515124	19,208072856	19,206557733	161,106474989	236,834932794

Slika 49. Prikaz odstupanja rezultata od traženih zahtjevima

Konačan izgled grede i njene dimenzije vide se na slici (Slika 50).

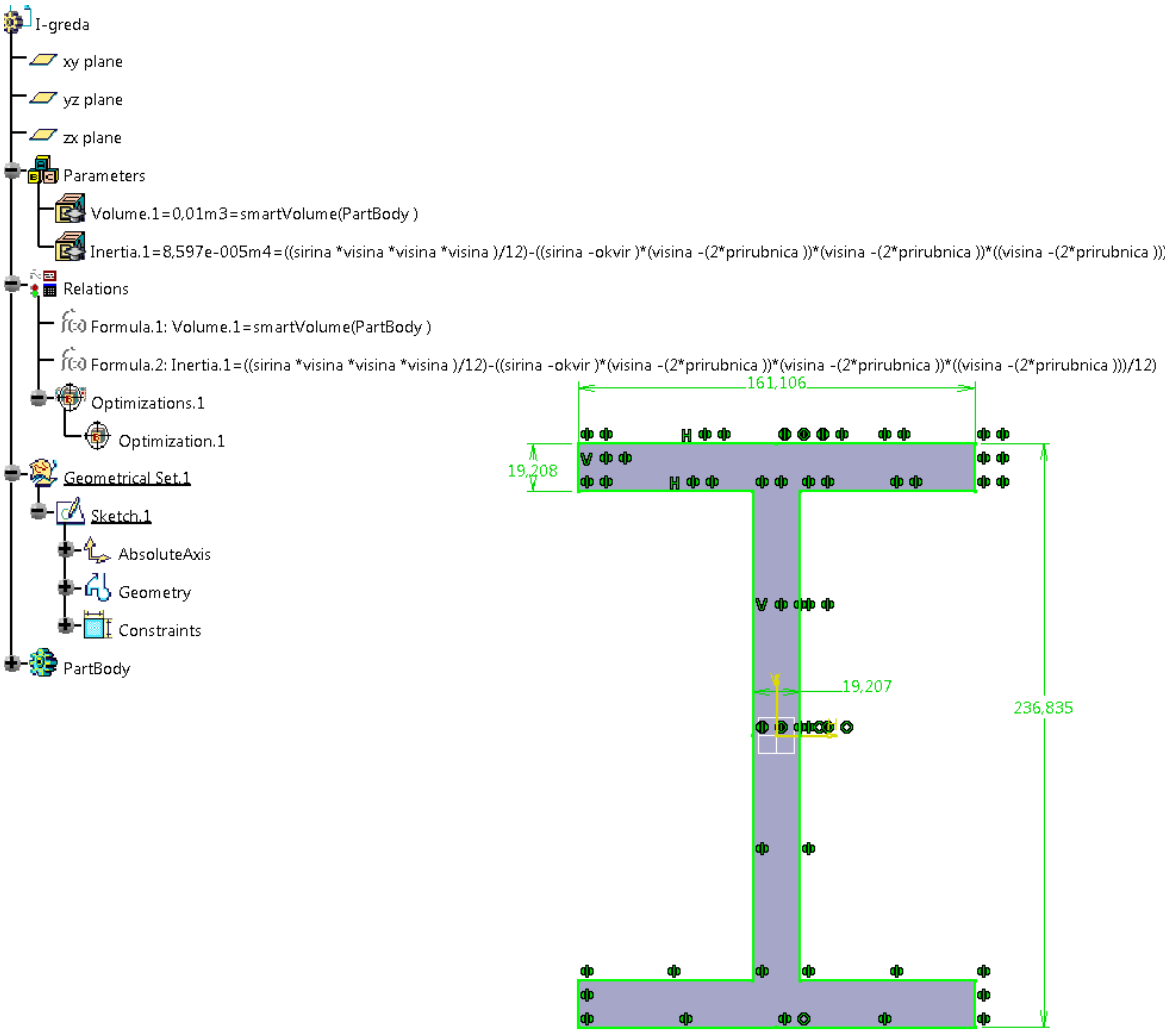

Slika 50. Konačan izgled i rezultati optimirane I-grede

3.5 Optimiranje viličastog nosača

U ovom primjeru htjela se optimiranjem smanjiti masa viličastog nosača za barem 15%. Uz to željelo se smanjiti i naprezanje (Maximum Von Misses). Htjelo se vidjeti koliki utjecaj na rezultate imaju vrijednosti brojeva koje se zadaju u „constraints“ pod „weight“.

Sveukupno su napravljene tri optimizacije koje su po svemu bile identične osim po brojevima u weight (tim brojem pridodalo se na važnosti pojedinog ograničenja, tj što je veći broj to je ograničenje značajnije za ispoštovat).

U „Part Designu“ je modeliran viličasti nosač, definirani su parametri i izmjerena je masa (Slika 51).

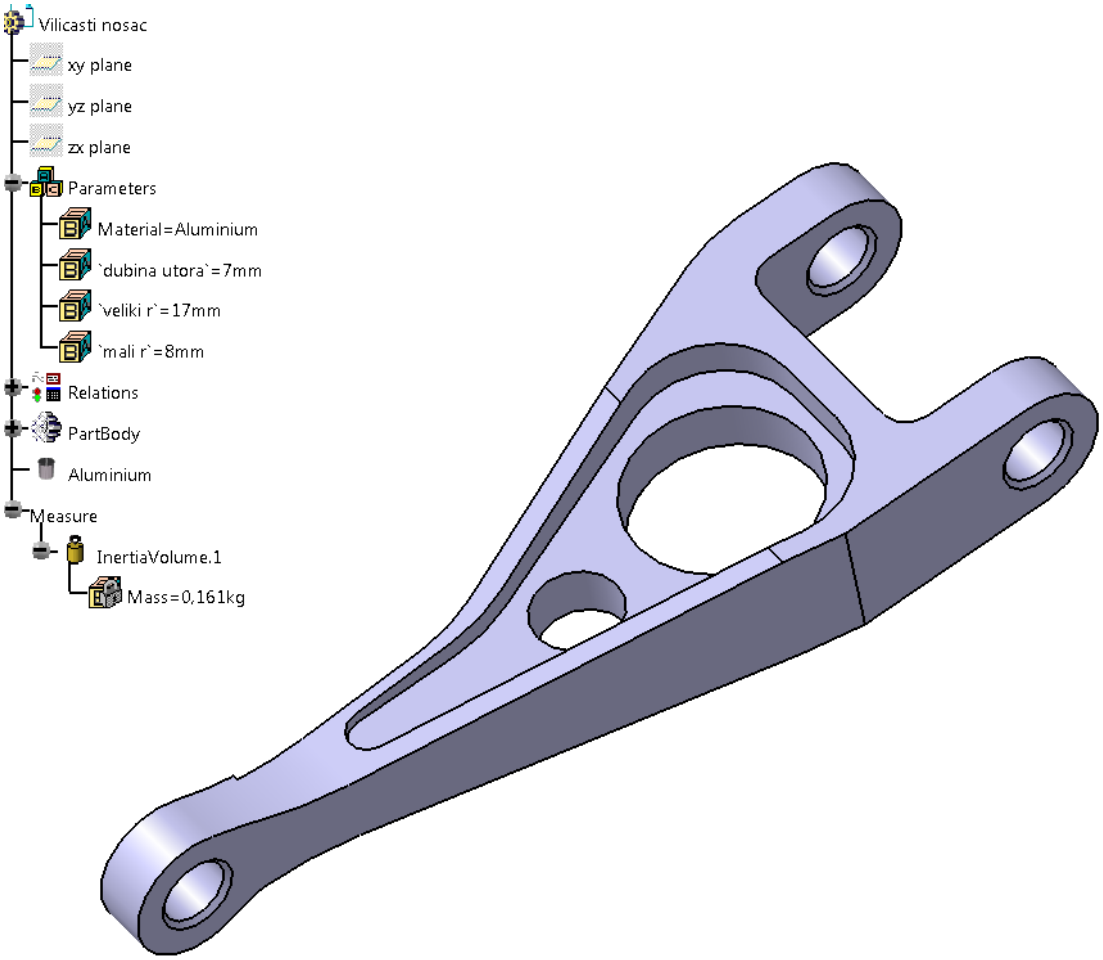

Slika 51. Izgled i parametri viličastog nosača

Za parametre su izabrane dimenzije koje neće utjecati na oblik nosača. Nazvane su „dubina utora“, „veliki r“ i „mali r“. Na što se točno ti parametri odnose vidi se na slikama (Slika 52 i Slika 53) To su dimenzije koje uz svoju brojčanu vrijednost imaju f(x).

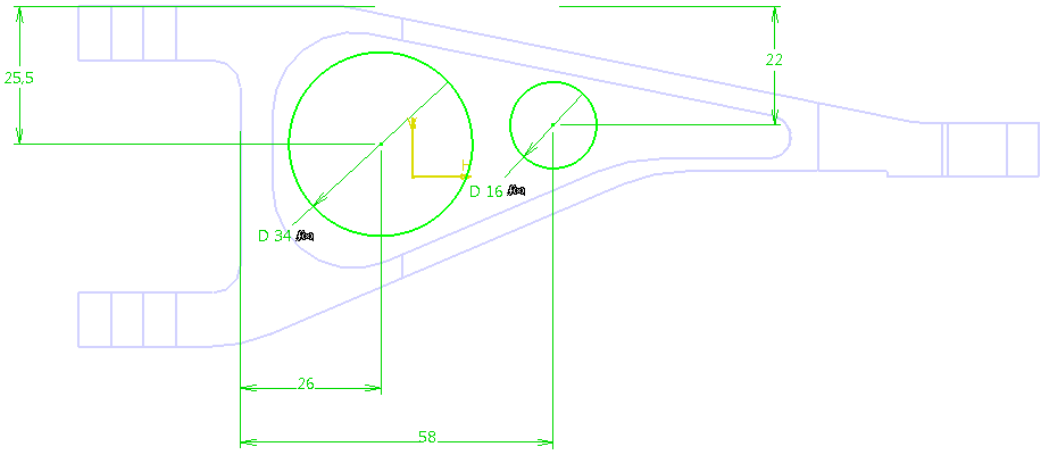

Slika 52. Prikaz parametara „veliki r“ i „ mali r“

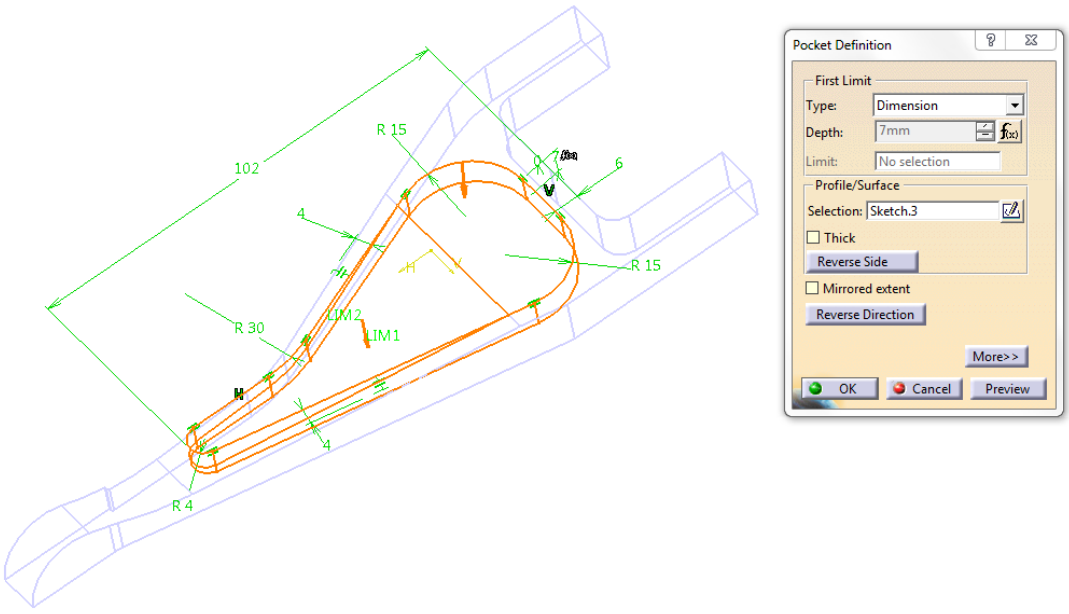

Slika 53. Prikaz parametra „dubina utora“

Za materijal viličastog nosača izabran je aluminij (Aluminium).

U „Generative Structural Analysis“ za konačne elemente izabrani su parabolični tetraedri čiji parametri (veličina i gustoća) mesha su 2mm i 1mm.

Viličasti nosač je na jednom kraju uklješten, a na drugom mu je definiran pomak (Enforced Displacement) od 0.254mm. U drvetu pod „Sensors“ izabrani su „Maximum von Mises“. Rezultati analize konačnih elemenata mogu se vidjeti na slici (Slika 54).

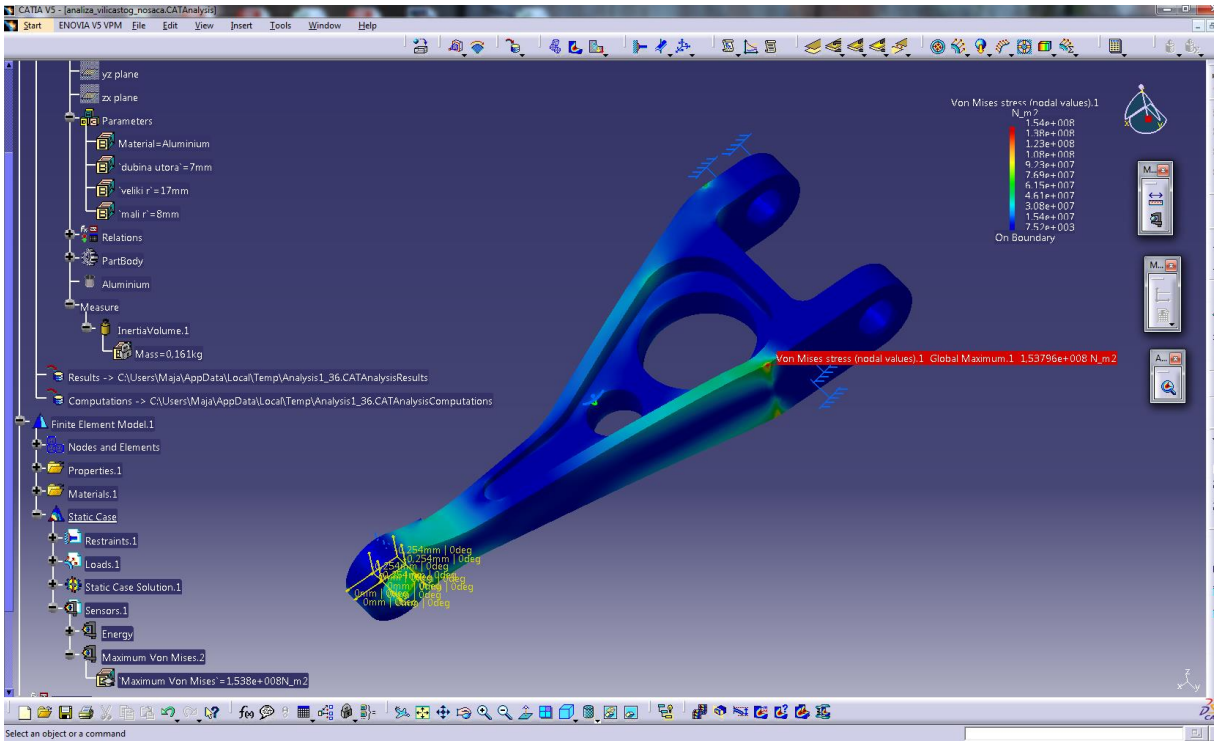

Slika 54. FEM analiza viličastog nosača

Idući korak je optimizacija nosača. Napravljene su tri optimizacije koje su jednake u svim segmentima osim u odabiru „težina“ (weight).

Uvjeti koji su identični u sva tri slučaja su:

Na kartici Problem: Optimization type: minimization

Optimized parameter: Mass

Free parameters: dubina_utora

veliki r

mali r

(za free parameters nije definiran raspon, ostavljen je na automatski)

Algorithm type: Simulated Annealing Algorithm

Convergence speed: Fast

Terminating criteria: 100, 20, 30

Na kartici Constraints: Maximum Von Misses<1.4e+008N_m2

Mass<=0.136kg

Dubina_utora<11mm

(htjelo se da nosač zadrži svoj „izvoran“ izgled jer već s 12mm je „šupalj“)

Veliki r<=19mm

Mali r<=9.5mm (tim dimenzijama rupe ostaju unutar utora)

Veliki r- mali r>0mm

U prvoj optimizaciji (optimization.1) vrijednosti za weight: su:

Maximum Von Misses - 5

Mass - 5

Dubina_utora - 1

Veliki r - 1

Mali r - 1

Veliki r-mali r – 1

Rezultati prve optimizacije vide se na slici (Slika 55).

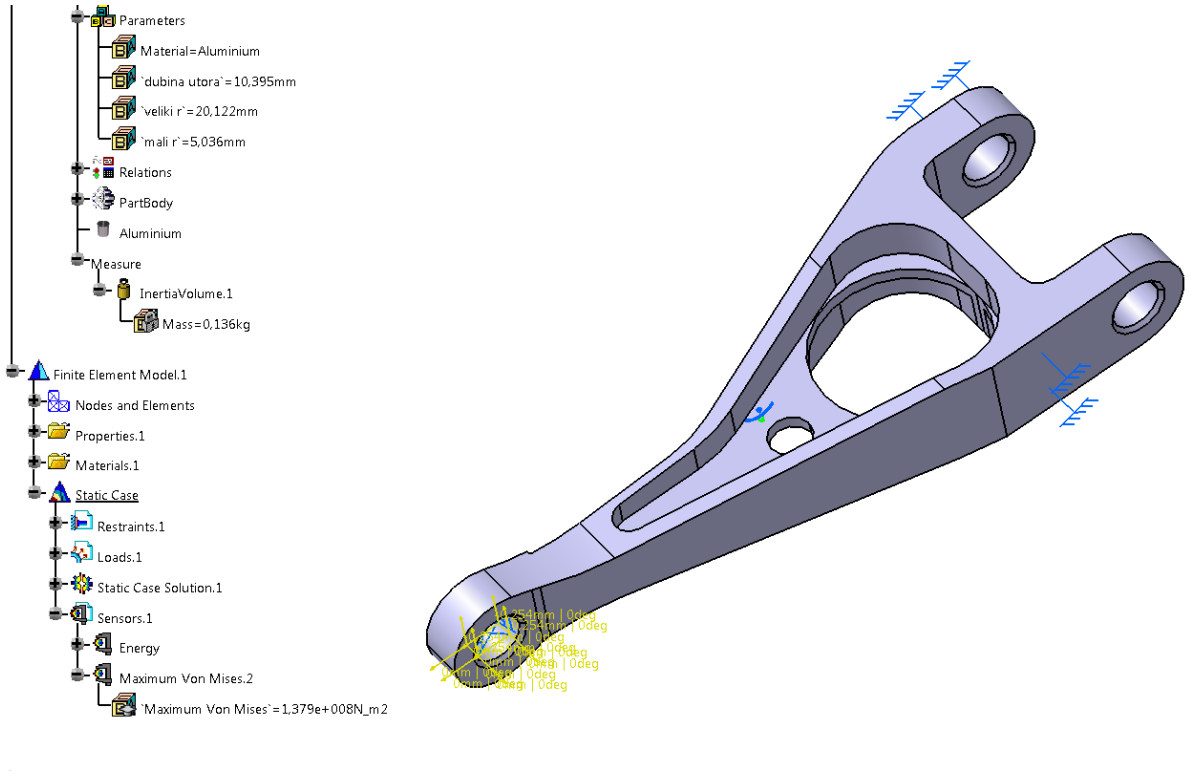

Slika 55. Izgled i rezultati prve optimizacije viličastog nosača

Ako se malo bolje pogledaju rezultati, vidi se kako svi traženi uvjeti nisu ispunjeni (Slika 56).

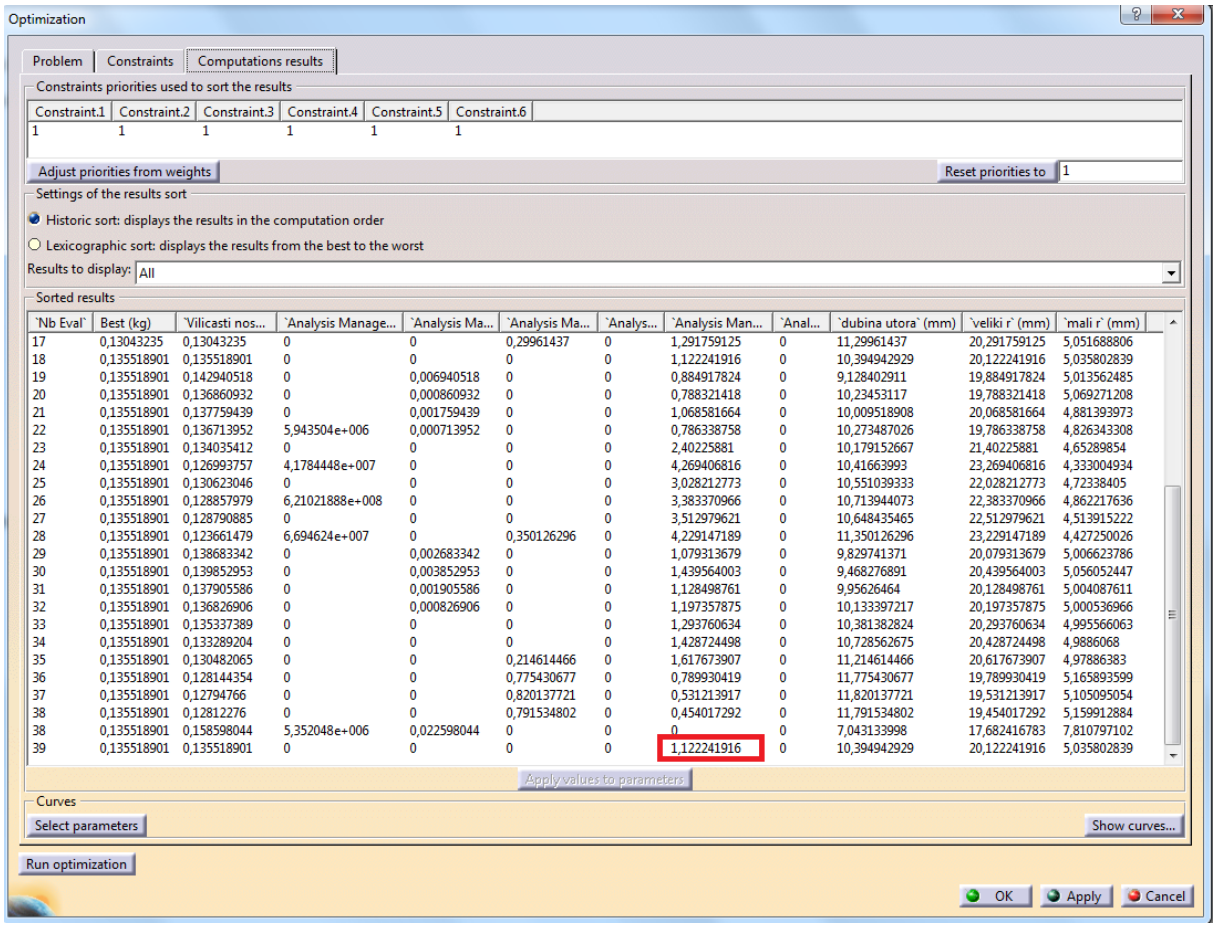

Slika 56. Tablica s rezultatima prve optimizacije

„Veliki r“ je veći od 19mm i samim time ulazi u tijelo nosača što se htjelo izbjeći.

U drugoj optimizaciji (optimization.2) vrijednosti za weight su:

Maximum Von Misses - 5

Mass - 5

Dubina_utora - 3

Veliki r - 3

Mali r - 3

Veliki r-mali r – 1

Rezultati druge optimizacije vide se na slici (Slika 57).

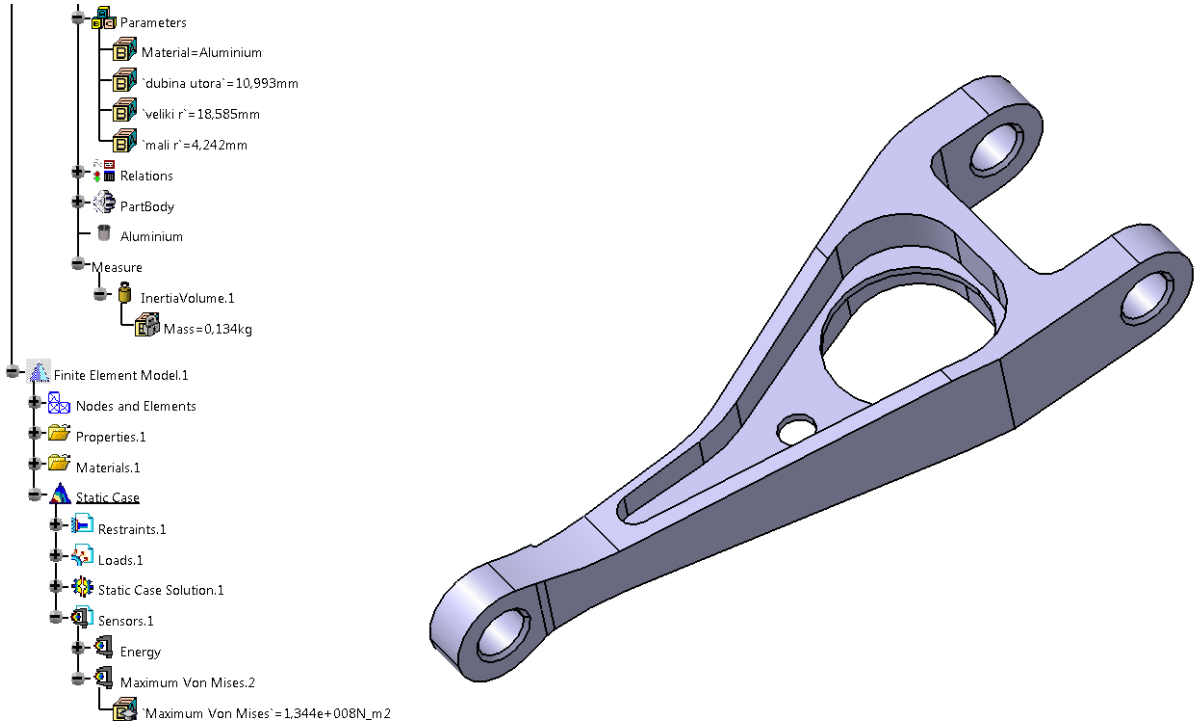

Slika 57. Izgled i rezultati druge optimizacije viličastog nosača

Najbolje ponuđeno rješenje ima ispunjene sve zadane uvjete. To se može vidjeti na slici (Slika 58) gdje rješenje pod brojem 51 u stupcima koji predstavljaju postavljena ograničenja sve vrijednosti su nula. Nule znače da nema odstupanja od traženih rješenja.

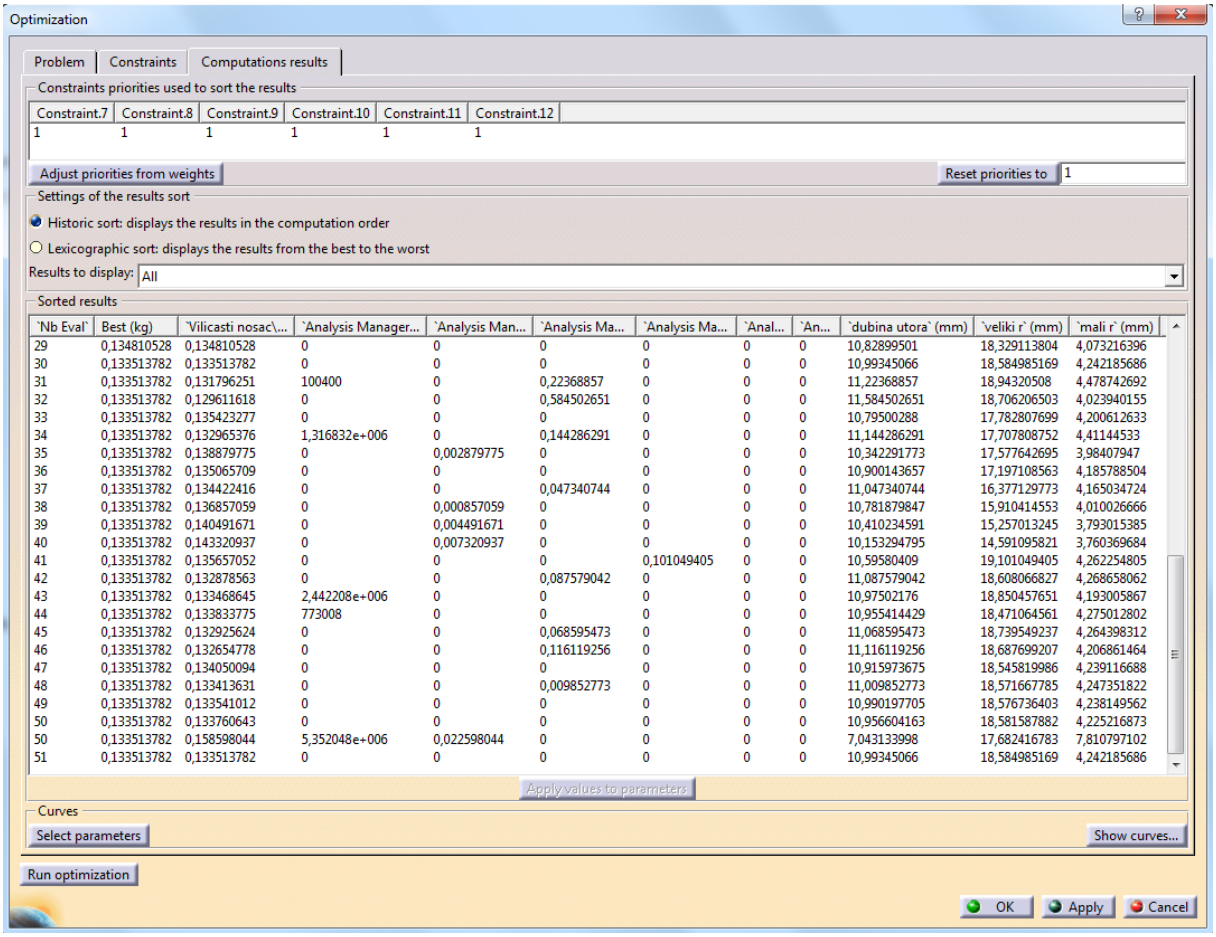

Slika 58. Tablica s rezultatima druge optimizacije

U trećoj optimizaciji (optimization.3) vrijednosti za weight: su:

Maximum Von Misses - 1

Mass - 1

Dubina_utora - 1

Veliki r - 1

Mali r - 1

Veliki r-mali r - 1

Rezultati treće optimizacije vide se na slici (Slika 59).

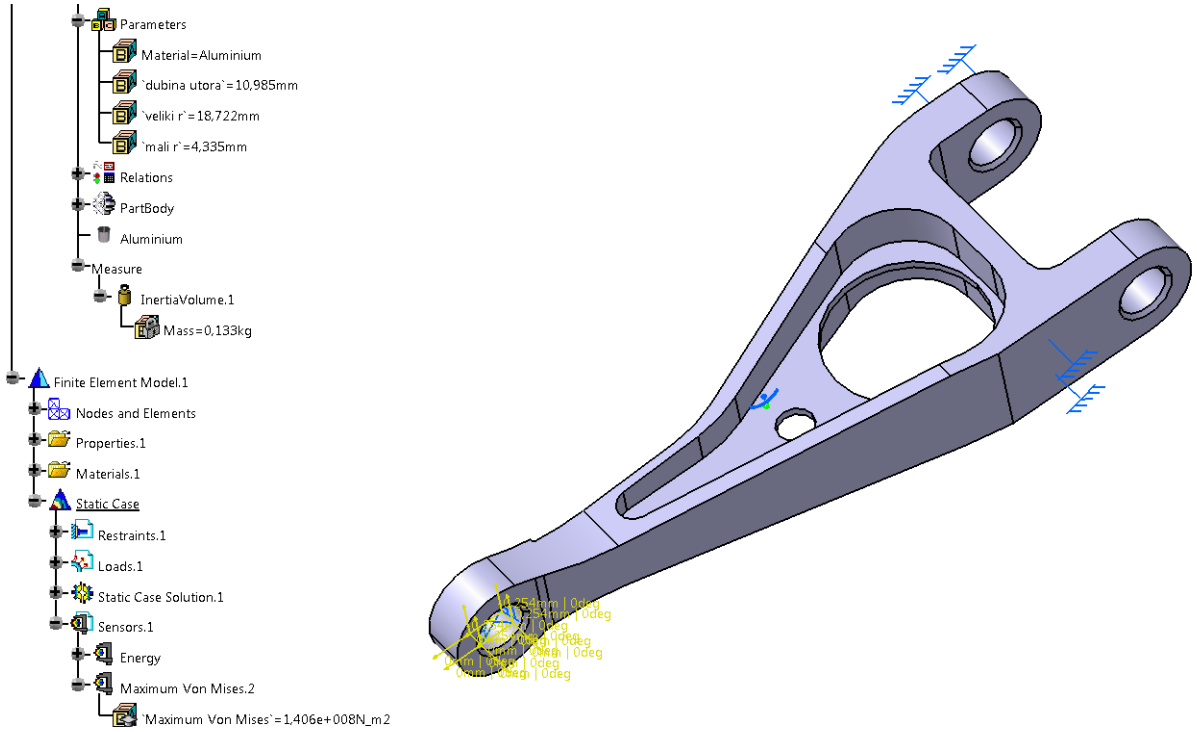

Slika 59. Izgled i rezultati treće optimizacije viličastog nosača

Najbolje rješenje čiji rezultati se vide na slici (Slika 59) ne zadovoljava sve uvjete jer je Maximum Von Misses veće od 1.4e+008N_m2.

Ali ako se gleda tablica s rješenjima na kartici „Computation results“, rezultati koji su primijenjeni na model u stupcima di se nalaze ograničenjima imaju sve nule. Što bi trebalo značiti da su svi uvjeti ispunjeni. U plavom pravokutniku u tablici nalazi se vrijednost odstupanja za uvjet Maximum Von Misses<1.4e+008N_m2 (Slika 60).

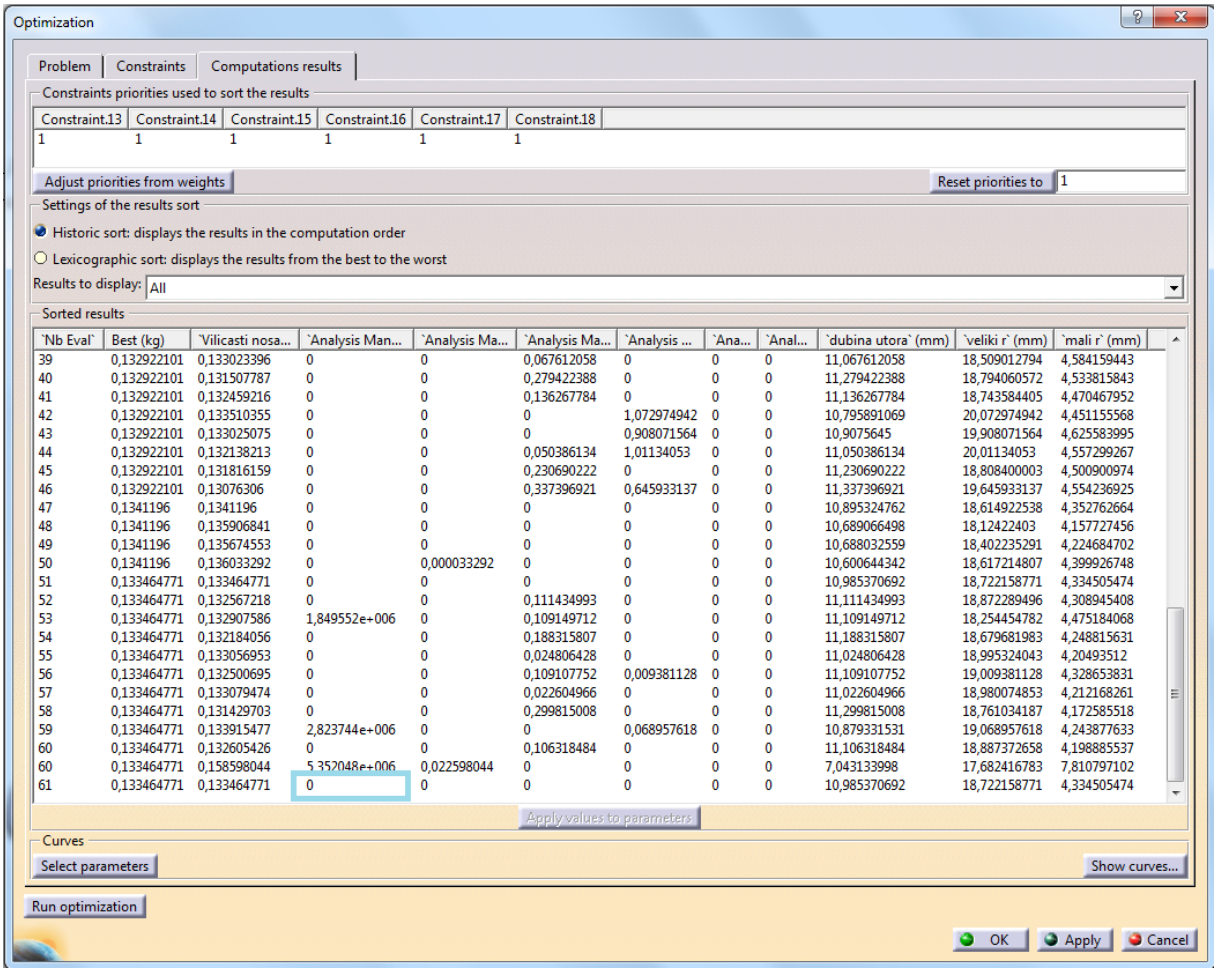

Slika 60. Tablica s rezultatima treće optimizacije

Zbog ne slaganja u rezultatima ponovljena je analiza konačnih elemenata za dimenzije dobivene optimiranjem. Rezultati su identični onima koji se vide na slici. (Slika 59)

Ali povratkom na radno okruženje „Product Engineering Optimizer“ i u optimizaciju, na kartici „Constraints“ vidi se kako uvjet ipak nije zadovoljen bez obzira što i dalje na kartici „Computation results“ stoje isti rezultati (Slika 61).

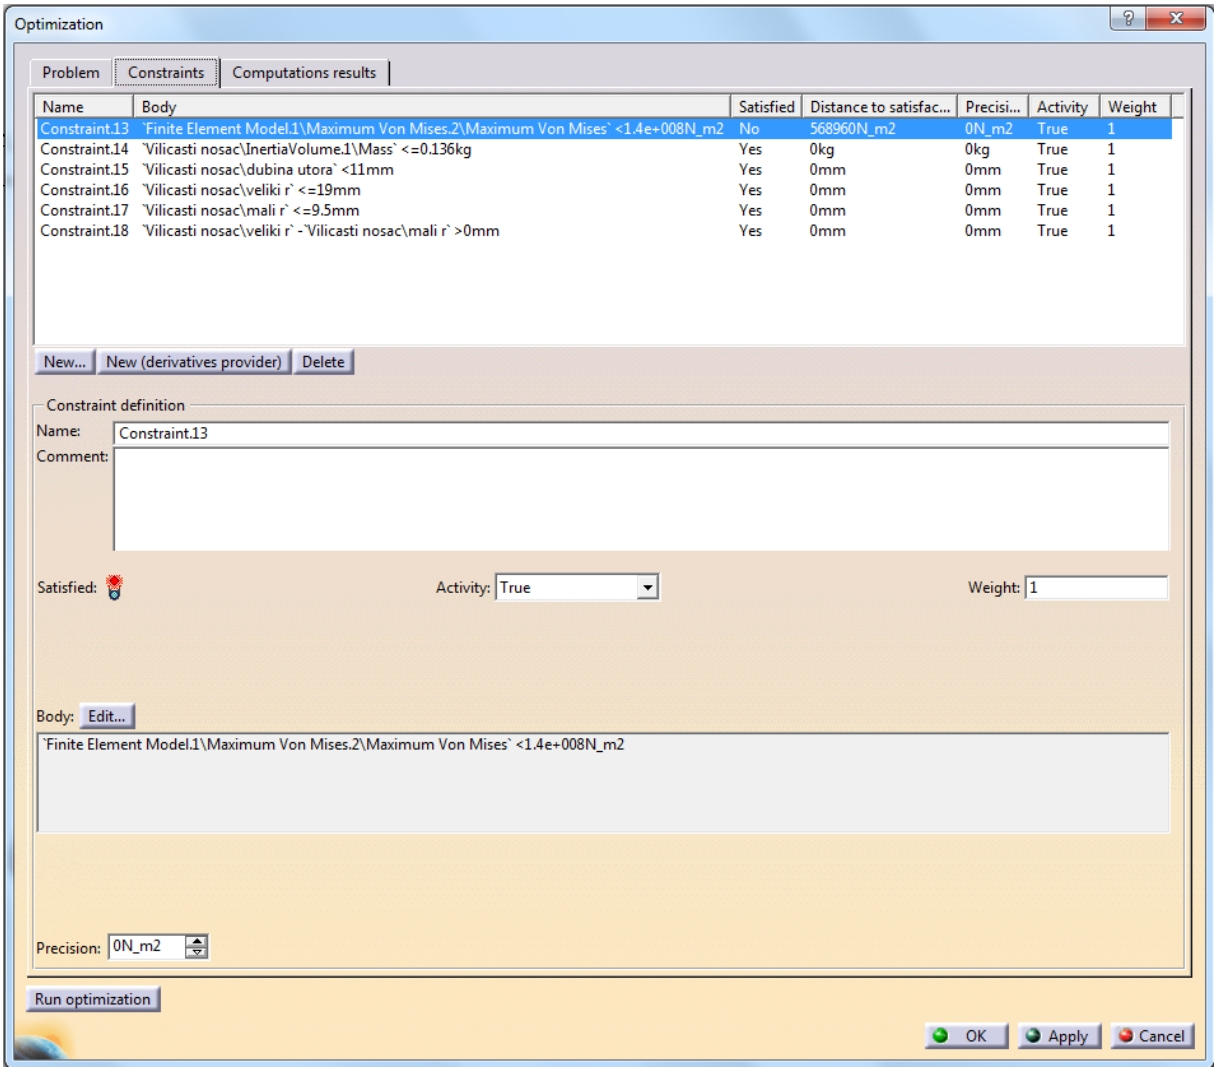

Slika 61. Rezultati nakon ponovljene FEM analize

Tu se vidi kako ponekad nije jednostavno doći do traženog rješenja, te da je potrebno vratiti se korak u nazad (u ovom slučaju analiza konačnih elemenata) da bi se dodatno provjerili rezultati.

U ovom primjeru jedino je druga optimizacija dala željene rezultate. Time se pokazalo da i davanje prioriteta ograničenjima ima utjecaj na konačni rezultat.

4. ZAKLJUČAK

Optimiranje konstrukcije u svrhu smanjenja mase je vrlo zahtjevan posao. Potrebno je veliko predznanje i iskustvo kako bi optimizacijom došli do optimalnih parametara konstrukcije.

Vrlo je bitno kod same optimizacije konstrukcije s naglaskom na smanjene mase da se sačuvaju prvobitni ulazni parametri tj. funkcionalnost konstrukcije. Važno je definirati ulazne parametre tj. dimenzije koje se mogu mijenjati, a da se pri tome ne gube prvobitna funkcionalna svojstva modela

CATIA modul za optimizaciju bez obzira što ima samo dio mogućnosti optimiranja, u usporedbi s nekim drugim programskim paketima, nudi veliki spektar opcija kako doći do željenog rješenja.

Kombiniranjem različitih postavki od vrste algoritma, brzine optimiranja, pa do dodavanja na važnosti pojedinih ograničenja za isti problem moguće je dobiti različite rezultate. Zbog toga je bitno razumjeti što koja od postavki točno znači, te kako izabrati najbolju kombinaciju za postići najbolji rezultat.

PRILOZI

I. CD-R disk

LITERATURA

[1] Fred Karam, Charles Kleismit: CATIA V5, Kompjuter biblioteka Beograd, 2004.

[2] http://catia-v5-cad.blogspot.hr/2013/03/catia-v5-cad-cam-introduction.html

[3] http://catiadesign.org/_doc/v5r14/catpdfkwoug_C2/kwoug.pdf

[4] http://4dmsco.com/solutions/catia/catia-v5-plm-express-cat/catia-v5-plm-express-optimize-and-review/catia-v5-knowledge-expert-and-engineering-optimization-kox/

[5] http://mbi-wiki.uni-wuppertal.de/wp-content/uploads/2011/06/Product-engineering-optimisation-using-CATIA-V5.pdf

[6] CadCam Design Centar: CATIA V5 Knjiga 3, Ljubljana,2003.