

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geofizički odsjek

Tonko Bogovac

Lorenzov energetska ciklus atmosfere
simuliran modelom SPEEDY i utjecaj
ENSO-a

Diplomski rad

Zagreb, 2019.

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geofizički odsjek

Diplomski sveučilišni studij Fizika – Geofizika
Smjer: Meteorologija i fizička oceanografija

Tonko Bogovac

Diplomski rad

Lorenzov energetska ciklus simuliran modelom SPEEDY i utjecaj ENSO-a

Voditeljica diplomskog rada: izv. prof. dr. sc. Ivana Herceg Bulić

Povjerenstvo: 1. _____
2. _____
3. _____

Ocjena diplomskog rada: _____

Zagreb, 2019.

Dragim roditeljima, majci Ivani i ocu Aleksandru, ali i sestri Hani, hvala vam što ste omogućili i podržali studij koji je rezultirao ovim radom, kako u teškim, tako i u lijepim trenucima. Također veliko hvala i dragim kolegama sa studija, a posebno Niku s kojim visokoškolske klupe dijelim još od upisa na studij, jer su brojne trenutke učinili vedrijim, a potragu za znanjem zabavnijom i lakšom. Hvala i mentorici, Ivani Herceg Bulić, na strpljenju te pomoći pri istraživanju teme ovog diplomskog rada.

Sažetak

U ovom radu korišten je rezultat 35-članog ansambla simulacija modelom SPEEDY koji je forsiran donjim rubnim uvjetom u obliku površinske temperature mora kako bi se izvrjednili članovi energije u Lorenzovom ciklusu. Rezultantni članovi raspoložive poencijalne energije i srednje zonalne kinetičke energije, te istoimeni članovi makroporemećaja prikazani su u pregledu za razdoblje od 1855. do 2010. godine u obliku srednjih godišnjih vrijednosti i srednjih sezonskih vrijednosti za sezone DJF i JJA, ali i u vertikalnom te u longitudinalno-vertikalnom presjeku. Izračunat je i NINO 3.4 indeks za određivanje faze El Niño - Južne oscilacije (ENSO), a na temelju indeksa određeni su El Niño i La Niña događaji, te su članovi Lorenzovog ciklusa promotreni dodatno u obliku kompozita za sve El Niño i La Niña događaje od 1855. do 2010. godine. Utvrđeno je da model SPEEDY zadovoljavajuće reproducira energiju zonalnog strujanja dok za članove makroporemećaja nije jednako uspješan. Utjecaj ENSO faza na članove Lorenzovog ciklusa je uočen i pokazao se najjačim za zimske hemisfere. Ključne riječi: Lorenzov energetski ciklus, model SPEEDY, El Niño - Južna oscilacija, ENSO, El Niño, La Niña

Lorenz energy cycle simulated with the model SPEEDY and the impact of ENSO

Abstract

This thesis uses the products of a 35-member ensemble simulated with the model SPEEDY with forcing applied to the model's lower boundary conditions in the form of sea surface temperatures to calculate energy reservoirs in the Lorenz energy cycle. Available potential energy and mean kinetic energy, as well as their eddy counterparts, are evaluated for the time period from 1855 until 2010 in the form of yearly averages as well as seasonal averages for the DJF and JJA seasons with their vertical profiles and longitude-altitude cross sections also discussed. NINO 3.4 index is calculated for the aforementioned time interval, allowing for the identification of El Niño - Southern Oscillation phases, El Niño and La Niña, and the discussion of Lorenz energy cycle in the context of those events. Model SPEEDY adequately reproduces zonal-mean energy while the same is not true for eddy energy. ENSO is shown to have an impact on Lorenz energy cycle components with the greatest impact in the winter hemisphere.

Keywords: Lorenz energy cycle, model SPEEDY, El Niño - Southern Oscillation, ENSO, El Niño, La Niña

Sadržaj

1. Uvod	1
1.1. Lorenzov energetski ciklus	1
1.2. El Niño - Južna oscilacija	2
2. Teorijski uvod	4
2.1. Ukupna potencijalna energija	4
2.2. Raspoloživa potencijalna energija	5
2.3. Kinetička energija	6
2.4. Lorenzov energetski ciklus u prostorno-vremenskoj domeni	7
3. Metode i podatci	9
3.1. Podatci i numerički model SPEEDY	9
2.1.1. Jezgra SPEEDY modela	9
2.1.2. Pregled fizičkih parametrizacija	9
2.1.2. Rubni uvjeti	10
3.2. Metode obrade podataka	11
2.2.1. Programi korišteni za obradu podataka	11
2.2.2. Metode usrednjavanja	11
2.2.3. Integracija tabličnih vrijednosti Newton-Cotesovim formulama	12
2.2.4. Članovi Lorenzovog energetskog ciklusa	15
2.2.5. NINO 3.4 indeks	17
4. Rezultati i diskusija	18
4.1. NINO 3.4 indeks	18
4.2. Srednja raspoloživa potencijalna energija P_M	19
4.3. Zonalna kinetička energija K_M	24
4.4. Raspoloživa potencijalna energija makroporemećaja P_E	30
4.5. Kinetička energija makroporemećaja K_E	37
5. Zaključak	44
Literatura	45

1. Uvod

Zemljinu atmosferu možemo promatrati kao energetska sustav: energija dolazi sa Sunca, a zahvaljujući atmosferskim procesima zagrijavanja, gibanja, mješanja i hlađenja, ta ista energija se raspodijeljuje kroz cijelu atmosferu. Procesi od izrazito velike vremenske i prostorne skale poput El Niño - Južne oscilacije (na dalje pišemo skraćeno ENSO za eng. El Niño - Southern Oscillation) mogu utjecati na globalnu atmosfersku cirkulaciju. U ovom radu promotrit ćemo utjecaj ENSO-a na raspodjelu energije u globalnoj cirkulaciji atmosfere kakvu je opisao Lorenz u, po njemu nazvanom, Lorenzovom energetskom ciklusu.

1.1. Lorenzov energetski ciklus

Zemljina atmosfera sustav je kojim konstantno kruži energija: ista dolazi od Sunca, a kroz različite fizičke procese raspodijeljuje se kroz cijeli sustav. Postoje različiti načini promatranja raspodjele energije, a Lorenz (1955) je postavio opis raspodjele i kruženja energije u atmosferi na koji se oslanjamo u ovom radu. Lorenz (1955) je uveo i pojam raspoložive potencijalne energije (engl. *available potential energy*) kao mjere za količinu energije koja se može preći u kinetičku energiju.

Izmjena energije iz raspoložive potencijalne energije u kinetičku energiju omogućuje pokretanje atmosferskih procesa koje možemo svakodnevno uočiti, stoga je razumijevanje međuodnosa između tih mjera energije kao i procesa poput ENSO-a od velike važnosti za razumijevanje atmosferskih procesa koji definiraju vrijeme, a time i za njegovu prognozu. Lorenzov energetski ciklus obuhvaća izvor energije za procese na Zemlji u obliku raspoložive potencijalne energije dobivene zagrijavanjem tropa i istovremenog hlađenja polova. Takvim diferencijalnim zagrijavanjem Zemlje ostvaruje se energetski višak u tropskim područjima, a manjak u polarnim područjima. Prijenos energije iz tropa u polarne krajeve vrši se baroklinim poremećajima - hladni zrak ide k Ekvatoru dok topli ide k polovima, a time se raspoloživa potencijalna energija preraspodijeljuje u potencijalnu energiju makroporemećaja. Vertikalnim gibanjem potom ostavaramo i prijelaz iz potencijalne u kinetičku energiju makroporemećaja. Zonalna kinetička energija preuzima energiju od kinetičke energije makroporemećaja, a ciklus se zatvara disipacijom energije trenjem.

Dugoročno, takav sustav mora biti u nekoj vrsti ravnoteže - u suprotnom bi se u sustavu gomilala energija. Upravo iz tog razloga stoji i tvrdnja da dugoročno procesi stvaranja (tj. ulaska) energije u sustav moraju biti u ravnoteži s procesima disipacije energije putem trenja, kako je naveo Holton (2004).

Globalna cirkulacija atmosfere ovisna je o uvjetima unutar same atmosfere: iako energija u sustav atmosfere ulazi izvana, procesi u samoj atmosferi mogu promijeniti raspodjelu energije na globalnoj skali. Jedan takav proces je i ENSO. Uz pomoć

rezultata numeričkih simulacija modelom SPEEDY, u ovom radu su procijenjene komponente energetskog ciklusa atmosfere te doprinos ENSO-a (tj. događaja El Niño i La Niña) na raspodjelu energije u sustavu atmosfere.

1.2. El Niño - Južna oscilacija

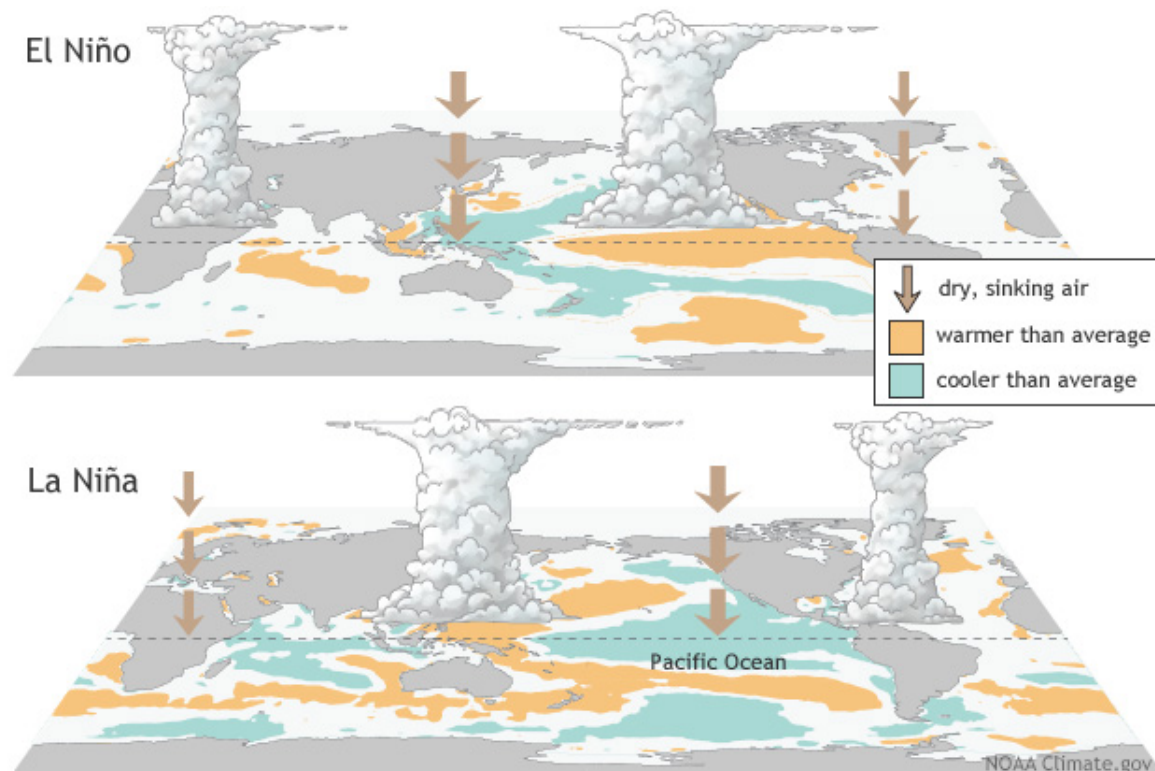
El Niño - Južna oscilacija ili ENSO označava međudjelovanje atmosfere i oceana na Pacifiku koje uočavamo u obliku nepravilnih međugodišnjih oscilacija u poljima tlaka, površinske temperature mora, ali i ostalih meteoroloških parametara. Unutar atmosferskog sustava govorimo o Južnoj oscilaciji koju je uočio Walker, a odnosi se na anomalije površinskog tlaka na zapadnom i istočnom Pacifiku. Izrazite anomalije tlaka vezane su uz veliku razliku tlakova između Darwina, Australija i Tahitija, Francuska Polinezija, (naime, anomalije tlaka na ta dva mjesta mjerenja su negativno vezane) što uzrokuje jačanje ćelije strujanja zraka, a posljedično diktira i anomaliju oborine zajedno s njenim položajem. Upravo te anomalije imaju izražene promjene s periodom od dvije do pet godina.

Walkerova ćelija, tj. horizontalna raspodjela tlaka između Darwina i Tahitija, utječe na pasate koji posljedično mogu jačati ili slabiti, ovisno o fazi Južne oscilacije. Misaono promotrimo slučaj negativne anomalije površinske temperature na istoku Pacifika: zbog niže temperature mora javlja se slabije isparavanje vode s morske površine, a posljedica slabijeg isparavanja je manji sadržaj vlage u zraku, pa tako i viši tlak. Pozitivna anomalija tlaka nad istočnim Pacifikom djeluje pogodno za pasate, jačajući površinsko strujanje zraka k zapadu. Na zapadnom dijelu tropskog Pacifika je tada niži tlak, te se javlja vertikalno konvektivno strujanje koje prati i kondenzacija vodene pare odnosno povećana vlažnost zraka, a razvija se i konvektivna naoblaka što za posljedicu ima i obilniju oborinu.

Drugim riječima, na zapadu, zbog nižeg tlaka, imamo uzlazno gibanje zraka koji na višim visinama divergira i giba se k istoku gdje dolazi do supsidencije, osiguravajući pozitivnu anomaliju tlaka na istoku i onemogućujući konvekcijske procese u tom području. Takva cirkulacija zatvara Walkerovu ćeliju u vertikali, a gore opisana situacija odgovara pojavi La Niña - prepoznamo je po negativnoj anomaliji površinske temperature mora na istoku Pacifika. Suprotnu situaciju od gore navedene imamo kad na istočnom Pacifiku prevladava pozitivna anomalija površinske temperature mora, a tu pojavu nazivamo El Niño, navodi Holton (2004).

Južna oscilacija predstavlja atmosfersku komponentu fenomena ENSO, a El Niño i La Niña odnose se na pripadajuću oceansku komponentu primarno okarakteriziranu toplijom (El Niño) odnosno hladnijom (La Niña) površinskom vodom od uobičajenog na istočnom Pacifiku. Za vrijeme La Niñe izraženo djelovanje pasata odnosi toplu površinsku vodu k zapadu, što za posljedicu ima izviranje dubinske hladne vode na

istoku, zajedno s anomalno plitkim položajem termokline te niskom morskom razinom. Na zapadnom Pacifiku se akumulira topla površinska morska voda, a ujedno se i spušta termoklina. Topla površinska voda na zapadu ponire, te se hladi putujući ponovno k istočnom Pacifiku gdje izvire, zatvarajući cirkulacijsku ćeliju pod površinom oceana. Protufaza La Niña je El Niño tijekom kojeg se odvija sličan proces cirkulacije, ali u suprotnom smjeru, zajedno sa suprotnim anomalijama.



Slika 1.1. Grafički prikaz El Niño i La Niña faza ENSO-a u atmosferi i utjecaj na srednju temperaturu mora. Izvor: NOAA Climate.gov

Iako se ENSO naizgled čini zatvoren na području Pacifika, analiza podataka u korelaciji s NINO 3.4 indeksom, mjerom intenziteta El Niño i La Niña događaja odnosno faza ENSO-a, pokazala je da prevladavajući meteorološki uvjeti u području središnjeg Pacifika imaju mjerljiv utjecaja na meteorološke uvjete u ostatku svijeta, a dosadašnja istraživanja su pokazala da je ENSO globalni generator klimatske varijabilnosti. Utjecaj ENSO-a na udaljena područja ostvaruje se daljinskim vezama (engl. *teleconnections*), a utjecaj je vidljiv u poljima vjetrova, oborine i temperature s pojedinim učincima izraženima ovisno o sezoni u kojoj prevladava faza ENSO-a, navode Davey et al. (2014). Utjecaj ENSO-a na gospodarsku i ljudsku djelatnost je značajan, stoga postoji i velik interes za predviđanje El Niño i La Niña faza, kao i utjecaja tih faza na vremenske prilike u ostatku svijeta. Osim energetskog ciklusa atmosfere, u ovom je radu promatran i utjecaj ENSO-a na komponente tog ciklusa.

2. Teorijski uvod

U ovom poglavlju prikazane su postavke Lorenzovog energetskog ciklusa koji je uveo Lorenz (1955), a nadopunili su Peixóto i Oort (1974).

2.1. Ukupna potencijalna energija

Za potrebe ovog rada uvodimo pojam raspoložive potencijalne energije kakvim ga je uveo Lorenz (1955) na temelju prethodno uvedene ukupne potencijalne energije koju je definirao Margules (koristimo se prijevodom originalnog rada autora Marquet (2017)), a raspis slijedimo po opisu koji je naveo Salby (2012): kako unutarnja i potencijalna energija u stupcu zraka imaju konstantan omjer, moguće je ukupnu potencijalnu energiju istog stupca izraziti upravo kao zbroj unutarnje i potencijalne energije:

$$dU = \rho C_v T dz \quad (2.1.)$$

S gore napisanom jednadžbom za unutarnju energiju izvršit ćemo integraciju kroz stupac zraka jedinične površine.

$$U = C_v \int_0^\infty \rho T dz \quad (2.2.)$$

Za slučaj potencijalne energije P koristit ćemo se parcijalnom integracijom, s tim da ćemo postojeći minus uveden zbog hidrostatičke aproksimacije iskoristiti kako bi integrirali u smjeru porasta tlaka.

$$dP = \rho g z dz = -z dp \quad (2.3.)$$

$$P = \int_{p(z)}^{p_s} z' dp' = z' p' \Big|_{p_s}^{p(z)} + \int_0^z p dz' = -z p(z) + R \int_0^z \rho T dz' \quad (2.4.)$$

U slučaju kad z teži u beskonačnost, potencijalna energija se svodi na jednadžbu (2.5.).

$$P = R \int_0^z \rho T dz \quad (2.5.)$$

Napravimo li omjer potencijalne energije P i unutarnje energije U , uočavamo da je njihov omjer za stupac zraka konstantan.

$$\frac{P}{U} = \frac{R}{C_v} \quad (2.6.)$$

Upravo iz tog razloga, ukupna potencijalna energija predstavlja spremnik energije i svaka promjena energije u tom spremniku mora očuvati omjer potencijalne i unutarnje energije. Margules je uveo zbroj te dvije energije kao ukupnu potencijalnu energiju (2.7.), navedeno je u radu Marquet (2017).

$$TPE = P + U = \int_0^\infty \rho C_p T dz \quad (2.7.)$$

Za adijabatičku atmosferu jedini izvor kinetičke energije su potencijalna i unutarnja energija, odnosno ukupna potencijalna energija.

2.2. *Raspoloživa potencijalna energija*

Lorenz (1955) je prilikom opisa energetske ciklusa atmosfere vrlo jednostavno utvrdio da je ukupna potencijalna energija loš pokazatelj koliko je energije u atmosferi raspoloživo za prijelaz u kinetičku energiju: promotrimo li atmosferu s jednolikom horizontalnom stratifikacijom gustoće jasno je da posjeduje veliku ukupnu potencijalnu energiju, ali takva stratifikacija ne omogućava gibanje pa je energija raspoloživa za prijelaz u kinetičku energiju u ovom slučaju jednaka nuli. Margules je dao naslutiti postojanje veličine koja određuje koliko je potencijalne energije raspoloživo za prijelaz u kinetičku energiju, a primarno bi se oslanjala na raspodjelu mase u zatvorenom sustavu. Upravo tu veličinu uvodi Lorenz (1955) i naziva ju raspoloživa potencijalna energija (engl. *available potential energy*, skraćeno APE).

Lorenz (1955) uzima da je potencijalna energija raspoloživa za prijelaz u kinetičku energiju pohranjena u odstupanju atmosfere od barotropne stratifikacije. Drugim riječima, u barotropnoj stratifikaciji raspoloživa potencijalna energija poprima minimalnu vrijednost. Lorenz (1955) definira APE kao razliku ukupne potencijalne energije atmosfere od ukupne potencijalne energije pri barotropnoj stratifikaciji postignutoj adijabatičkom preraspodjelom mase. Dodatno, Lorenz (1955) navodi i svojstva tako definirane raspoložive potencijalne energije:

- Zbroj raspoložive potencijalne energije i kinetičke energije u adijabatičkim procesima je očuvan
- APE je u potpunosti određen raspodjelom mase
- APE je pozitivan za baroklinu stratifikaciju, a jednak nuli za barotropnu stratifikaciju

Lorenz tako izvodi sljedeći izraz za prosječni APE za stupac jedinične površine koristan za usporedbu s TPE.

$$\overline{APE} = \frac{1}{2} \int_0^\infty \overline{T}(\Gamma_d - \overline{\Gamma})^{-1} \overline{\left(\frac{T'}{\overline{T}}\right)^2} dp \quad (2.8.)$$

U izrazu (2.8.) \overline{T} označava prosječnu temperaturu, T' je vremensko odstupanje temperature od prosjeka, Γ_d je suho-adijabatička stopa ohlađivanja dok je $\overline{\Gamma}$ prosječni vertikalni temperaturni gradijent, a dp diferencijal tlaka. Ako kao tipične vrijednosti uzmemo $\overline{\Gamma} = \frac{2}{3}\Gamma_d$, a za $\overline{T'^2} = (15^\circ C)^2$, za omjer APE i TPE dobivamo:

$$\frac{\overline{APE}}{\overline{TPE}} \sim \frac{1}{200} \quad (2.9.)$$

Prema ovom rezultatu, manje od 1% ukupne potencijalne energije je raspoloživo za prijelaz u kinetičku energiju, navodi Lorenz (1955).

2.3. *Kinetička energija*

Prije nego pređemo na izraze koji su korišteni u ovom radu, razmotrimo analitički izraz za kinetičku energiju kakav daje Lorenz (1955):

$$\overline{K} = \frac{1}{2g} \int_0^{p_0} \overline{V^2} dp \quad (2.10.)$$

U izrazu g označava akceleraciju slobodnog pada, a V brzinu. Lorenz (1955) tako navodi da je omjer kinetičke energije i ukupne potencijalne energije izrazito malen:

$$\frac{\overline{K}}{\overline{TPE}} \sim \frac{1}{2000} \quad (2.11.)$$

Uspoređujući taj omjer s prethodno dobivenim omjerom raspoložive potencijalne energije i ukupne potencijalne energije, Lorenz (1955) zaključuje:

$$\frac{\overline{K}}{\overline{APE}} \sim \frac{1}{10} \quad (2.12.)$$

Prema Lorenzu (1955), u atmosferi postoji značajna količina energije koja može preći u kinetičku energiju. Taj rezultat je važan jer ukazuje na mogućnost pojave atmosferskih gibanja zbog prijelaza energije iz potencijalne u kinetičku.

2.4. Lorenzov energetski ciklus u prostorno-vremenskoj domeni

Oort (1964) je preformulirao izraze za energiju u Lorenzovom ciklusu oslanjajući se primitivne jednadžbe, bez korištenja hidrostatičke i geostrofičke aproksimacije. Dodatno, ovako izražene energije Lorenzovog ciklusa omogućuju razlikovanje tranzijentnih i stacionarnih komponenti energije za slučaj makroporemećaja. Iz tih gore navedenih razloga, formulacija Lorenzovog energetskog ciklusa kakvu je dao Oort (1964) danas je najčešće korištena, a navodimo ju u cijelosti:

$$P_M = \frac{C_p}{2} \int \gamma [\langle T \rangle]'^2 dm \quad (2.13.)$$

$$P_E = \frac{C_p}{2} \int \gamma [\langle T'^2 \rangle + \langle T \rangle'^2] dm = P_{TE} + P_{SE} \quad (2.14.)$$

$$K_M = \frac{1}{2} \int ([\langle u \rangle]^2 + [\langle v \rangle]^2) dm \quad (2.15.)$$

$$K_E = \frac{1}{2} \int [\langle u'^2 \rangle + \langle v'^2 \rangle] dm + \frac{1}{2} \int [\langle u \rangle'^2 + \langle v \rangle'^2] dm = K_{TE} + K_{SE} \quad (2.16.)$$

Svaki od pojedinih članova dodatno je diskutiran u poglavlju 3., *Metode i podatci*. U Tablici 2.2 nalazi se legenda svih simbola korištenih u jednadžbama Lorenzovog energetskog ciklusa, (2.13.) - (2.16.), dok Tablica 2.1 sadrži opis usrednjavanja korištenih u istim jednadžbama.

Tablica 2.1. Pregled korištenih usrednjavanja i odstupanja za proizvoljnu veličinu A

$\langle A \rangle$	vremenski srednjak
A'	odstupanje od vremenskog srednjaka, $A' = A - \langle A \rangle$
$[A]$	zonalni srednjak
A^*	odstupanje od zonalnog srednjaka, $A^* = A - [A]$
\bar{A}	meridionalni srednjak
A''	odstupanje od meridionalnog srednjaka, $A'' = A - \bar{A}$

Tablica 2.2. Pregled korištenih simbola i njihovih značenja

Simbol	Značenje
a	prosječni radijus Zemlje, $6371km$
C_p	specifični toplinski kapacitet pri stalnom tlaku
dm	element mase, $a^2 \cos \phi d\lambda d\phi \frac{dp}{g}$
λ	geografska dužina
ϕ	geografska širina
g	akceleracija slobodnog pada, $9,81 \frac{m}{s^2}$
K_M	srednja zonalna kinetička energija
K_E	kinetička energija makroporemećaja
K_{TE}, K_{SE}	tranzijentna i stacionarna kinetička energija makroporemećaja
p	tlak
P_M	srednja zonalna raspoloživa potencijalna energija
P_E	raspoloživa potencijalna energija makroporemećaja
P_{TE}, P_{SE}	tranzijentna i stacionarna raspoloživa potencijalna energija makroporemećaja
R	plinska konstanta za suhi zrak
t	vrijeme
T	temperatura
u	zonalna komponenta vjetra
v	meridionalna komponenta vjetra
γ	faktor statičke stabilnosti jednak $-\frac{\theta}{T} \frac{R}{C_p} \left(\frac{\partial[\langle \bar{\theta} \rangle]}{\partial p} \right)^{-1}$
Γ	vertikalni temperaturni gradijent, tj. $-\frac{\partial T}{\partial z}$
Γ_d	suho-adiabatička stopa ohlađivanja jednaka $\frac{g}{C_p}$
θ	potencijalna temperatura, $\theta = T \left(\frac{1000hPa}{p} \right)^{\frac{R}{C_p}}$

3. Metode i podatci

3.1. Podatci i numerički model SPEEDY

Za dobivanje rezultata u ovom radu korišteni su podatci dobiveni numeričkim modelom opće cirkulacije poznatim pod imenom SPEEDY (eng. *Simplified Parameterizations, primitive-E-Equation DYNAMICS*), a koji su razvili i dokumentirali Kucharski et al. (2013). Model je razvijen u Međunarodnom centru za teorijsku fiziku Abdus Salam, Trst, Italija. Dalje ćemo navesti obilježja SPEEDY modela, tj. njegovu spektralno-dinamičku jezgru i neke od relevantnih fizičkih parametrizacija koje model koristi.

3.1.1. Jezgra SPEEDY modela

Model SPEEDY je hidrostatički model i koristi σ -koordinatu, dok za osnovne prognostičke varijable daje polja vrtložnosti, divergencije, apsolutne temperature i logaritma tlaka. Ostale varijable dobivaju se na temelju fizičkih parametrizacija i osnovnih prognostičkih polja. Varijable su određene na cijelim nivoima σ -koordinate, 0,025; 0,095; 0,20; 0,34; 0,51; 0,685; 0,835 i 0,95, izuzev polja površinskog tlaka (P_s). Najniži nivo odgovara atmosferskom graničnom sloju, dok dva najviša nivoa odgovaraju stratosferi. Tijekom *post-processinga* izlazne varijable su izračunate na izobarnim plohama od 30, 100, 200, 300, 500, 700, 850 i 925 hPa.

Za vremenski korak model koristi preskočnu (eng. *leapfrog*) shemu zajedno s vremenskim filterom na standardnoj gausianskoj mreži od 96 s 48 točaka, odnosno 3,75° geografske dužine s 3,75° geografske širine.

3.1.2. Pregled fizičkih parametrizacija

Različiti fizički procesi opisani su parametrizacijama primjerenima za model grube vertikalne rezolucije poput SPEEDY modela. Dalje slijedi kratki opis tih procesa i njihovih parametrizacija.

Konvekcija je parametrizirana pojednostavljenim tokom mase, a ista parametrizacija 'uključuje' se u području gdje je prisutna uvjetna nestabilnost ili gdje vlažnost u atmosferskom graničnom sloju prelazi određenu vrijednost. Izvlačenje zraka (eng. *detrainment*) odvija se samo na nivou vrha oblaka, a uvlačenje zraka (eng. *entrainment*) samo u donjoj polovici troposfere. Za zrak u uzlaznoj struji se pretpostavlja da je zasićen.

Kondenzacija velike skale parametrizirana je pomoću referentne vrijednosti relativne vlažnosti ovisnoj o σ -koordinati, kad relativna vlažnost pređe tu referentnu vrijednost ista se spušta k referentnoj vrijednosti u intervalu od 4 sata, a količina latentne topline uklonjene iz atmosfere u tom postupku pohranjuje se u suhu statičku energiju.

Naoblaka i debljina naoblake izvodi se na temelju ukupne oborine i relativne vlažnosti u stupcu zraka koji obuhvaća sve troposferske slojeve izuzev atmosferskog graničnog sloja .

Kratkovalno zračenje parametrizirano je pomoću dva spektralna pojasa od kojih jedan sadrži dio spektra blizak infracrvenom zračenju. Kratkovalno zračenje reflektirano je na površini i na vrhu oblaka, a albedo oblaka proporcionalan je ukupnoj naoblaci. Propustnost kratkovalnog zračenja sloja ovisna je o masi sloja, specifičnoj vlažnosti i naoblaci.

Dugovalno zračenje parametrizirano je na temelju četiri spektralna pojasa - jednim spektralnim "prozorom" (dio spektra u kojem atmosfera vrši minimalnu apsorpciju) i 3 apsorpcijske vrpce od kojih su dvije vrpce vodene pare i jedna vrpca ugljikova dioksida. Za svaki sloj, propustnost svakog pojasa ovisna je o masi sloja i njegovoj vlažnosti. Oblaci smanjuju propustnost spektralnog prozora ovisno o naoblaci. Emisija oblaka prema dolje izražena je kao otežana funkcija ovisna o temperaturi na vrhu i interpoliranoj temperaturi na polovici oblaka. Emisija oblaka prema gore koristi se temperaturom na vrhu i polovici oblaka.

Površinski tok impulsa i energije određeni su *bulk* aerodinamičnim formulama s različitim koeficijentima razmjene između kopna i mora. Dodatno, koeficijenti za tok topline ovise i o indeksu stabilnosti, a tok impulsa nad kopnom ovisi još i o visini topografije. Površinska temperatura tla (eng. *skin temperature*) određena je bilancom energije površine.

Vertikalna difuzija parametrizirana je s tri člana: preraspodjelom suhe statičke energije i vlage između dva najniža sloja što simulira plitku konvekciju u području uvjetne nestabilnosti, difuzijom vodene pare u stabilnim uvjetima donje troposfere ovisno o vertikalnom profilu relativne vlažnosti i difuzijom statičke suhe energije u slučaju kad vertikalni temperaturni gradijent prilazi suho-adijabatičkom limitu.

3.1.3. Rubni uvjeti modela i eksperiment Ctrl

Model zahtijeva pripadne rubne uvjete kako bi odredio tok impulsa, topline i vlage na površini, te tok dolaznog sunčevog zračenja na vrhu atmosfere. Na površini, osim visine topografije i maske kopna i mora, model zahtijeva klimatološka polja sljedećih varijabli: površinska temperatura mora, udio leda na površini mora, temperatura tla u sloju dubine 1 m, dubina snijega, albedo golog tla i udio kopna prekrivenog vegetacijom. Model koristi godišnji srednjak albeda golog tla i udjela kopna prekrivenog vegetacijom, a za ostala polja koristi se mjesečni srednjak te interpolirani dnevni srednjaci.

Na vrhu atmosfere tok dolaznog sunčevog zračenja izračunat je iz astronomskih formula bez dnevnog ciklusa. Empiričke i sezonski varijabilne formule koriste se za izračun apsorpcije zračenja ozonom u stratosferi.

Eksperiment *Ctrl* proveden je modelom SPEEDY za promatrano vremensko raz-

doblje od 1854. godine do 2010. godine s izostavljenom prvom godinom vremenske integracije (1854.) zbog stabilizacije. Eksperiment *Ctrl* predstavlja ansambl od 35 međusobno nezavisnih numeričkih simulacija modelom SPEEDY. Članovi ansambla dijele istovjetne rubne uvjete modela, ali s malo izmijenjenim početnim uvjetima. Izmjerene srednje mjesečne temperature mora zajednički su donji rubni uvjet za sve članove ansambla, a međugodišnja varijabilnost temperature mora predstavlja glavno forsiranje na donjoj granici modela. Promjenjivost temperature mora od posebnog je interesa za ovaj rad zbog veze površinske temperature mora u tropskom Pacifiku i pojave ENSO-a.

Podatci koje koristimo u radu srednjak su 35 članova ansambla *Ctrl* eksperimenta, a koji na temelju ulaznih polja površinske temperature mora modelom SPEEDY simula ostala polja na globalnoj mreži. Na temelju rezultata eksperimenta *Ctrl* za razdoblje od 1855. do 2010. godine vršimo daljnji račun članova Lorenzovog energetskog ciklusa te NINO 3.4 indeksa kako je opisano u poglavlju *3.2 Metode obrade podataka*.

3.2. Metode obrade podataka

3.2.1. Programi korišteni za obradu podataka

Ovaj rad oslanja se na dva programa za obradu podataka: **CDO** (Climate Data Operators) i **GNU Octave**.

CDO, dokumentiran u radu autora Schulzweida (2019), je skup naredbi za manipulaciju klimatskih podataka i rezultata numeričkih modela, a u ovom radu koristio se u svrhu filtriranja i vremenskog usrednjavanja podataka dobivenih iz modela SPEEDY. Sezonskim usrednjavanjem promatrani su rezultati za zimsku, DJF, i ljetnu, JJA, sezonu. Također su izračunati i godišnji srednjaci promatranih parametara.

GNU Octave, s dokumentacijom od autora Eaton et al. (2017), je program i programski jezik kompatibilan s Matlabom namijenjen numeričkoj obradi podataka. U ovom radu se koristi za gotovo svu obradu podataka nakon filtriranja vremenskih razdoblja i vremenskih usrednjavanja koja su napravljena programom CDO. To podrazumijeva usrednjavanja, integraciju ali i ostale matematičke postupke opisane u ovom radu kao i grafički prikaz rezultata.

3.2.2. Metode usrednjavanja

Za izračun članova Lorenzovog energetskog ciklusa vršimo prikladna usrednjavanja i odstupanja od tako dobivenih srednjaka, kao što je prikazano u Tablici 3.1:

U Tablici 3.1 u drugom stupcu su navedeni postupci kojim računamo pojedine srednjake, a riječ je o srednjaku funkcije A. Prilikom usrednjavanja funkcije A po vremenu, srednjak funkcije A zamijenit ćemo aritmetičkom sredinom vrijednosti funkcije A za vremenski interval od interesa - razlog tome je što imamo dostupne isključivo mjesečne

Tablica 3.1. Usrednjavanja i odstupanja od srednjaka

Simbol	Postupak	Značenje
$\langle A \rangle$	$\frac{1}{t_2-t_1} \int_{t_1}^{t_2} A dt$	vremenski srednjak
A'	$A - \langle A \rangle$	odstupanje od vremenskog srednjaka
$[A]$	$\frac{1}{2\pi} \int_{-\pi}^{\pi} A d\lambda$	zonalni srednjak
A^*	$A - [A]$	odstupanje od zonalnog srednjaka
\bar{A}	$\frac{1}{\pi} \int_{-\frac{\pi}{2}}^{\frac{\pi}{2}} A d\phi$	meridionalni srednjak
A''	$A - \bar{A}$	odstupanje od meridionalnog srednjaka

srednjake. U preostalim prostornim srednjacima koristimo se gore navedenim formulama. Dodatno, razlika u granicama integracije ovih usrednjavanja od istih navedenih u radu autora Peixóto i Oort (1974) je posljedica isključivo redoslijeda kojim model SPEEDY zapisuje vrijednosti polja na mrežu, ali i činjenice da u ovom radu promatramo cijelu atmosferu za razliku od samo sjeverne hemisfere kako rade Peixóto i Oort (1974).

3.2.3. Integracija tabličnih vrijednosti Newton-Cotesovim formulama

Produkti modela SPEEDY su vrijednosti varijabli u pojedinim točkama mreže modela. Tako dobivene varijable trebamo koristiti za usrednjavanja navedena u Tablici 3.1, međutim te varijable ne mogu predstavljati analitičku podintegralnu funkciju A , već isključivo vrijednosti podintegralne funkcije A u točkama mreže modela. Prilikom integracije tako zadane podintegralne funkcije oslanjamo se na metodu integracije tabličnih vrijednosti Newton-Cotesovim formulama.

Newton-Cotesove formule, preuzete iz udžbenika autora Chapra (2009), najčešće su korištena shema za numeričko izvrijednjavanje integrala, a oslanjaju se na zamjenu podintegralne funkcije ili tabličnih vrijednosti s aproksimacijom koju je puno lakše integrirati, a u ovom slučaju se radi o polinomu n -tog stupnja $f_n(x) = a_0 + a_1x + \dots + a_{n-1}x^{n-1} + a_nx^n$.

$$I = \int_a^b f(x)dx \cong \int_a^b f_n(x)dx \quad (3.1.)$$

Površina pod polinomom n -tog stupnja približno odgovara i površini ispod podintegralne funkcije. Naravno, zahvaljujući svojstvima integrala, uvijek možemo podijeliti jedan interval na više manjih intervala gdje polinom bolje opisuje stvarnu funkciju koju želimo integrirati. U slučaju podataka iz modela s kojim radimo taj broj intervala je već konačno određen raspodjelom mreže modela. Preostaje nam jedino odabir stupnja polinoma s kojim želimo prikazati funkciju na određenom intervalu.

U našem slučaju koristimo se zatvorenim oblikom tih formula jer su nam vrijednosti podintegralne funkcije u rubnim točkama poznate. Prvi oblik zatvorenih Newton-Cotesovih formula koristi polinom prvog stupnja, odnosno pravac:

$$f_1(x) = f(a) + \frac{f(b) - f(a)}{b - a}(x - a) \quad (3.2.)$$

Integracijom tog polinoma dobivamo da je integral jednak:

$$I = \int_a^b f_1(x)dx = (b - a) \frac{f(a) + f(b)}{2} \quad (3.3.)$$

Formulu (3.3.) zovemo trapezno pravilo. Možemo se koristiti i polinomima višeg stupnja kako bismo dobili na točnosti aproksimacije, međutim preduvjet za te formule je da su međusobne udaljenosti točaka x_0 , x_1 i x_2 na intervalu od a do b jednake. To će nam se ispostaviti važnim za račun na mreži modela. Za polinom drugog stupnja imamo da je:

$$I \cong \int_a^b f_2(x)dx = (b-a) \frac{f(x_0) + 4f(x_1) + f(x_2)}{6} \quad (3.4.)$$

Formulu (3.4.) zovemo i Simpsonovo pravilo $\frac{1}{3}$. Podijelimo li interval od a do b s četiri točke x_0 , x_1 , x_2 i x_3 , odnosno na 3 jednaka podintervala, možemo se koristiti i polinomom stupnja 3, a tad imamo i Simpsonovo pravilo $\frac{3}{8}$:

$$I \cong \int_a^b f_3(x)dx = (b-a) \frac{f(x_0) + 3f(x_1) + 3f(x_2) + f(x_3)}{8} \quad (3.5.)$$

Za izvrijednjavanje integrala u ovom radu koristi se kombinacija gore navedenih formula: potprogrami *onedint.m* i *onedint_TLAK.m* napisani su sa svrhom izvrijednjavanja integrala i prolaze kroz sve točke intervala na kojem vršimo integraciju ispitujući udaljenosti među tim točkama. Ako su nadolazeće tri točke jednako udaljene koristi se Simpsonovo pravilo $\frac{3}{8}$ (3.5.), ako su samo nadolazeće 2 točke jednako udaljene koristi se Simpsonovo pravilo $\frac{1}{3}$ (3.4.), a u krajnjem slučaju se koristi i trapezno pravilo (3.3.). Tako napisani potprogram omogućuje korištenje parnog ili neparnog broja podintervala (Simpsonova formula $\frac{1}{3}$ ograničena je samo na parni broj podintervala što nam ne odgovara za integraciju po geografskoj širini ili dužini), a ujedno i takva kombinacija metoda pruža veću točnost od one koju bismo dobili da smo koristili isključivo trapeznu formulu.

Dodatno, gore navedenu metodu koristimo i za izvrijednjavanje volumnih integrala za sve članove Lorenzovog ciklusa. Isti volumni integral u svim članovima skraćeno se označava s:

$$\int dm = \int_{p_{tlo}}^{p_{vrh}} \int_{-\frac{\pi}{2}}^{\frac{\pi}{2}} \int_{-\pi}^{\pi} a^2 \cos\phi d\lambda d\phi \frac{dp}{g} \quad (3.6.)$$

U volumnom integralu (3.6.) srednji radijus Zemlje označavamo s a i iznosi 6371 km, akceleraciju slobodnog pada označavamo s g i iznosi $9.81 \frac{m}{s^2}$, p_{tlo} označava tlak zraka na površini i p_{vrh} označava uvijek 30 hPa izobarnu ploha koja je ujedno i najviša izobarna ploha u modelu SPEEDY. Volumni integral (3.6.) rješava se s posebnim potprogramom *vol_int_s_presjecima.m* koji rješava svaki od tri integrala jedan po jedan koristeći prethodno spomenuta 2 potprograma (*onedint.m* i *onedint_TLAK.m*). Volumna integracija se vrši prvo integracijom po geografskoj dužini λ , potom geografskoj širini ϕ i na kraju po tlaku, p . Posebno, integral po geografskoj širini ϕ se razdvaja na dva integrala, jedan za južnu i drugi za sjevernu hemisferu. Rezultat izračuna je raspodjela energije u Lorenzovom energetskom ciklusu posebno za južnu i sjevernu hemisferu

Nakon što potprogram *vol_int_s_presjecima.m* izvrijedni trostruki integral, sve vrijednosti dijeli s površinom Zemlje na koju se ti članovi odnose. To radimo kako bismo kao konačnu vrijednost (nakon množenja s faktorom koji se nalazi van volumnog

integrala) dobili članove Lorenzovog energetskog ciklusa u jedinicima 10^5 J m^{-2} te ih mogli uspoređivati s drugim radovima i rezultatima. Vrijednosti koje se odnose na južnu ili sjevernu hemisferu dijelimo s $2\pi a^2$ gdje je a oznaka za srednji radijus Zemlje. Zbroj doprinosa južne i sjeverne hemisfere podijeljen s dva predstavlja vrijednost za cijelu atmosferu.

3.2.4. Članovi Lorenzovog energetskog ciklusa

U ovom radu izračunati su sljedeći članovi Lorenzovog energetskog ciklusa: P_M , K_M , P_{TE} , P_{SE} , K_{TE} i K_{SE} , a zbrajanjem stacionarnih i tranzijentnih članova makroporemećaja (P_{TE} i P_{SE} te K_{TE} i K_{SE}) dobiveni su i P_E te K_E , odnosno raspoloživa potencijalna energija i kinetička energija makroporemećaja. Ovdje ćemo još dodatno prokomentirati svaki od tih članova, odnosno pojedina usrednjavanja potrebna za njihov izračun.

Za svaki od članova izračunali smo sezonske srednjake za sezone DJF i JJA, te godišnji srednjak. Izostavljene su vrijednosti za 1855. godinu jer niz podataka počinje sa siječnjom 1855. godine, posljedično prva DJF sezona nije potpuna zbog nedostatka prosinca 1854. godine.

$$P_M = \frac{C_p}{2} \int \gamma [\langle T \rangle]''^2 dm \quad (3.7.)$$

U članu srednje raspoložive potencijalne energije ili P_M (3.7.) prvo se vremenski usrednjava temperatura ($\langle T \rangle$), tj. koristimo sezonske i godišnje srednjake dobivene aritmetičkim usrednjavanjem. Potom te vrijednosti zonalno usrednjavamo ($[\langle T \rangle]$). Preostaje nam odrediti i odstupanje od meridionalnog srednjaka ($[\langle T \rangle]''$), za to određujemo meridionalni srednjak ($[\langle \bar{T} \rangle]$), a potom ga oduzimamo od prethodno dobivenih rezultata, tj. od $[\langle T \rangle]$. Za kraj kvadriramo rezultat i množimo s faktorom stabilnosti, γ , nakno čega slijedi volumna integracija i množenje s konstantom ispred volumnog integrala, $\frac{C_p}{2}$.

$$\gamma = -\frac{\theta}{T} \frac{R}{C_p p} \left(\frac{\partial [\langle \bar{\theta} \rangle]}{\partial p} \right)^{-1} \quad (3.8.)$$

Prilikom računa γ opet se pozivamo na usrednjavanja iz Tablice (3.1), tj. na meridionalni, zonalni i vremenski srednjak potencijalne temperature θ . Koristili smo se sezonskim i godišnjim srednjacima tlaka i temperature za izračun $\langle \theta \rangle$. Za izračun $\frac{\partial [\langle \bar{\theta} \rangle]}{\partial p}$ koristimo se u Octave ugrađenom funkcijom *gradient*. Funkcija kao argumente uzima vrijednosti $[\langle \bar{\theta} \rangle]$ na $n = 9$ razina tlaka zajedno s vrijednostima tlaka p . Funkcija se koristi metodama konačnih razlika za određivanje diferencijala u pojedinim točkama: za prvu točku koristi aproksimaciju konačnih razlika unaprijed (3.9.), za međutočke koristi aproksimaciju centralne konačne razlike (3.10.), a za zadnju točku

aproksimaciju konačnih razlika unazad (3.11.).

$$f'(x_{m=1}) = \frac{f(x_2) - f(x_1)}{x_2 - x_1} \quad (3.9.)$$

$$f'(x_{1 < m < n}) = \frac{f(x_{m+1}) - f(x_{m-1})}{x_{m+1} - x_{m-1}} \quad (3.10.)$$

$$f'(x_{m=n}) = \frac{f(x_m) - f(x_{m-1})}{x_m - x_{m-1}} \quad (3.11.)$$

$$P_E = \frac{C_p}{2} \int \gamma [\langle T'^2 \rangle + \langle T \rangle^{*2}] dm = P_{TE} + P_{SE} \quad (3.12.)$$

Sljedeće računamo **raspoloživu potencijalnu energiju makroporemećaja** P_E (3.12.) koju dijelimo na dva člana, energiju tranzijentnih (P_{TE}) i stacionarnih (P_{SE}) makroporemećaja. Program naziva *Pe.m* računa svaki od ta dva člana zasebno, te ih na kraju zbraja. Prilikom izračuna tranzijentne komponente (P_{TE}) prvo računamo mjesečne klimatološke vrijednosti na temelju svih dostupnih godina (od kojih je ukupno 155). Tako dobiveni mjesečni klimatološki srednjak oduzimamo od odgovarajuće mjesečne vrijednosti kako bi dobili mjesečno odstupanje od klimatološkog srednjaka, a tu vrijednost i kvadriramo - time smo dobili T'^2 . Sljedeći korak je za svaku godinu usrednjiti te vrijednosti za DJF i JJA sezone, kao i za cijelu godinu, da bi se dobio član $\langle T'^2 \rangle$. Preostaje izračun zonalnog srednjaka tih vrijednosti i volumna integracija te množenje s konstantama.

Za stacionarni član (P_{SE}) koristimo se sezonskim srednjacima temperature za DJF i JJA sezonu, kao i godišnjim srednjacima, a od njih oduzimamo odgovarajuće zonalne srednjake nakon čega te razlike kvadriramo i time dobivamo $\langle T \rangle^{*2}$. Preostaje izračunati zonalni srednjak, te volumna integracija i množenje s $\frac{C_p}{2}$. Zbroj P_{TE} i P_{SE} daje P_E .

Prelazimo na kinetičku energiju, odnosno na **kinetičku energiju srednjeg zonalnog strujanja** K_M (3.13.):

$$K_M = \frac{1}{2} \int ([\langle u \rangle]^2 + [\langle v \rangle]^2) dm \quad (3.13.)$$

Ovdje u i v predstavljaju meridionalnu i zonalnu komponentu vjetra. Postupak za ovaj član je jednostavan: računamo srednjak za DJF i JJA sezonu kao i za svaku godinu za obje komponente vjetra, a potom srednjake tih komponenti vjetra zonalno usrednjavamo, kvadriramo, zbrajamo i volumno integriramo.

Zadnji član u Lorenzovom energetskom ciklusu je **kinetička energija makroporemećaja** K_E (3.14.) koja se dijeli na tranzijentnu (K_{TE}) i stacionarnu komponentu

(K_{SE}):

$$K_E = \frac{1}{2} \int [\langle u'^2 \rangle + \langle v'^2 \rangle] dm + \frac{1}{2} \int [\langle u \rangle^{*2} + \langle v \rangle^{*2}] dm = K_{TE} + K_{SE} \quad (3.14.)$$

Za član K_{TE} računamo prvo mjesečni klimatološki srednjak komponenti vjetra za svih 155 raspoloživih godina koje potom oduzimamo od svakog mjesečnog srednjaka kako bi dobili mjesečno odstupanje komponenti vjetra od klimatoloških vrijednosti, u' i v' . Ta odstupanja potom kvadriramo i usrednjavamo za sezone DJF i JJA, te za cijelu godinu što nas dovodi do $\langle u'^2 \rangle$ i $\langle v'^2 \rangle$. Te dvije komponente potom zbrajamo i zbroj zonalno usrednjavamo, nakon čega slijedi volumna integracija i množenje s $\frac{1}{2}$.

Član K_{SE} koristi srednjake komponenti vjetra za DJF i JJA sezonu, te za svaku godinu, $\langle u \rangle$ i $\langle v \rangle$. Te srednjake zonalno usrednjavamo, a tako dobivene zonalne srednjake oduzimamo od $\langle u \rangle$ i $\langle v \rangle$ kako bi dobili odstupanje sezonske i godišnje vrijednosti od zonalnog srednjaka za taj period: $\langle u \rangle^*$ i $\langle v \rangle^*$. Potom te dvije komponente kvadriramo, zbrajamo i zbroj zonalno usrednjavamo. Preostaje još volumna integracija i množenje s članom ispred integrala, $\frac{1}{2}$. Rezultat dva gornja postupka zbrajamo kako bismo dobili K_E .

3.2.5. NINO 3.4 indeks

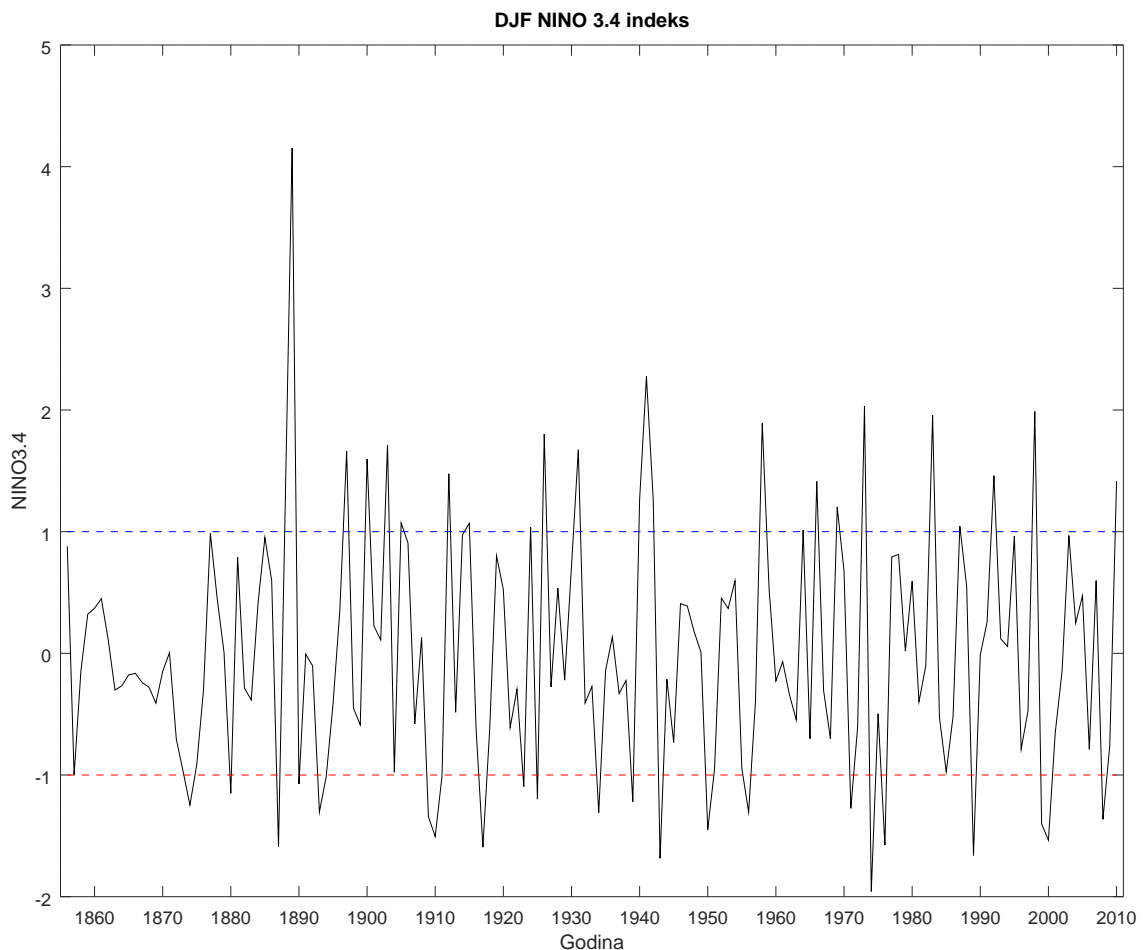
NINO 3.4 indeks omogućava nam određivanje El Niño i La Niña događaja na Pacifiku. Indeks se oslanja na površinske temperature mora između 5° južno i 5° sjeverno od ekvatora, te između 170° i 120° zapadno od Griničkog meridijana za sezonu DJF. Za izračun indeksa koristimo se sezonskim anomalijama površinske temperature mora nad prethodno navedenim područjem. Računamo klimatološki srednjak sezonskih površinskih srednjaka za sljedeća razdoblja: 1855. – 1890., 1891. – 1920., 1921. – 1950., 1951. – 1980. i 1981. – 2010.. Računanje klimatoloških vrijednosti za posebna razdoblja bi trebalo otkloniti utjecaj globalnog zatopljenja. Na temelju tih klimatoloških srednjaka određene su sezonske anomalije srednjaka površinske temperature. Sezonske anomalije dijelimo standardnom devijacijom čime je dobivena bezdimenzionalna vrijednost, tj. standardizirani NINO 3.4 indeks. El Niño događaj određen je s vrijednošću NINO 3.4 indeksa većom od 1, a La Niña događaji imaju pripadajuću vrijednost NINO 3.4 indeksa manju od -1 .

4. Rezultati i diskusija

U ovom poglavlju promotrit ćemo rezultate prethodno opisanih postupaka, odnosno prikazat ćemo i diskutirati raspoloživu potencijalnu energiju i kinetičku energiju srednjeg zonalnog strujanja, ali i makroporemećaja. Te energije u atmosferi prikazujemo kao prosječne vrijednosti atmosfere za jedinčni kvadrat površine.

Rezultate ćemo promatrati zasebno za južnu i sjevernu hemisferu, te cijelu atmosferu, a isto tako svaku od tih prostornih domena posebno ćemo promatrati u kontesktu DJF i JJA sezona, te u godišnjem prosjeku. U tu svrhu prikazivat ćemo srednje sezone i godišnje vrijednosti u vremenu, ali i srednjak svih vrijednosti u vertikalnom i longitudinalno-vertikalnom presjeku.

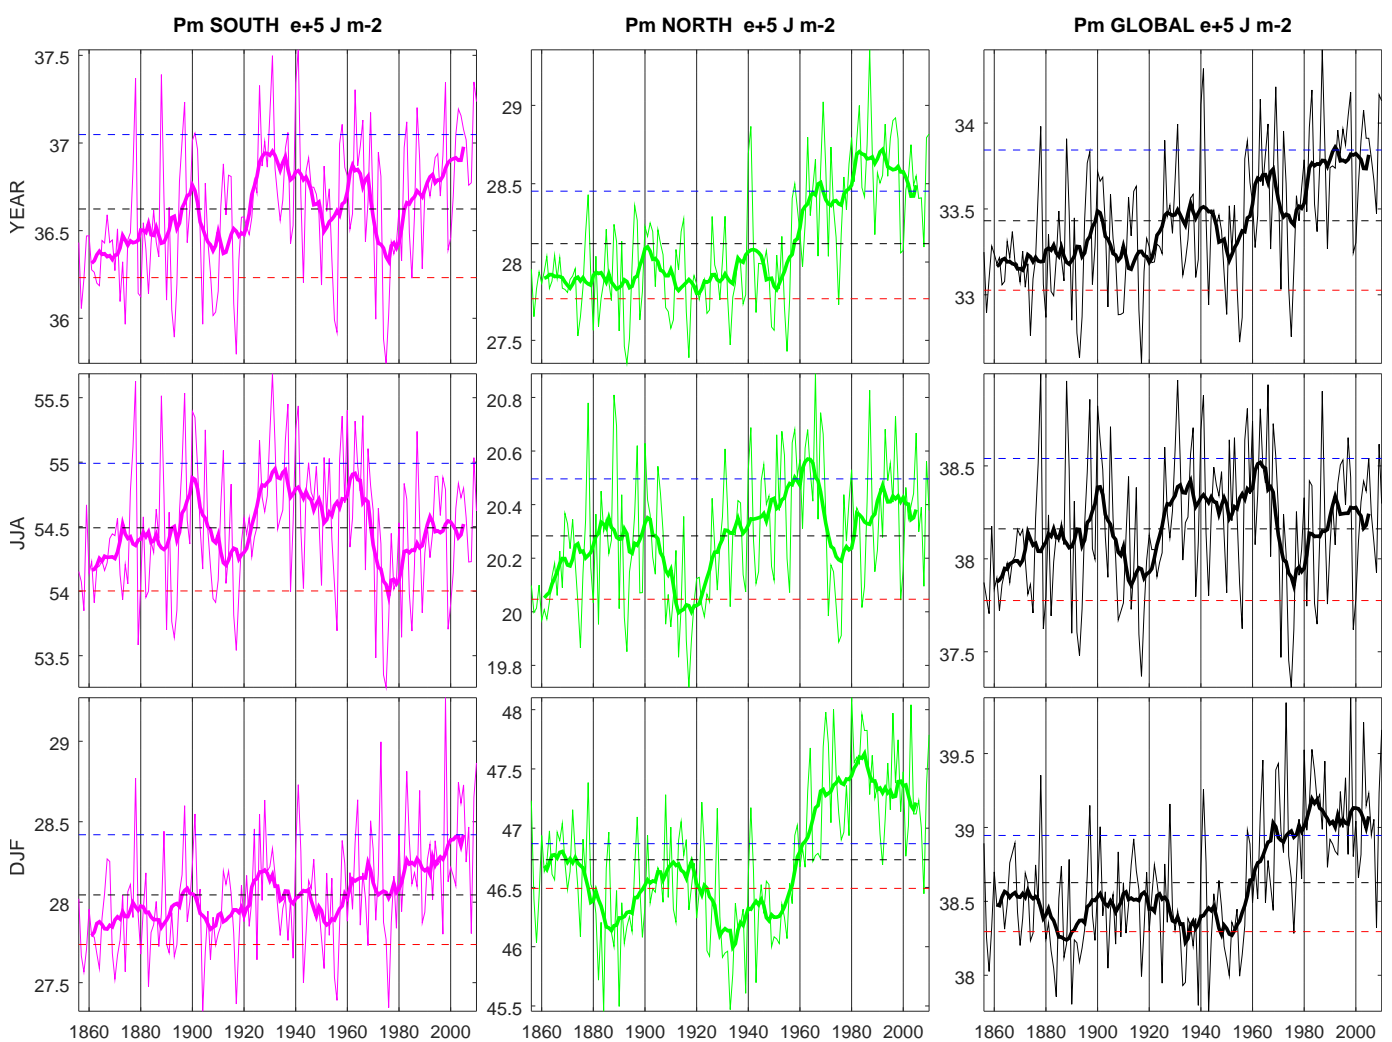
4.1. NINO 3.4 indeks



Slika 4.1. DJF NINO 3.4 indeks za razdoblje 1856. - 2010. Plava (crvena) isprekidana linija označava graničnu vrijednost indeksa za El Niño (La Niña) događaje.

Prvo ćemo kratko promotriti NINO 3.4 indeks koji smo izračunali za vremensko razdoblje od 1856. do 2010. godine. Na slici 4.1 vidimo vrijednosti NINO 3.4 indeksa, a plava i crvena linija označavaju indeks vrijednosti jedan, odnosno minus jedan, kao vrijednost na temelju koje detektiramo godinu s El Niño odnosno La Niña događajem. Na podacima koje smo koristili zabilježena su 24 El Niño događaja, te 25 La Niña događaja. Na temelju tih 24, odnosno 25 El Niño i La Niña događaja, napravili smo izračun prosječne vrijednosti energije Lorenzovog ciklusa i njihove profile.

4.2. Srednja raspoloživa potencijalna energija P_M



Slika 4.2. Zonalna raspoloživa potencijalna energija (10^5 J m^{-2}) za južnu, sjevernu i sveukupnu atmosferu i za DJF i JJA sezone te za cijelu godinu za razdoblje od 1856. do 2010.. Tanka linija predstavlja P_M , debela linija označava 11-godišnji klizni srednjak, plava isprekidana linija označava srednju vrijednost za El Niño, a crvena za La Niña događaje, dok crna isprekidana linija označava srednjak svih podataka

Dalje promatramo rezultate za član srednje raspoložive potencijalne energije P_M za cijelu atmosferu na slici 4.2. Važno je uočiti da su skale različite. 11-godišnji srednjak označen je debljom linijom, a daje nam naslutiti uzlazni trend u srednjoj raspoloživoj potencijalnoj energiji, a možemo uočiti i značajne višegodišnje oscilacije. P_M tijekom godine iznosom prevladava na južnoj hemisferi, kao i u JJA sezoni, dok suprotnu situaciju imamo tijekom DJF sezone kad više srednje zonalne raspoložive potencijalne energije nosi sjeverna hemisfera. Drugim riječima, član P_M nosi više energije u zimskoj sezoni. Na slici 4.2 jasno je vidljivo da El Niño događaji doprinose porastu energije, a La Niña smanjenju.

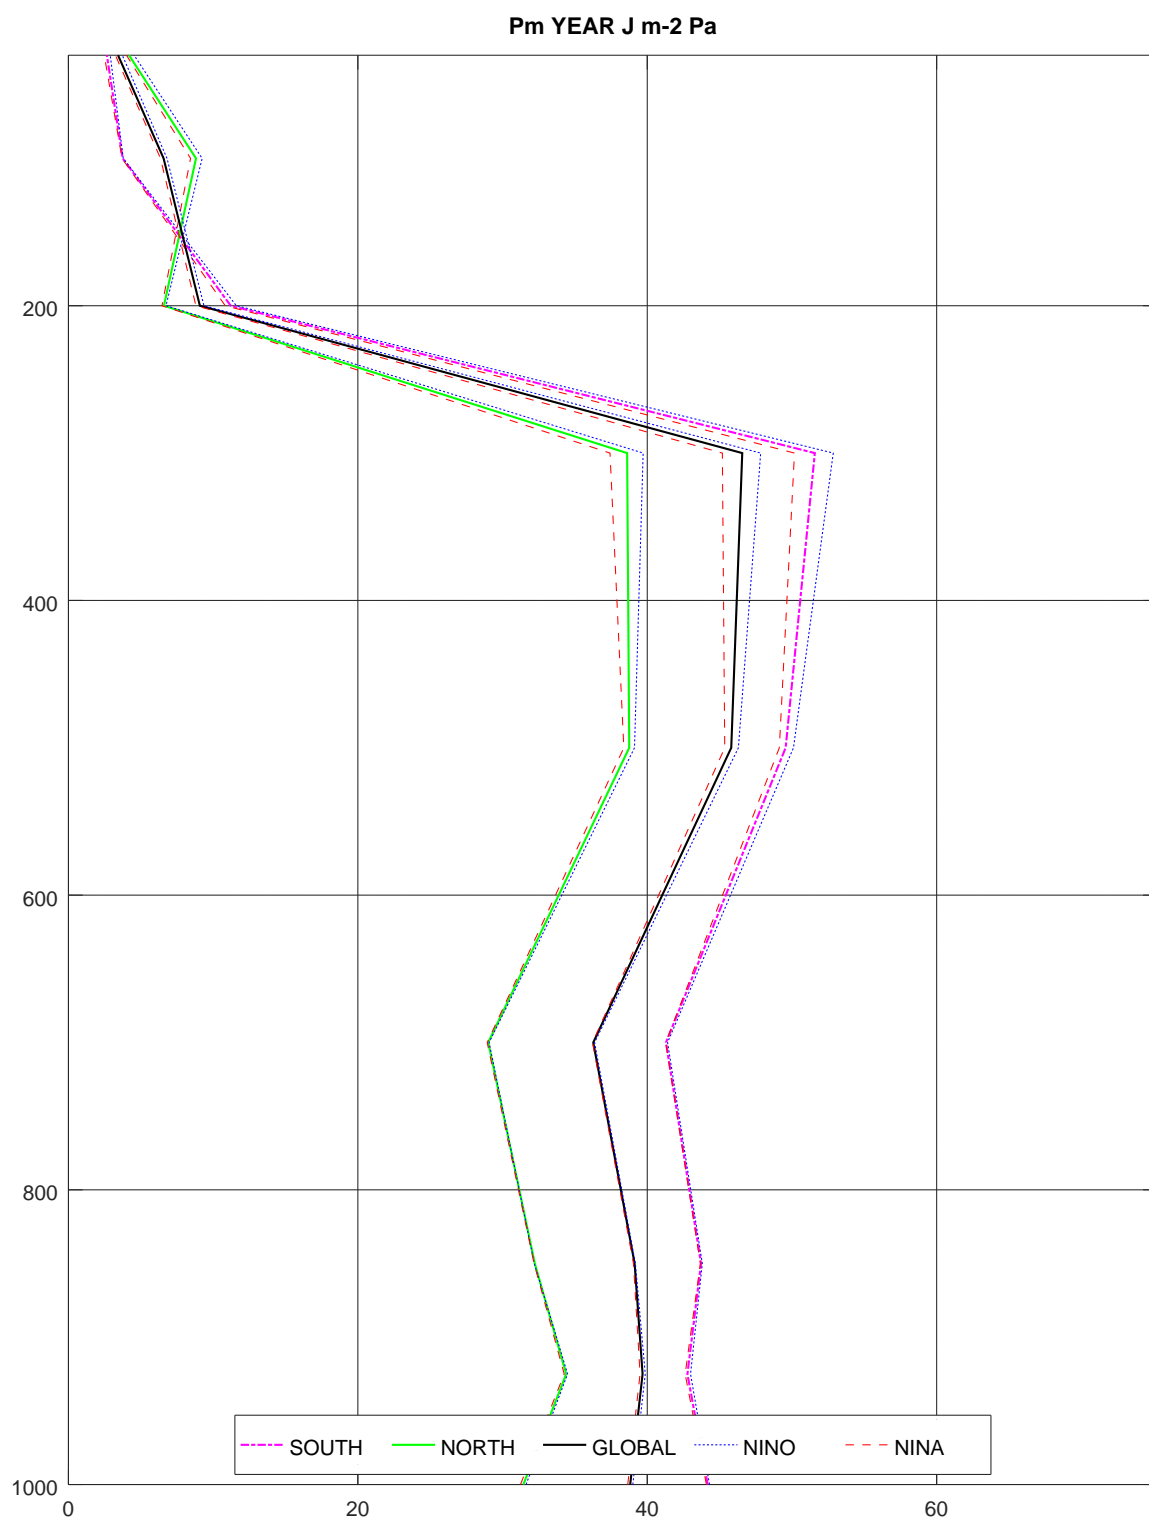
U Tablici 4.1 možemo promotriti srednje vrijednosti za sve setove podataka. Zanimljivo je uočiti da srednjak energije u prosjeku odstupa za 1% (-1%) od srednje vrijednosti P_M -a za El Niño (La Niña) događaje i to neovisno o sezoni i domeni. Jedina iznimka je DJF sezona na sjevernoj hemisferi gdje je utjecaj ENSO faza upola manji, a zbog utjecaja ENSO događaja koji bi tad trebao biti najjači očekivali bismo veće vrijednosti P_M u ovoj sezoni.

Tablica 4.1. Tablica srednjih vrijednost srednje potencijalne raspoložive energije (10^5 J m^{-2}) i postotak odstupanja od srednjaka za El Niño odnosno La Niña događaje za južnu, sjevernu i sveukupnu atmosferu, te za DJF i JJA sezone i za cijelu godinu

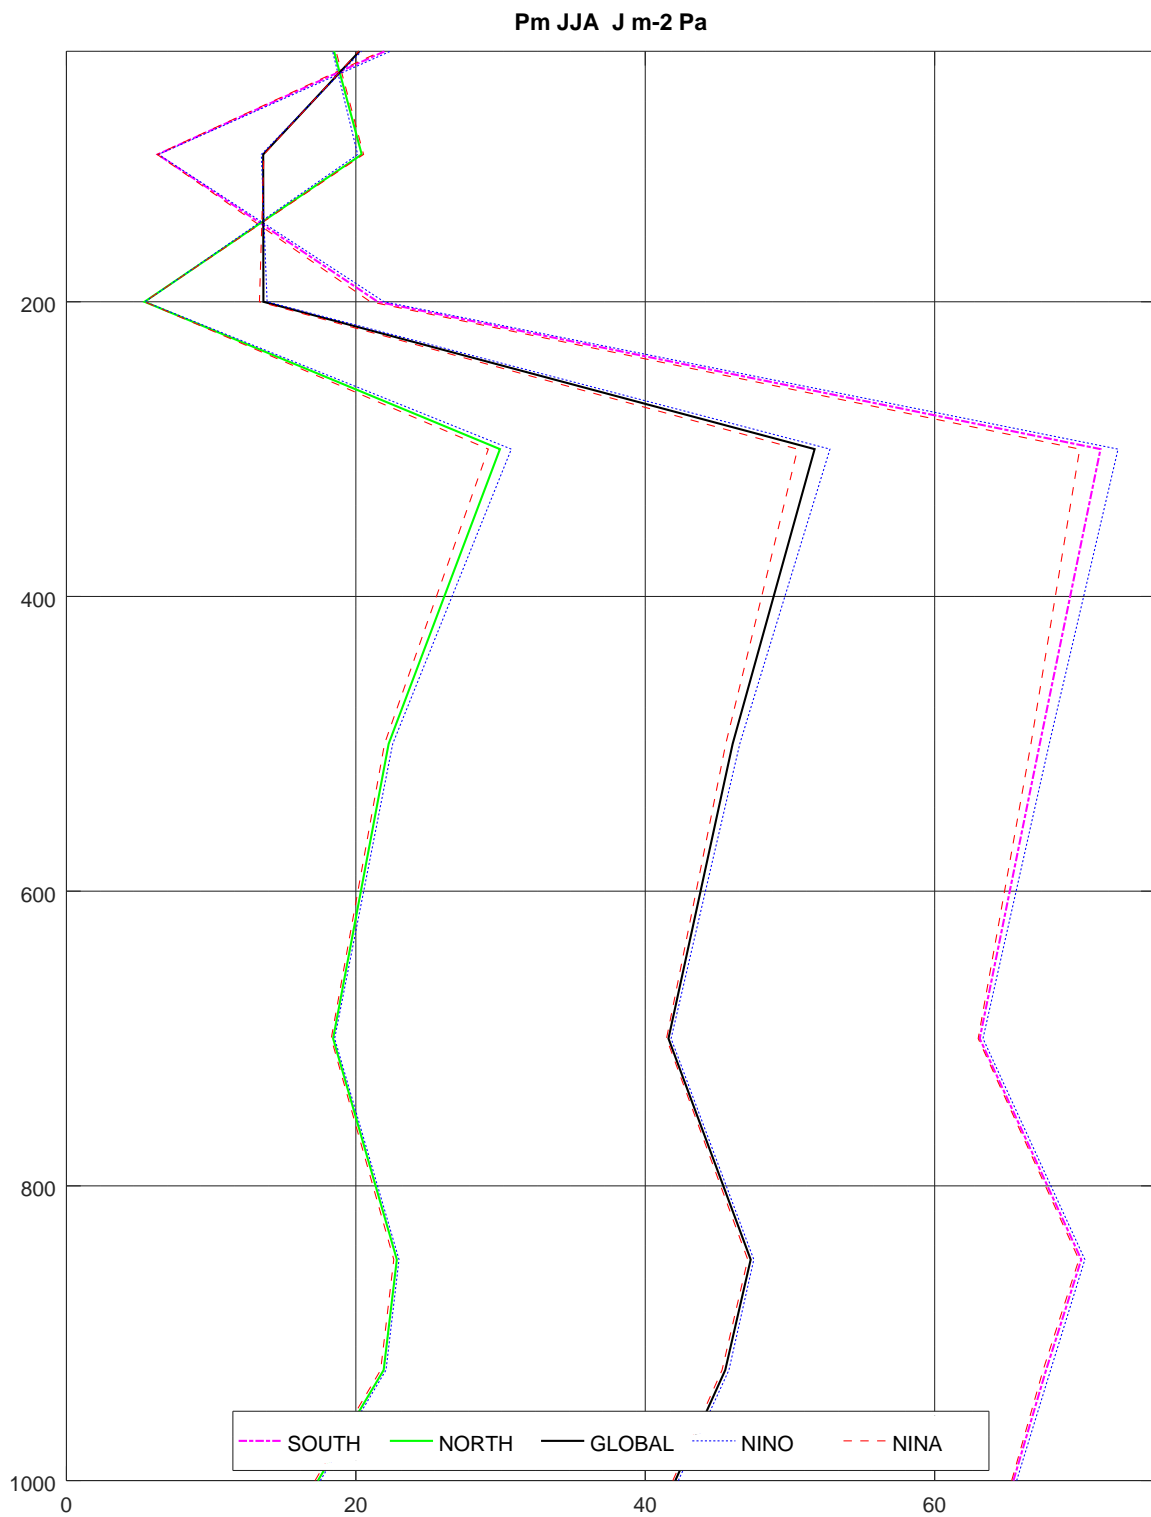
Interval	Hemisfera	El Niño	Srednjak	La Niña	El Niño	La Niña
YEAR	SOUTH	37.05	36.62	36.23	1.159 %	-1.069 %
YEAR	NORTH	28.45	28.12	27.77	1.192 %	-1.250 %
YEAR	GLOBAL	33.84	33.43	33.03	1.232 %	-1.210 %
JJA	SOUTH	54.99	54.49	54.00	0.917 %	-0.898 %
JJA	NORTH	20.50	20.28	20.05	1.049 %	-1.166 %
JJA	GLOBAL	38.54	38.16	37.78	0.992 %	-1.011 %
DJF	SOUTH	28.42	28.05	27.74	1.333 %	-1.099 %
DJF	NORTH	46.87	46.73	46.49	0.290 %	-0.517 %
DJF	GLOBAL	38.95	38.63	38.30	0.827 %	-0.858 %

Na slikama 4.3 - 4.5 nalazi se godišnji vertikalni presjek srednje raspoložive potencijalne energije gdje vidimo da je najveći dio energije sadržan u troposferi, do 300 hPa. Doprinos El Niño i La Niña događaja je relativno malen, kao što se vidi i u Tablici 4.1, dok odstupanja od prosječnih klimatoloških vrijednosti uočavamo u sloju između 300 i 500 hPa. Za godišnje vrijednosti El Niño događaji doprinose relativno malom povećanju P_M u višoj troposferi na obje hemisfere, ali i i globalno. Slab utjecaj imaju i La Niña događaji koji doprinose relativno malenom smanjenju energije u odnosu na prosječnu godišnju vrijednost. Isto vidimo i za DJF i JJA sezone. Slika 4.6 prikazuje longitudinalno-vertikalni presjek srednjaka srednje raspoložive potencijalne energije za DJF i JJA sezone te cijelu godinu zajedno sa srednjim vrijednostima za El Niño i La Niña događaje. Sve slike unutar istog razdoblja dijele izolinije, dok je za sve slike korištena ista *colormap*. Član P_M najviši je na zimskoj hemisferi blizu površine s

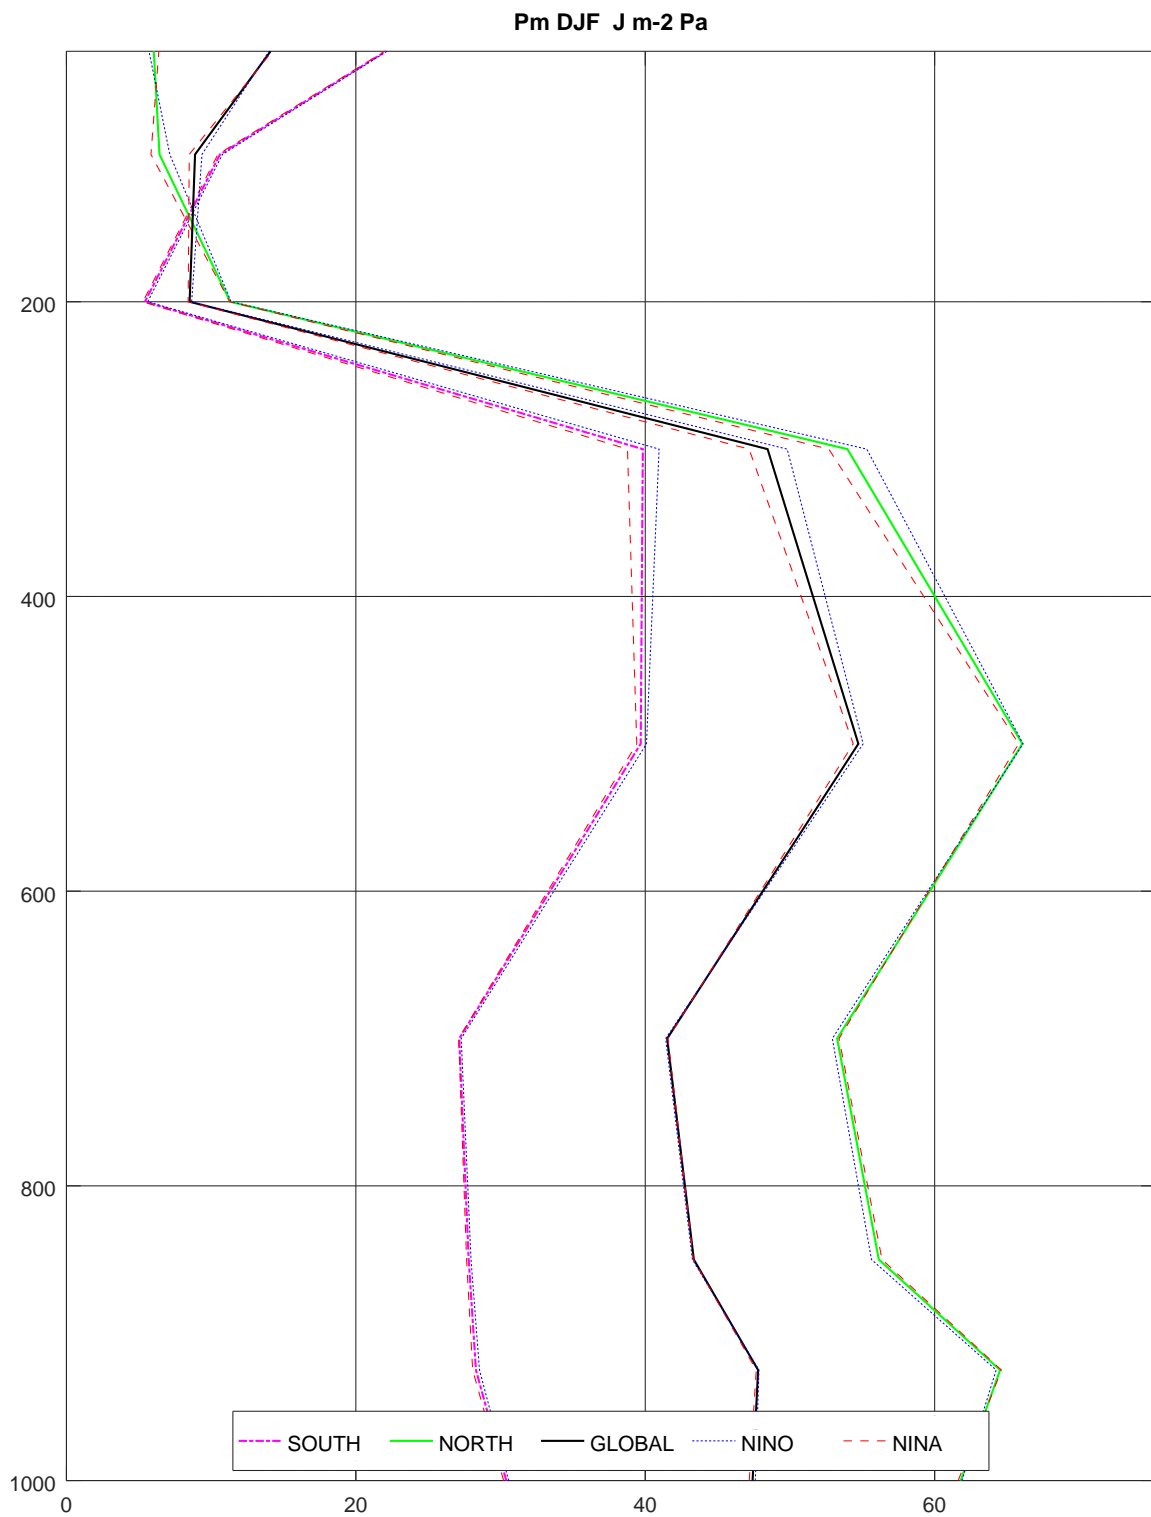
posebno visokim vrijednostima na južnom polu tokom JJA sezone.



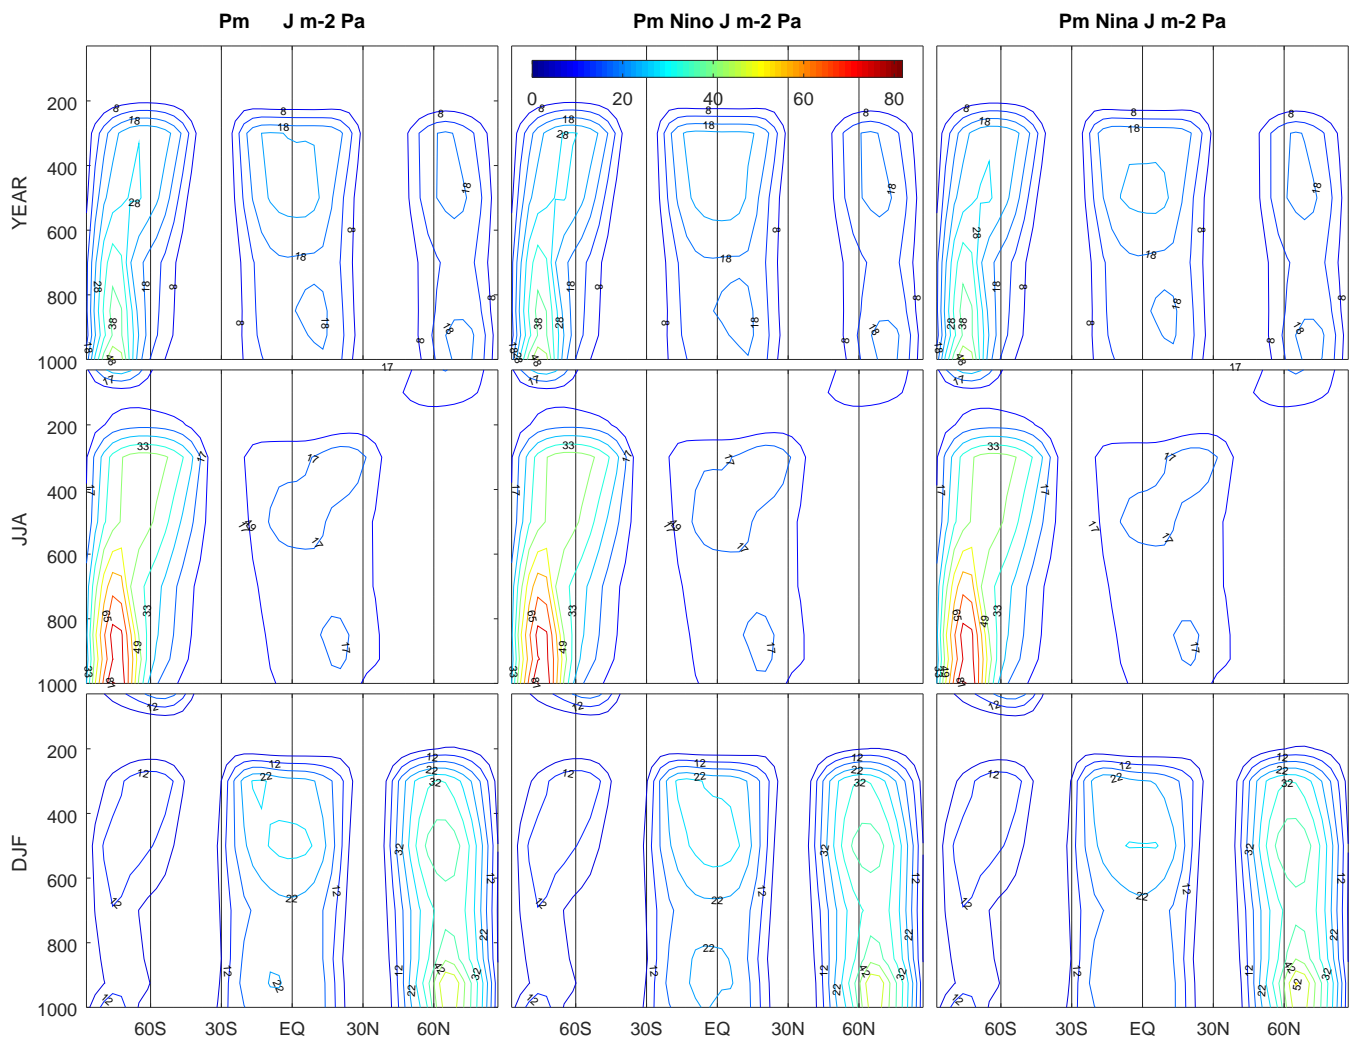
Slika 4.3. Vertikalni presjek godišnje zonalne raspoložive potencijalne energije (J m^{-2} Pa) za južnu hemisferu, sjevernu hemisferu i globalnu domenu



Slika 4.4. Vertikalni presjek sezonske zonalne raspoložive potencijalne energije (J m^{-2} Pa) za južnu hemisferu, sjevernu hemisferu i globalnu domenu za JJA sezonu



Slika 4.5. Vertikalni presjek sezonske zonalne raspoložive potencijalne energije ($\text{J m}^{-2} \text{Pa}$) za južnu hemisferu, sjevernu hemisferu i globalnu domenu za DJF sezonu

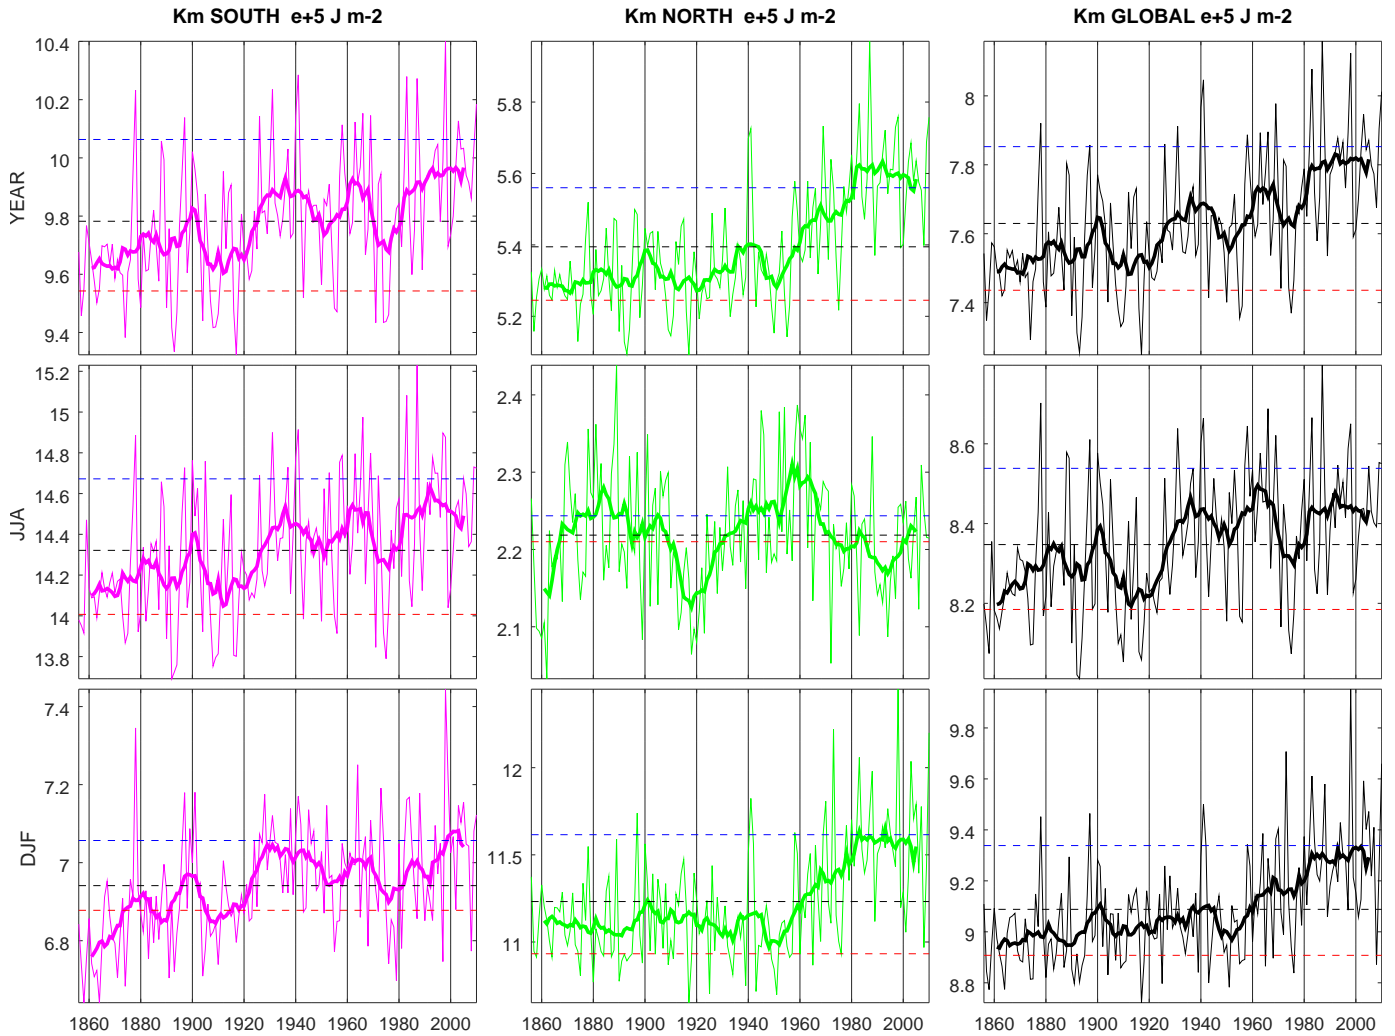


Slika 4.6. Longitudinalno-vertikalni presjek srednje raspoložive potencijalne energije ($\text{J m}^{-2} \text{ Pa}$) za DJF i JJA sezone te cijelu godinu sa srednjim stanjem, te za El Niño i La Niña događaje

Najveće promjene uočavamo oko Ekvatora od površine do 300 hPa gdje se, ovisno nastupa li El Niño ili La Niña događaj, prikladno povećaje odnosno smanjuje P_M . Ostatak tog utjecaja uočljiv je između 300 i 500 hPa.

4.3. Zonalna kinetička energija K_M

Zonalna kinetička energija kao prosječna vrijednost za stupac zraka jedinične površine prikazana je na slici 4.7 za cijelo promatrano razdoblje 1855. - 2010. godine. Po linijama 11-godišnjeg klznog srednjaka uočavamo pozitivni trend u cijelom promatranom vremenskom razdoblju. Uočavamo i višegodišnje oscilacije, pogotovo za slučaj sjeverne hemisfere u JJA sezoni. Za član K_M energetski intenzivnija je zimska sezona od ljetne. Vidljiv je doprinos El Niño događaja k povećanju energije, a La Niña k smanjenju.



Slika 4.7. Zonalna kinetička energija (10^5 J m^{-2}) za južnu, sjevernu i sveukupnu atmosferu i za DJF i JJA sezone te za cijelu godinu za razdoblje od 1856. do 2010.. Tanka linija predstavlja K_M , debela linija označava 11-godišnji klizni srednjak, plava isprekidana linija označava srednju vrijednost za El Niño, a crvena za La Niña događaje, dok crna isprekidana linija označava srednjak svih podataka

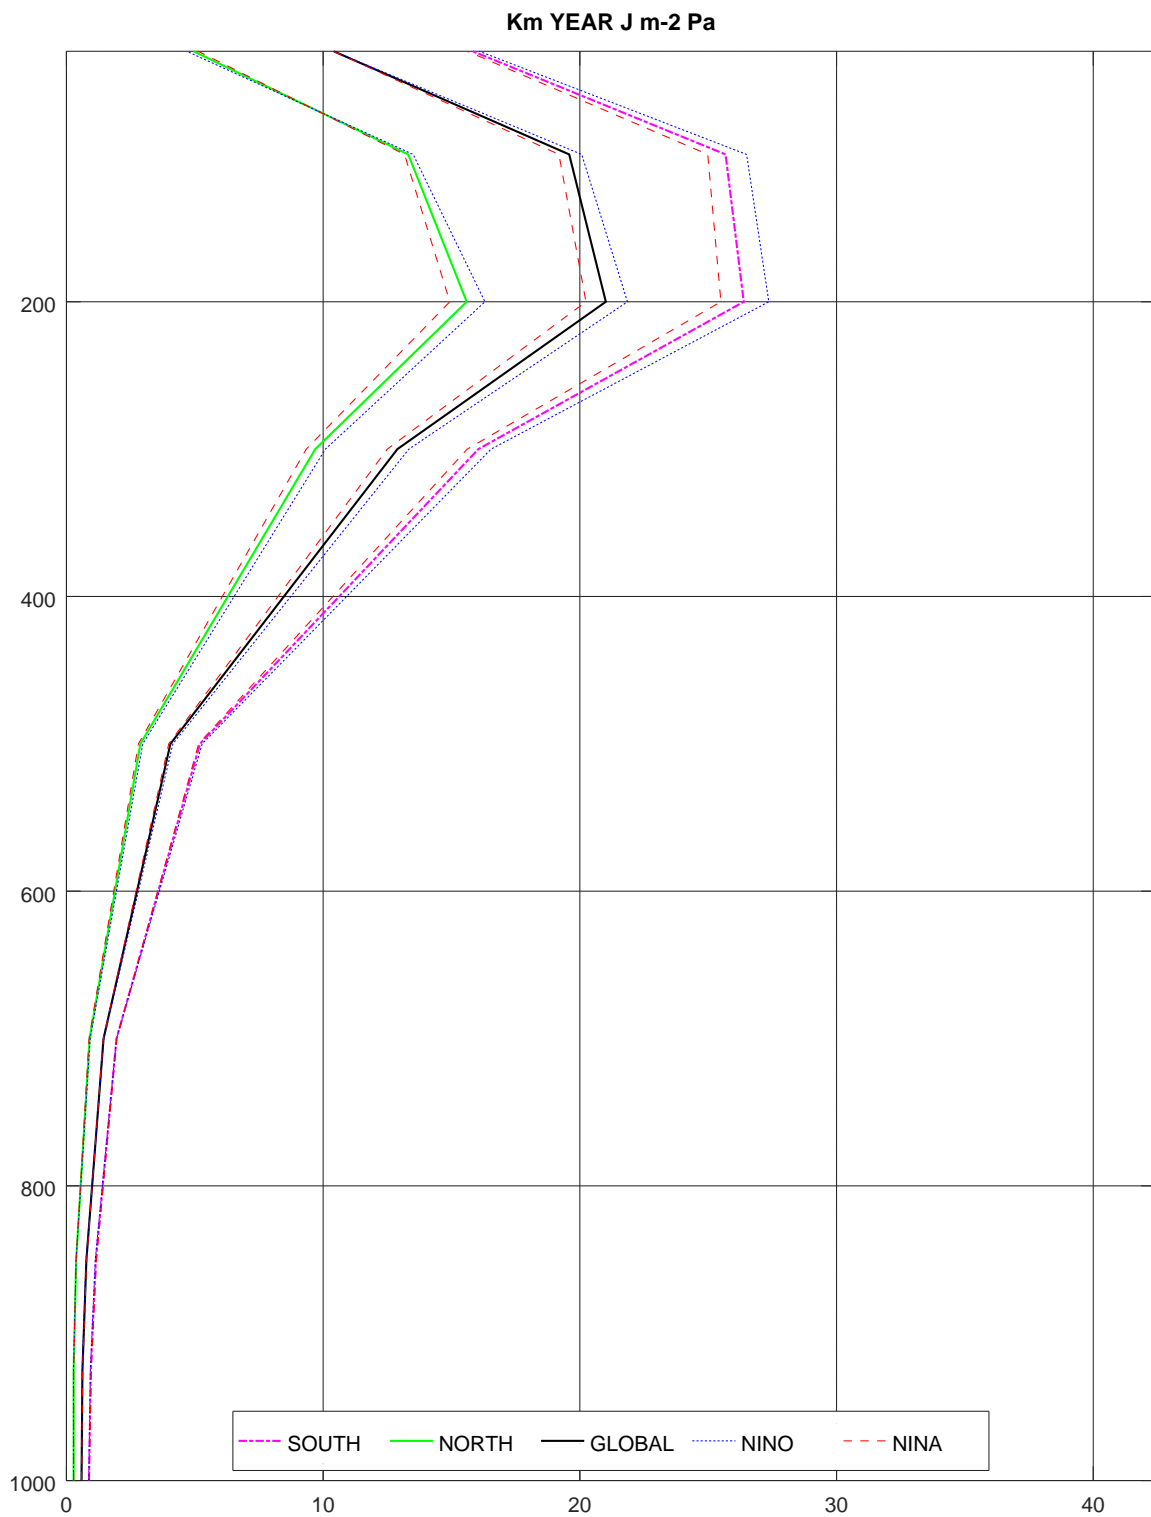
Iz Tablice 4.2 vidimo srednjak zonalne kinetičke energije na promatranom razdoblju od 1856. do 2010. godine. Vidimo da El Niño i La Niña događaji relativno doprinose i do 3% k prosječnoj vrijednosti K_M . Najveći doprinos ENSO-a članu K_M je za zimske hemisfere, dok najmanji na ljetne. Utjecaj ENSO događaja na zimske hemisfere je 2 – 3% relativno povećanje zonalne kinetičke energije za El Niño događaje, odnosno smanjenje za La Niña događaje. Ljetne hemisfere osjećaju manji doprinos ENSO-a članu K_M . Doprinos relativnoj promjeni energije je za oko 0.3 – 0.4% manji za La Niña događaje od protufaze El Niño. Dakle, El Niño i La Niña događaji doprinose više relativnoj promjeni energije u zimskoj sezoni nego u ljetnoj, ali sa slabijim utjecajem La Niña događaja.

Tablica 4.2. Tablica srednjih vrijednost zonalne kinetičke energije izražena u jedinicima 10^5J m^{-2} i postotak odstupanja od srednjaka za El Niño odnosno La Niña događaje za južnu, sjevernu i sveukupnu atmosferu, te za DJF i JJA sezone, te za cijelu godinu

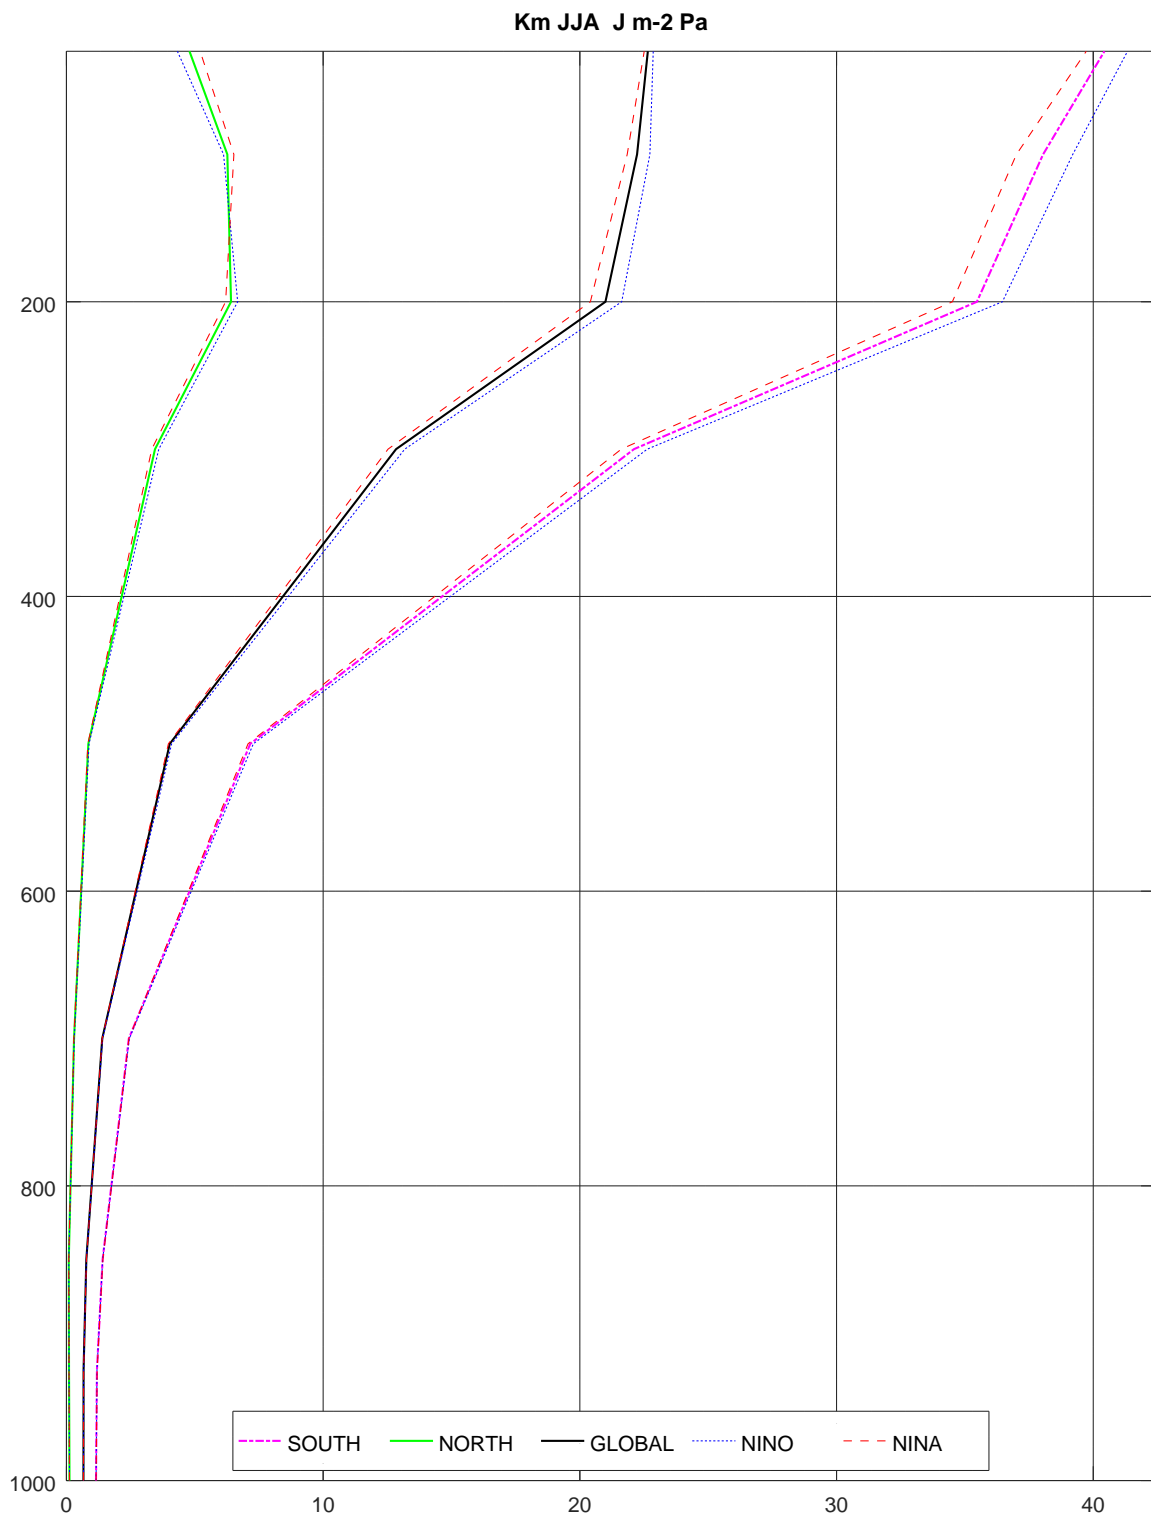
Interval	Hemisfera	El Niño	Srednjak	La Niña	El Niño	La Niña
YEAR	SOUTH	10.06	9.78	9.54	2.872 %	-2.448 %
YEAR	NORTH	5.56	5.39	5.25	3.066 %	-2.774 %
YEAR	GLOBAL	7.85	7.63	7.44	2.921 %	-2.540 %
JJA	SOUTH	14.67	14.32	14.01	2.450 %	-2.194 %
JJA	NORTH	2.24	2.22	2.21	1.128 %	-0.384 %
JJA	GLOBAL	8.54	8.35	8.18	2.290 %	-1.949 %
DJF	SOUTH	7.06	6.94	6.88	1.667 %	-0.911 %
DJF	NORTH	11.62	11.23	10.93	3.414 %	-2.667 %
DJF	GLOBAL	9.34	9.09	8.91	2.754 %	-1.985 %

Na slikama 4.8 - 4.10 prikazan je K_M u vertikalnom profilu, a uočljivo je da srednja kinetička energija raste do razine mlazne struje oko 200 hPa. El Niño i La Niña događaj najviše doprinose članu K_M na razini mlazne struje. Utjecaj ENSO faza na vertikalni profil K_M konzistentan je i ovdje: El Niño povećava, a La Niña događaji smanjuju član K_M s izuzetkom ljetne, tj. južne, hemisfere u JJA sezoni gdje utjecaj ENSO faza nije jasno vidljiv.

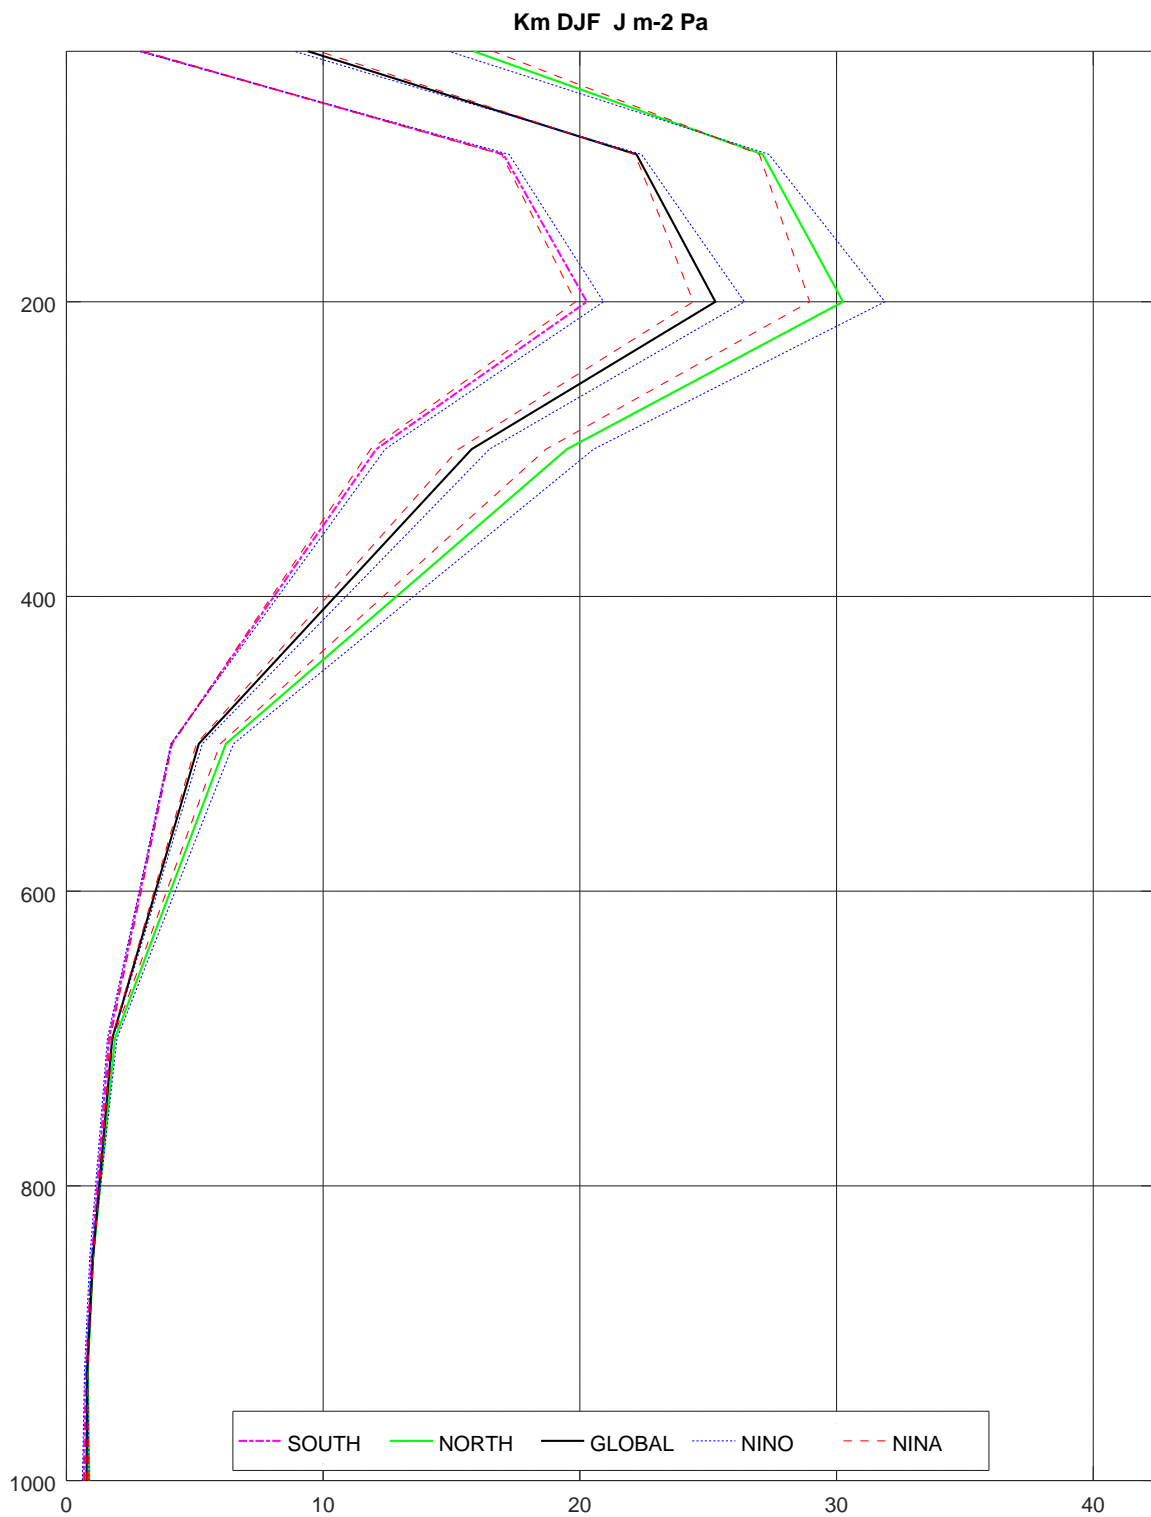
Na slici 4.11 vidimo da se u longitudinalno-vertikalnom presjeku najviše kinetičke energije nalazi oko 30° sjeverno i južno na 200 hPa. Važno je naglasiti da su prikazane iste izolije unutar svake sezone (godine) zasebno, a ista boja označava iste vrijednosti izolija kroz sve slike. Iznosom član K_M prevladava na zimskim sezonama. Na ljetnim hemisferama u obje sezone uočljiva je razlika: u JJA sezoni nema puno energije na sjevernoj hemisferi, dok na južnoj hemisferi u DJF sezoni imamo značajno više energije u usporedbi. Utjecaj ENSO faza zadržan je na visini mlazne struje kako vidimo na samim maksimuma u longitudinalno-vertikalnom presjeku, a same faze djeluju kao što je prethodno opisano: El Niño događaji doprinose porastom K_M , a La Niña događaji smanjenju.



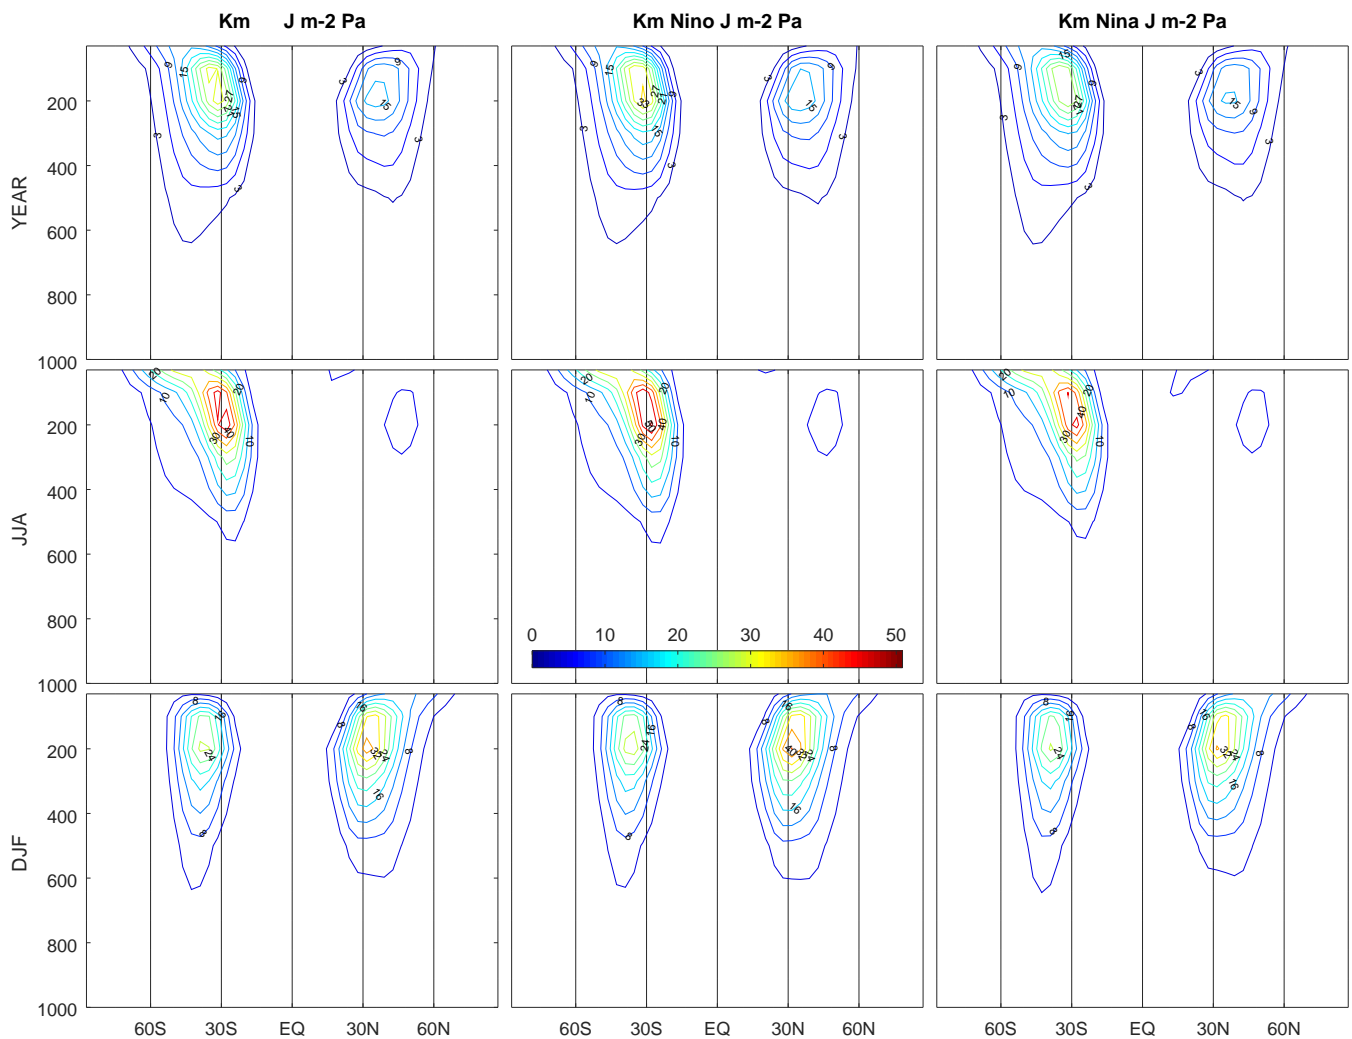
Slika 4.8. Vertikalni presjek srednje kinetičke energije ($\text{J m}^{-2} \text{Pa}$) za južnu, sjevernu i sveukupnu atmosferu za cijelu godinu



Slika 4.9. Vertikalni presjek srednje kinetičke energije ($\text{J m}^{-2} \text{ Pa}$) za južnu, sjevernu i sveukupnu atmosferu za JJA sezonu



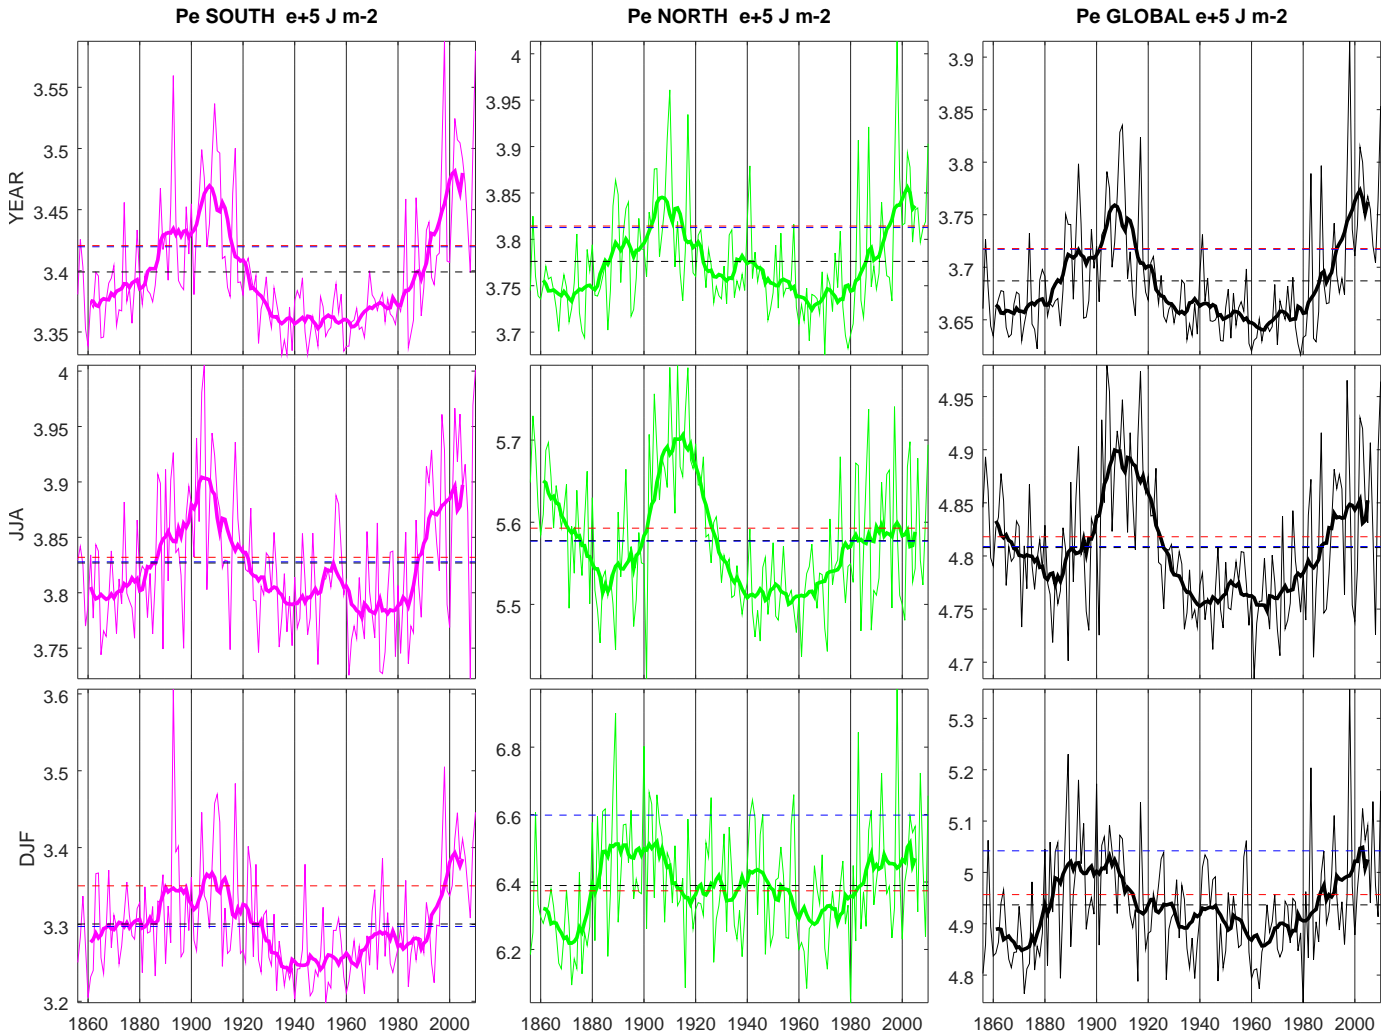
Slika 4.10. Vertikalni presjek srednje kinetičke energije ($J m^{-2} Pa$) za južnu, sjevernu i sveukupnu atmosferu za DJF sezonu



Slika 4.11. Longitudinalno-vertikalni presjek srednje kinetičke energije ($\text{m}^{-2} \text{Pa}$) za DJF i JJA sezone te cijelu godinu sa srednjim stanjem, te za El Niño i La Niña događaje

4.4. *Raspoloživa potencijalna energija makroporemećaja P_E*

Pregled raspoložive potencijalne energije makroporemećaja razdvojen po hemisferama i na godišnje te JJA i DJF sezonske vrijednosti vidimo na slici 4.12. Deblja liniji koja prikazuje 11-godišnji srednjak ukazuje na dekadne oscilacije. Skale na slici nisu jednake, a to treba uvažiti prilikom analize. Promotrimo li rezultate na slici 4.12 u kontekstu rezultata u radu autora Kim i Kim (2012) koji se temelje na mjerenjima, uočljivo je da su rezultati usporedivi. Međutim, P_E izračunat na temelju simulacije modelom SPEEDY ovisan je o stacionarnom članu P_{SE} , dok je doprinos tranzijentnog člana P_{TE} gotovo zanemariv što ne odgovara rezultatima dobivenim na temelju mjerenih podataka u radu autora Kim i Kim (2012). Odstupanje ćemo dodatno komentirati zajedno s članom kinetičke energije makroporemećaja K_E , a dalje nastavljamo promatrati član P_E u kontekstu El Niño i La Niña događaja.



Slika 4.12. Vrtložna raspoloživa potencijalna energija ($10^5 Jm^{-2}$) za južnu, sjevernu i sveukupnu atmosferu i za DJF i JJA sezone te za cijelu godinu za razdoblje od 1856. do 2010.. Tanka linija predstavlja P_E , debela linija označava 11-godišnji klizni srednjak, plava isprekidana linija označava srednju vrijednost za El Niño, a crvena za La Niña događaje, dok crna isprekidana linija označava srednjak svih podataka

Na slici 4.12 član P_E je u obje sezone, kao i za godišnje vrijednosti, iznosom veći na sjevernoj hemisferi s najvišim vrijednostima u DJF sezoni, a ujedno ima i značajniju međusezonsku varijaciju od do sada promotrenih P_M i K_M . Trend nije jasno uočljiv. Iznos člana P_E raste na zimskoj hemisferi. Za godišnji srednjak vidimo da za vrijeme El Niño i La Niña događaja iznos člana P_E raste jednako, u JJA sezoni El Niño događaji ne utječu na energiju dok La Niña događaji slabo povećavaju P_E . ENSO najviše doprinosi DJF sezoni kada El Niño događaji dovode do porasta člana P_E na sjevernoj hemisferi i bez utjecaja na južnu hemisferu, dok su La Niña događaji odgovorni za slabiji porast na južnoj hemisferi bez značajnog utjecaja na sjevernu hemisferu.

U Tablici 4.3 navedene su srednje vrijednosti raspoložive potencijalne energije ma-

kroporemećaja zajedno s relativnim utjecajem El Niño i La Niña događaja. Uočavamo da je utjecaj relativno slabiji nego kao kod ostalih, do sad promotrenih, članova (P_M i K_M). Na ovaj član i El Niño i La Niña događaji utječu povećanjem iznosa P_E iako je do sada La Niña smanjivala količinu energije, a pri tome smo izostavili slučajeve kad je utjecaj ENSO-a oko 0%. Utjecaj El Niño i La Niña događaja je zanemarivo malen za JJA sezonu, dok u DJF sezoni uočavamo utjecaj na član P_E u obliku relativnog povećanja iznosa od 3.268% za El Niño događaje na sjevernoj hemisferi i 1.505% na južnoj hemisferi za La Niña događaje. Za ukupnu hemisferu prevladaju El Niño događaji jer sjeverna hemisfera ima veće vrijednosti člana P_E . ENSO je intenzitetom najjači u DJF sezoni pa je i za očekivati da će tada utjecaj ENSO događaja biti jači na P_E .

Interval	Hemisfera	El Niño	Srednjak	La Niña	El Niño	La Niña
YEAR	SOUTH	3.42	3.40	3.42	0.606 %	0.633 %
YEAR	NORTH	3.81	3.78	3.81	0.966 %	1.009 %
YEAR	GLOBAL	3.72	3.69	3.72	0.815 %	0.834 %
JJA	SOUTH	3.83	3.83	3.83	0.027 %	0.133 %
JJA	NORTH	5.58	5.58	5.59	-0.012 %	0.272 %
JJA	GLOBAL	4.81	4.81	4.82	0.021 %	0.212 %
DJF	SOUTH	3.30	3.30	3.35	-0.098 %	1.505 %
DJF	NORTH	6.60	6.39	6.37	3.268 %	-0.245 %
DJF	GLOBAL	5.04	4.94	4.96	2.133 %	0.405 %

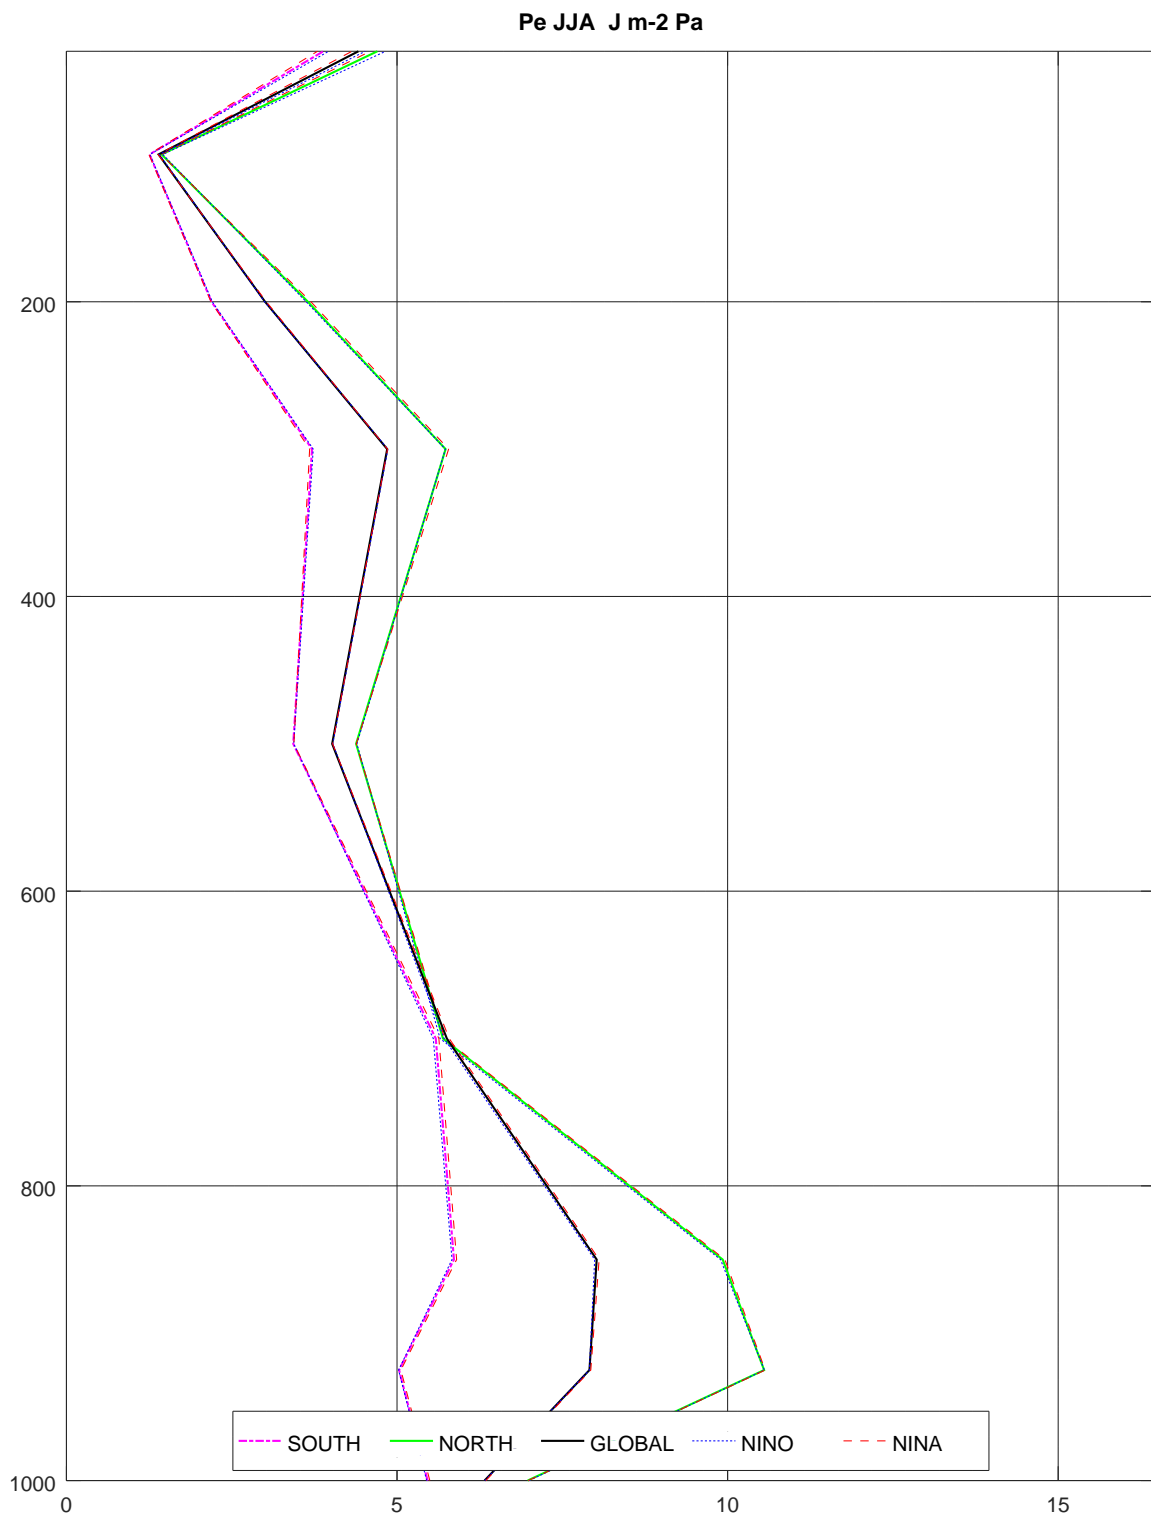
Tablica 4.3. Tablica srednjih vrijednost vrtložne raspoložive potencijalne energije ($10^5 Jm^{-2}$) i postotak odstupanja od srednjaka za El Niño odnosno La Niña događaje za južnu, sjevernu i sveukupnu atmosferu, te za DJF i JJA sezone, te za cijelu godinu

Na slikama vertikalnih profila 4.13 - 4.15 ne možemo vidljivo razdvojiti utjecaj ENSO-a, izuzev za DJF sezonu gdje je uočljiv jasan utjecaj El Niño događaja na sjevernu hemisferu, te slabiji utjecaj La Niña događaja. Slično vrijedi i za cijelu atmosferu, ali s manjom promjenom raspoložive potencijalne energije makroporemećaja. ENSO utjecaj najjači je ponovno na području od 100 do 400 hPa. Vidimo i blag utjecaj La Niña događaja na niske slojeve atmosfere na južnoj hemisferi u DJF sezoni. Primjetan je i značajan porast raspoložive potencijalne energije makroporemećaja u najvišem sloju modela, na 30 hPa, u DJF sezoni, ali zato jer je to najviši nivo modela SPEEDY koji ima slabu vertikalnu rezoluciju od samo 8 razina opravdano je smatrati taj rezultata nepouzdanim.

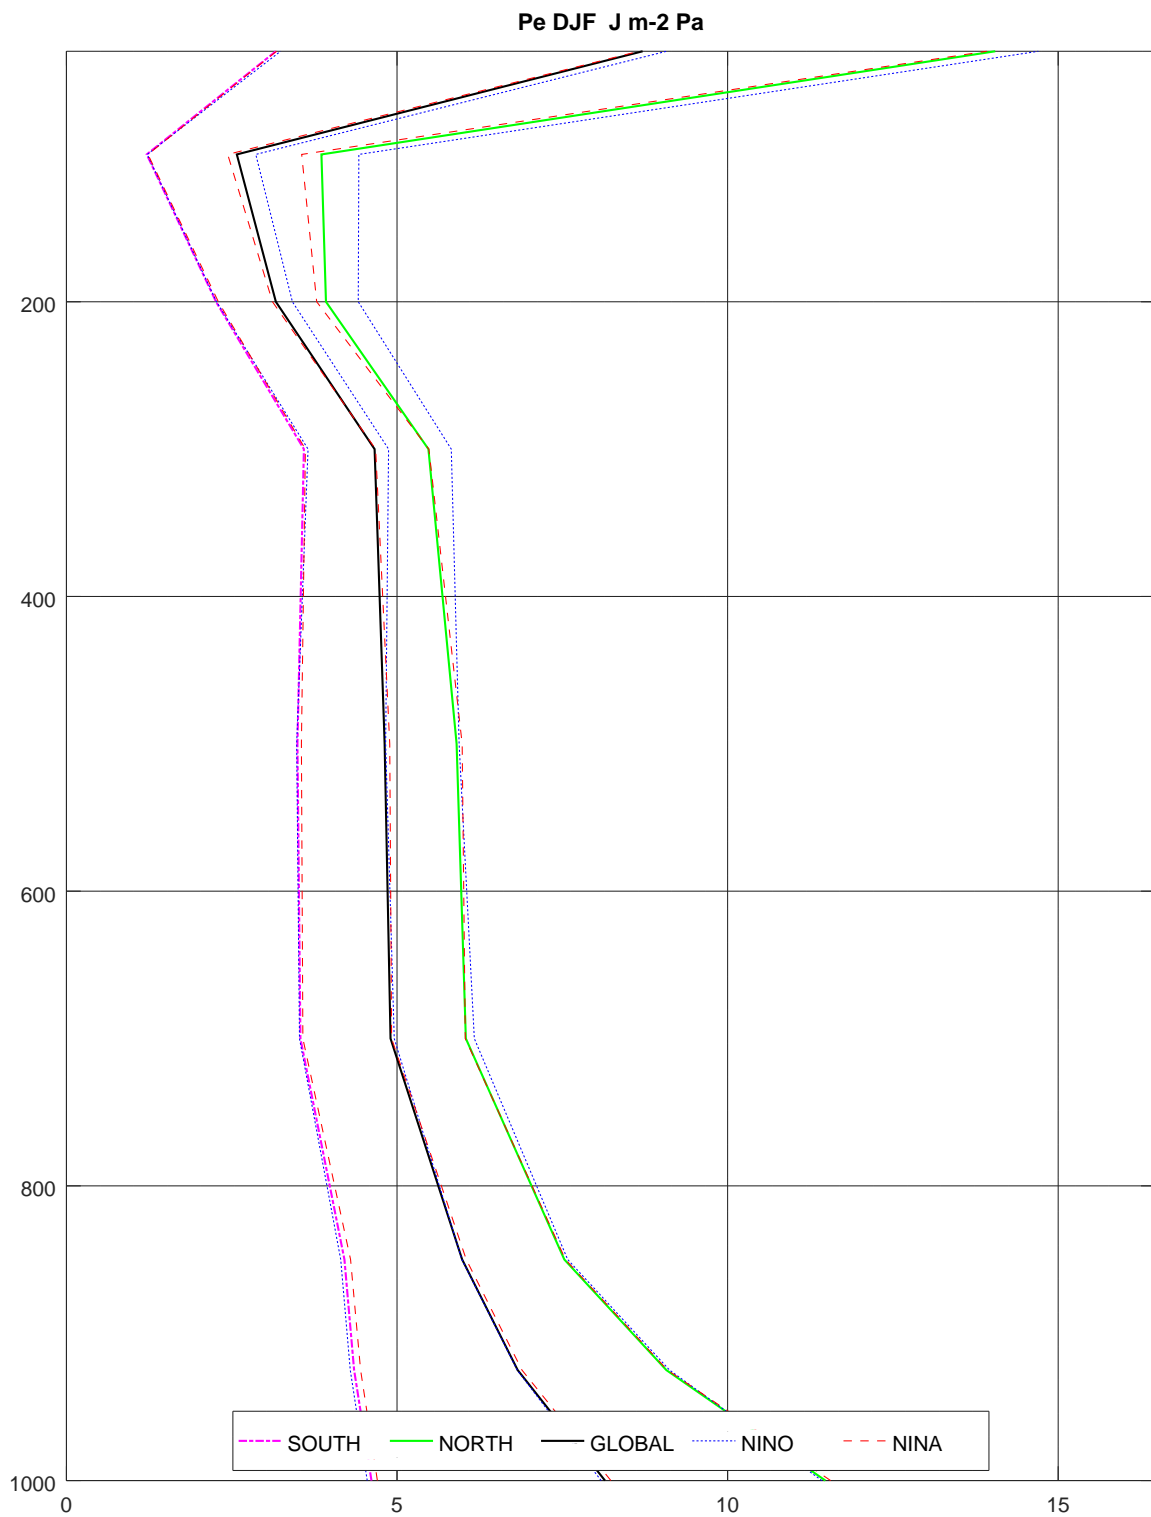
Zadnja slika, 4.16, prikazuje longitudinalno-vertikalni profil raspoložive potencijalne energije makroporemećaja. Za godišnji srednjak i sezonski srednjak JJA sezone uočavamo samo blagi porast energije oko Ekvatora na 400 hPa za El Niño i La Niña događaje.



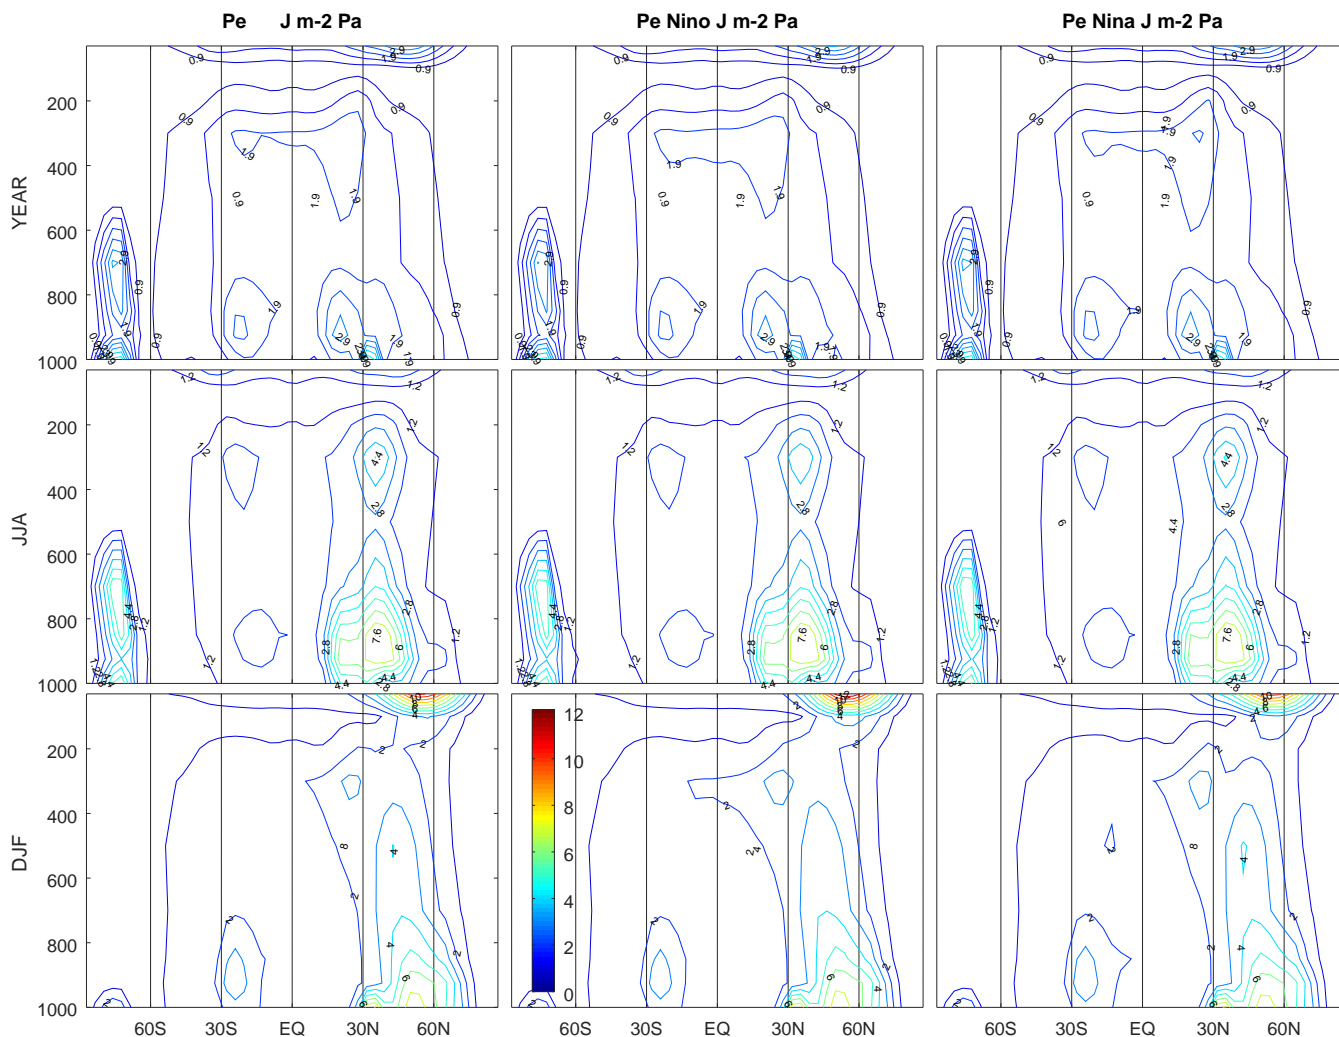
Slika 4.13. Vertikalni presjek vrtložne raspoložive potencijalne energije ($J m^{-2} Pa$) za južnu, sjevernu i sveukupnu atmosferu za cijelu godinu



Slika 4.14. Vertikalni presjek vrtložne raspoložive potencijalne energije ($J m^{-2} Pa$) za južnu, sjevernu i sveukupnu atmosferu za JJA sezonu



Slika 4.15. Vertikalni presjek vrtložne raspoložive potencijalne energije ($\text{J m}^{-2} \text{ Pa}$) za južnu, sjevernu i sveukupnu atmosferu za DJF sezonu

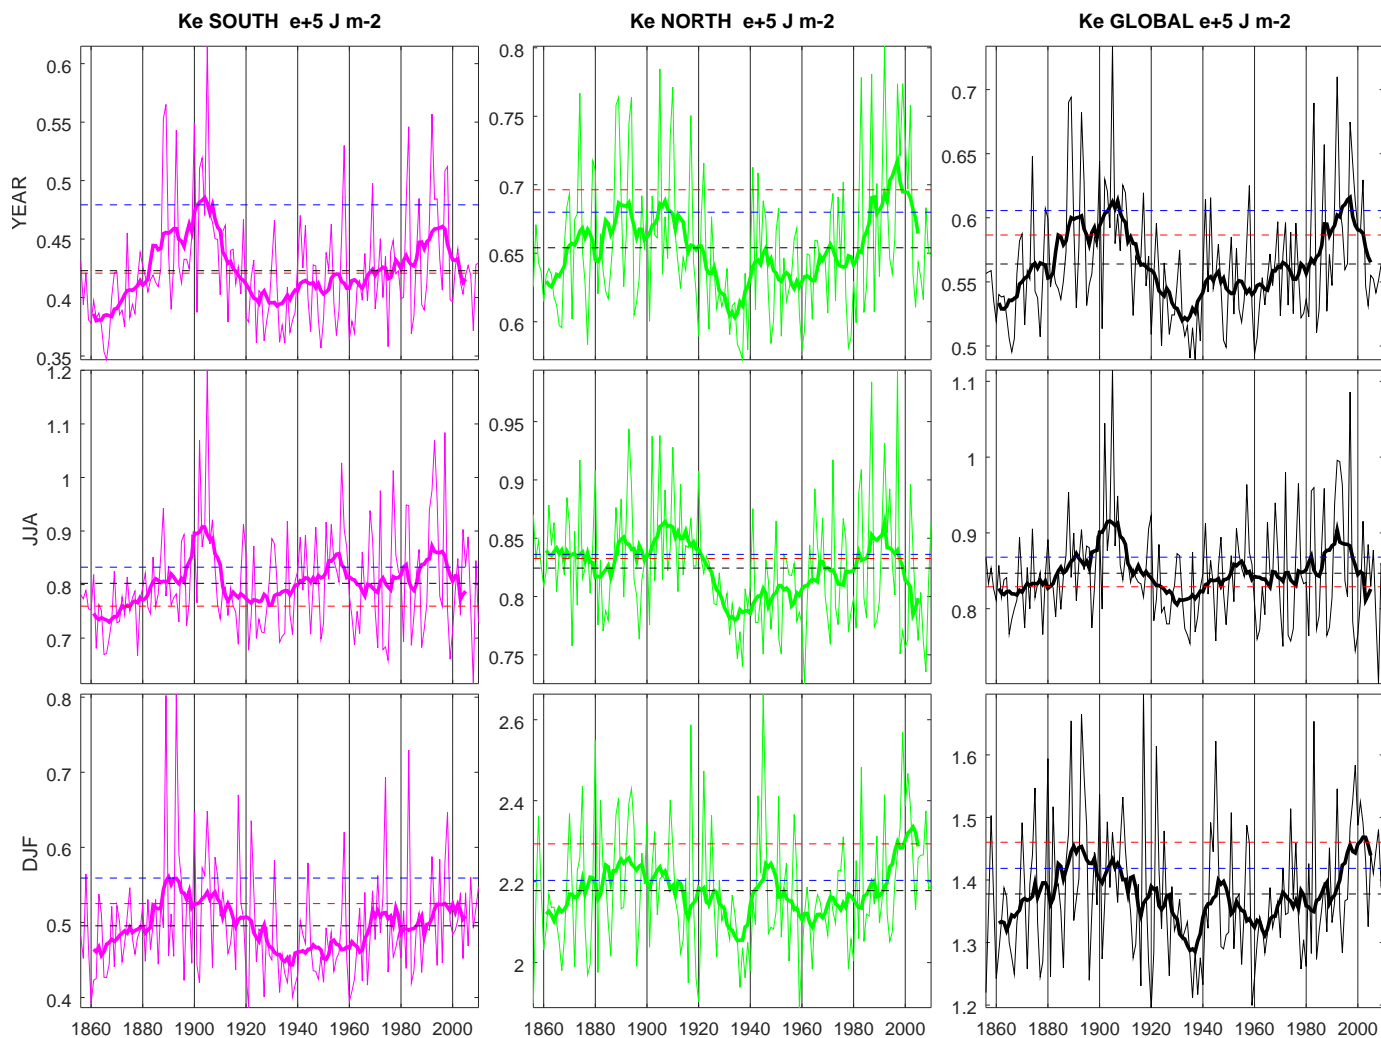


Slika 4.16. Longitudinalno-vertikalni presjek člana P_E ($J m^{-2} Pa$) za DJF i JJA sezone te cijelu godinu, te za El Niño i La Niña događaje. Paleta boja jednak je za sve presjeka, dok su izolnije jednake za svako razdoblje posebno.

P_E u godišnjim i JJA sezonskim vrijednostima ima najveći iznos na samom jugu, ali i oko 30° sjeverno, na površini i u nižim slojevima troposfere. Za JJA sezone oba maksimuma jačaju u odnosu na godišnje vrijednosti, s naglaskom na maksimum na sjevernoj hemisferi. Struktura koja se proteže preko ekvatora na 300 hPa se u JJA sezoni razdvaja na dva različita dijela, gdje opet viši iznos P_E člana vidimo na sjevernoj hemisferi. U DJF sezoni, u kojoj i uočavamo promjene za El Niño i La Niña događaje, vidimo nastajanje novog maksimuma P_E upravo na sjevernom vrhu modela. Taj rezultat smo u vertikalnom presjeku već komentirali kao nepozudan. Ostale promjene, koje bismo očekivali na temelju vertikalnog presjeka, nisu jednako intenzivne i uočljive: El Niño dovodi do povećanja energije u sjevernoj hemisferi na 300 hPa gdje se izolnije šire prema ekvatoru, dok za La Niña događaje uočavamo i jačanje P_E na južnoj hemisferi na 500 hPa i 900 hPa, ali i na sjevernoj hemisferi oko

500 hPa.

4.5. Kinetička energija makroporemećaja K_E



Slika 4.17. Kinetička energija makroporemećaja (10^5 J m^{-2}) za južnu, sjevernu i sveukupnu atmosferu i za DJF i JJA sezone te za cijelu godinu

Član kinetičke energije makroporemećaja K_E ovisi o odstupanjima vjetra od vremenskog srednjaka (tranzijentni član), ali i o odstupanjima vjetra od zonalnog srednjaka (stacionarni član). Iznos člana K_E na slici 4.17 u usporedbi s rezultatima autora Kim i Kim (2012) značajno odstupa. Prisjetit ćemo se i odstupanja tranzijentne komponente člana P_E (odstupanje temperature od vremenskog srednjaka) spomenute u prethodnom poglavlju. Niske vrijednosti u oba člana (K_E , te P_E , odnosno niska tranzijentna komponenta člana P_E) moguća su posljedica malene vremenske te grube prostorne rezolucije što za posljedicu ima nemogućnost modela da simulira tranzijentne poremećaje. Preostaje objasniti i odstupanje stacionarnog člana K_E koji je manji, te stacionarnog člana

P_E koji je veći od rezultata dobivenih na temelju mjerenja u radu Kim i Kim (2012), međutim to zahtjeva bolje razumijevanje modela SPEEDY i dodatno istraživanje.

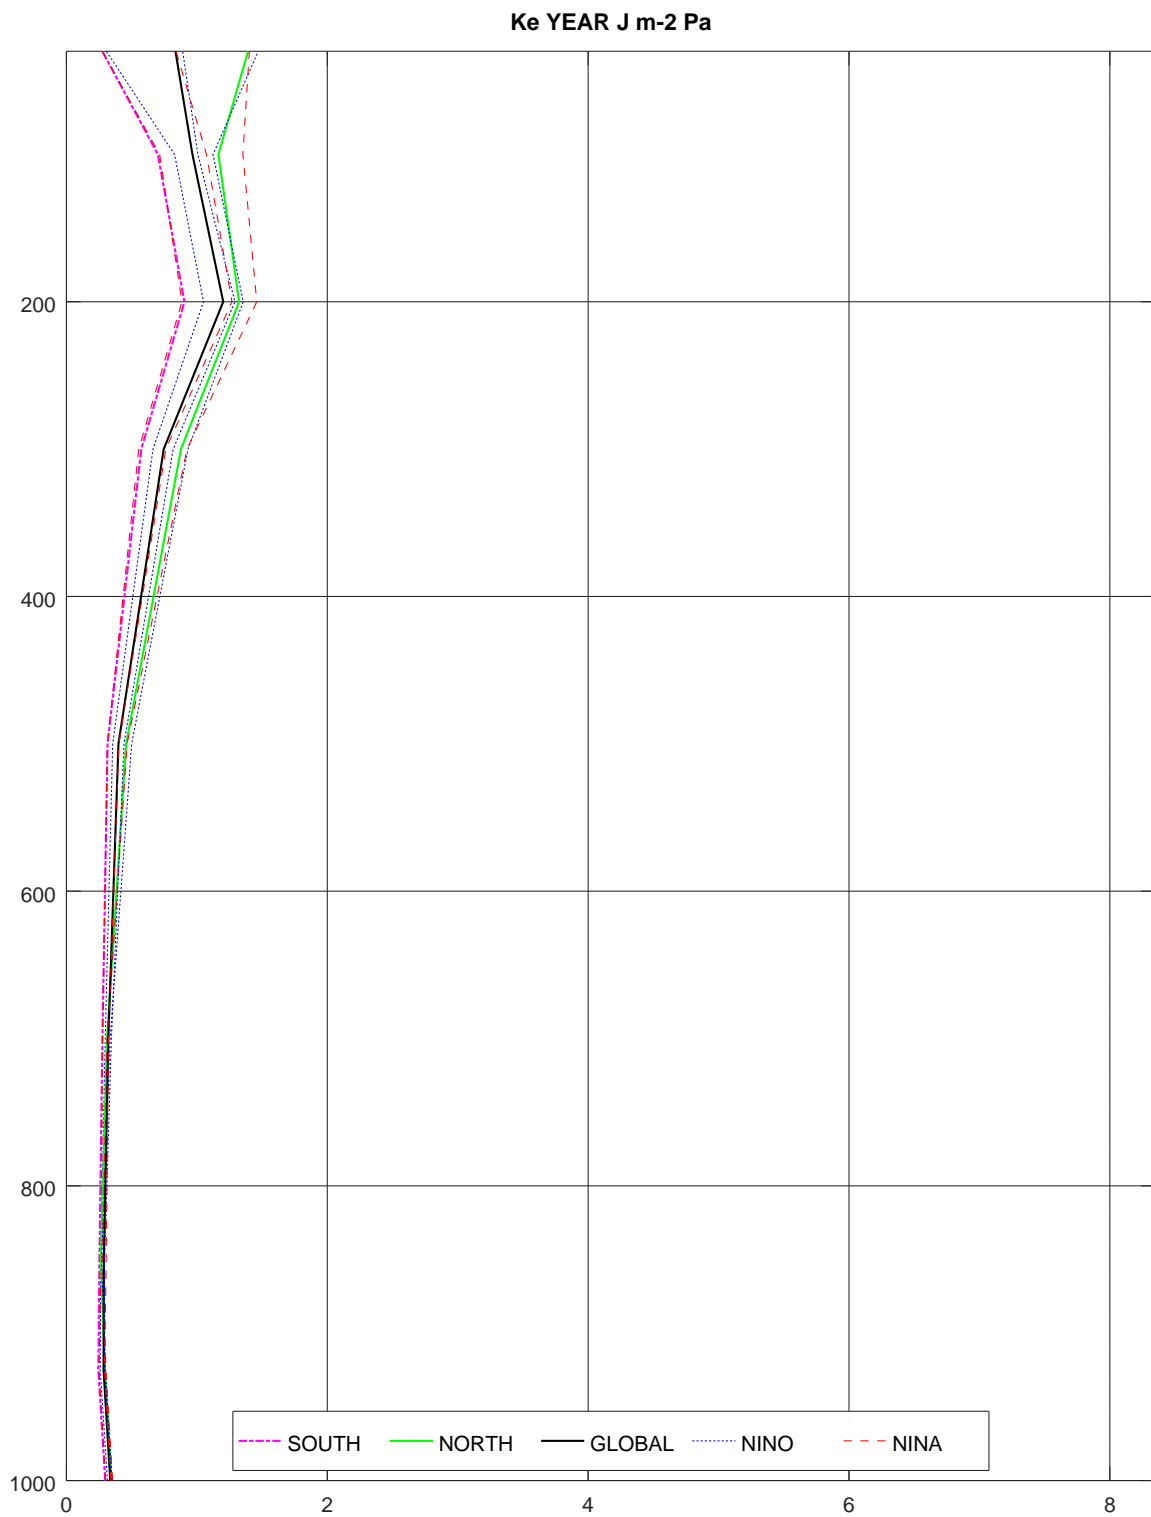
Usprkos tome tumačimo član K_E s ciljem promatranja utjecaja El Niño i La Niña događaja. Na slici 4.17 član K_E iznosom je veći na zimskim hemisferama, te je uvijek veći na sjevernoj hemisferi. Najviše iznosi tijekom zime (DJF sezona) na sjevernoj hemisferi. Uočljiv je i doprinos El Niño i La Niña događaja k povećanju K_E u DJF sezoni, ali i na sjevernoj hemisferi JJA sezone. Na južnoj hemisferi La Niña djeluje sa samnjenjem K_E . Na godišnjoj razini prevladava utjecaj El Niño događaja, s izuzetkom sjeverne hemisfere gdje je jači utjecaj La Niña događaja.

Interval	Hemisfera	El Niño	Srednjak	La Niña	El Niño	La Niña
YEAR	SOUTH	0.48	0.42	0.42	13.315 %	-0.500 %
YEAR	NORTH	0.68	0.65	0.70	3.971 %	6.476 %
YEAR	GLOBAL	0.61	0.56	0.59	7.390 %	4.012 %
JJA	SOUTH	0.83	0.80	0.76	3.758 %	-5.315 %
JJA	NORTH	0.84	0.82	0.83	1.425 %	0.997 %
JJA	GLOBAL	0.87	0.85	0.83	2.505 %	-2.104 %
DJF	SOUTH	0.56	0.50	0.53	12.837 %	5.973 %
DJF	NORTH	2.20	2.18	2.29	1.161 %	5.305 %
DJF	GLOBAL	1.42	1.38	1.46	2.971 %	6.003 %

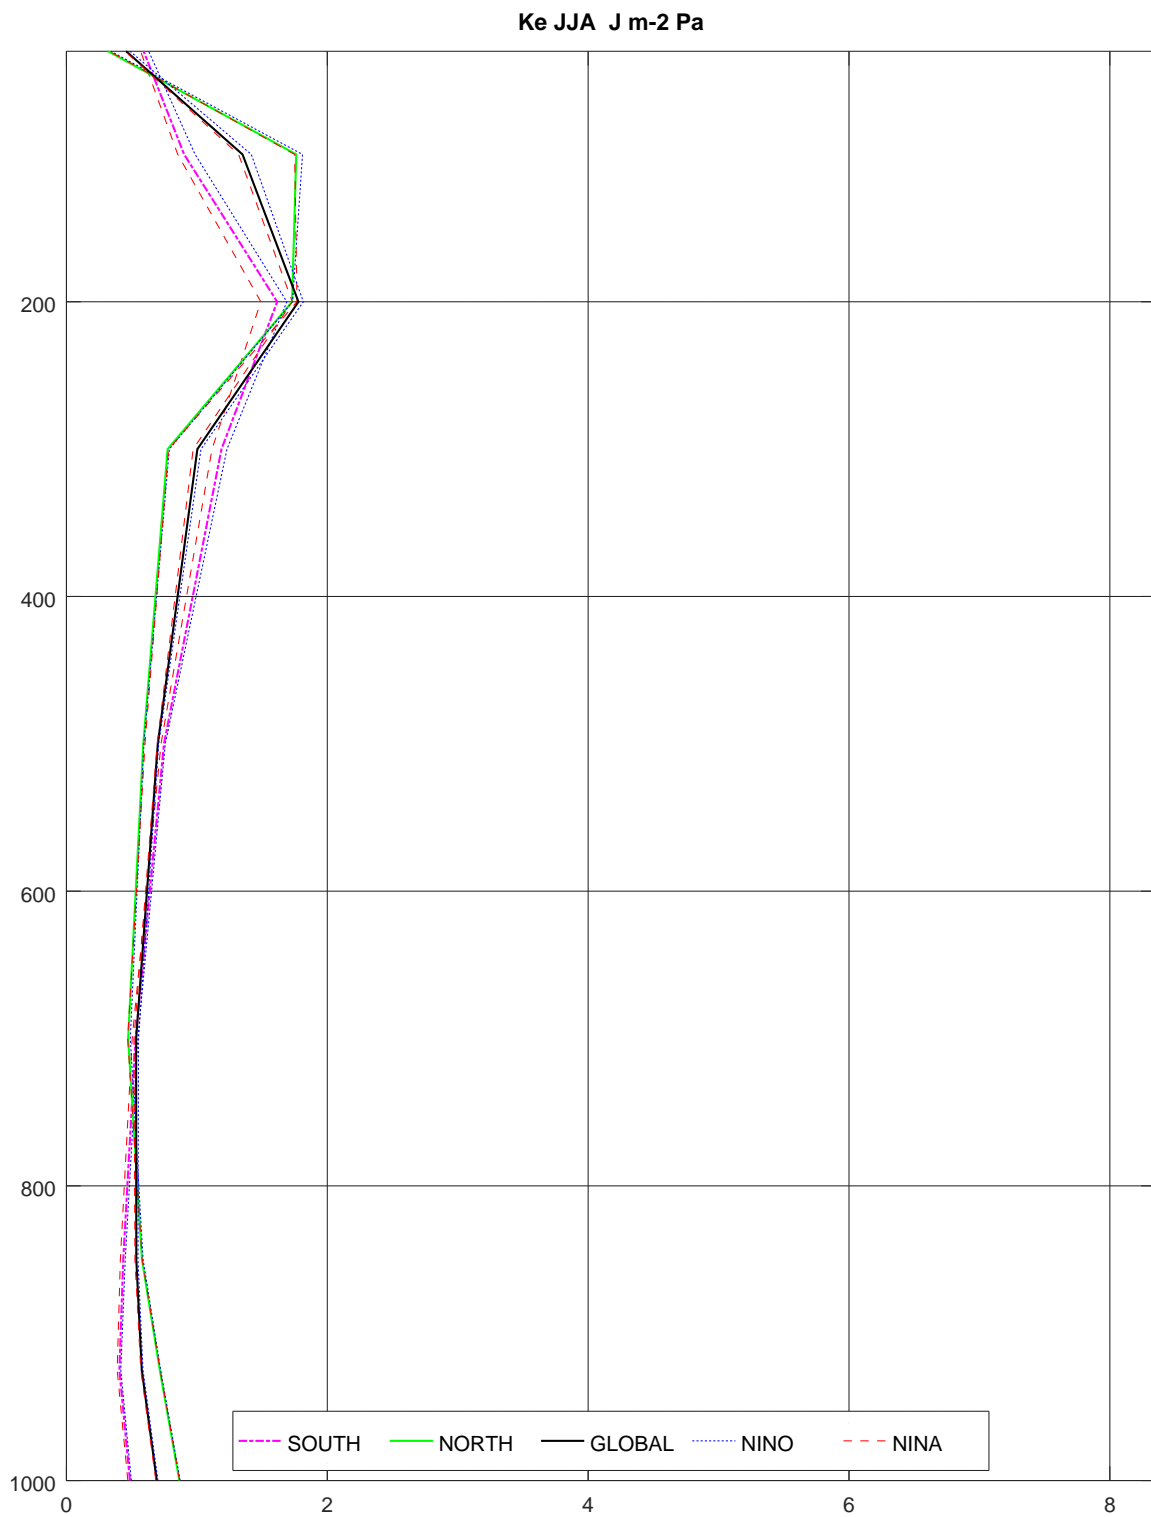
Tablica 4.4. Tablica srednjih vrijednost vrtložne kinetičke energije makroporemećaja (10^5J m^{-2}) i postotak odstupanja od srednjaka za El Niño odnosno La Niña događaje za južnu, sjevernu i sveukupnu atmosferu, te za DJF i JJA sezone, te za cijelu godinu

Iz Tablice 4.4 vidimo da El Niño događaji uvijek pridonose povećanju vrtložne kinetičke energije makroporemećaja, dok La Niña događaji u JJA sezoni smanjuju K_E . Oba događaja najviše utječu na kinetičku energiju makroporemećaja u DJF sezoni, a tad je i najjači intezitet ENSO faza. Posebno jaki doprinos u DJF sezoni ima El Niño na južnoj odnosno ljetnoj hemisferi. Na godišnjoj razini je utjecaj El Niño događaja značajniji za porast K_E člana od La Niña događaja, a i El Niño događaji djeluju na povećanje K_E na obje hemisfere s naglaskom na južnu, dok La Niña događaji povećavaju K_E samo na sjevernoj hemisferi. El Niño i La Niña događaji jačaju kinetičku energiju makroporemećaja u DJF sezoni i u godišnjoj srednjoj vrijednosti s iznimkom La Niña događaja u JJA sezoni.

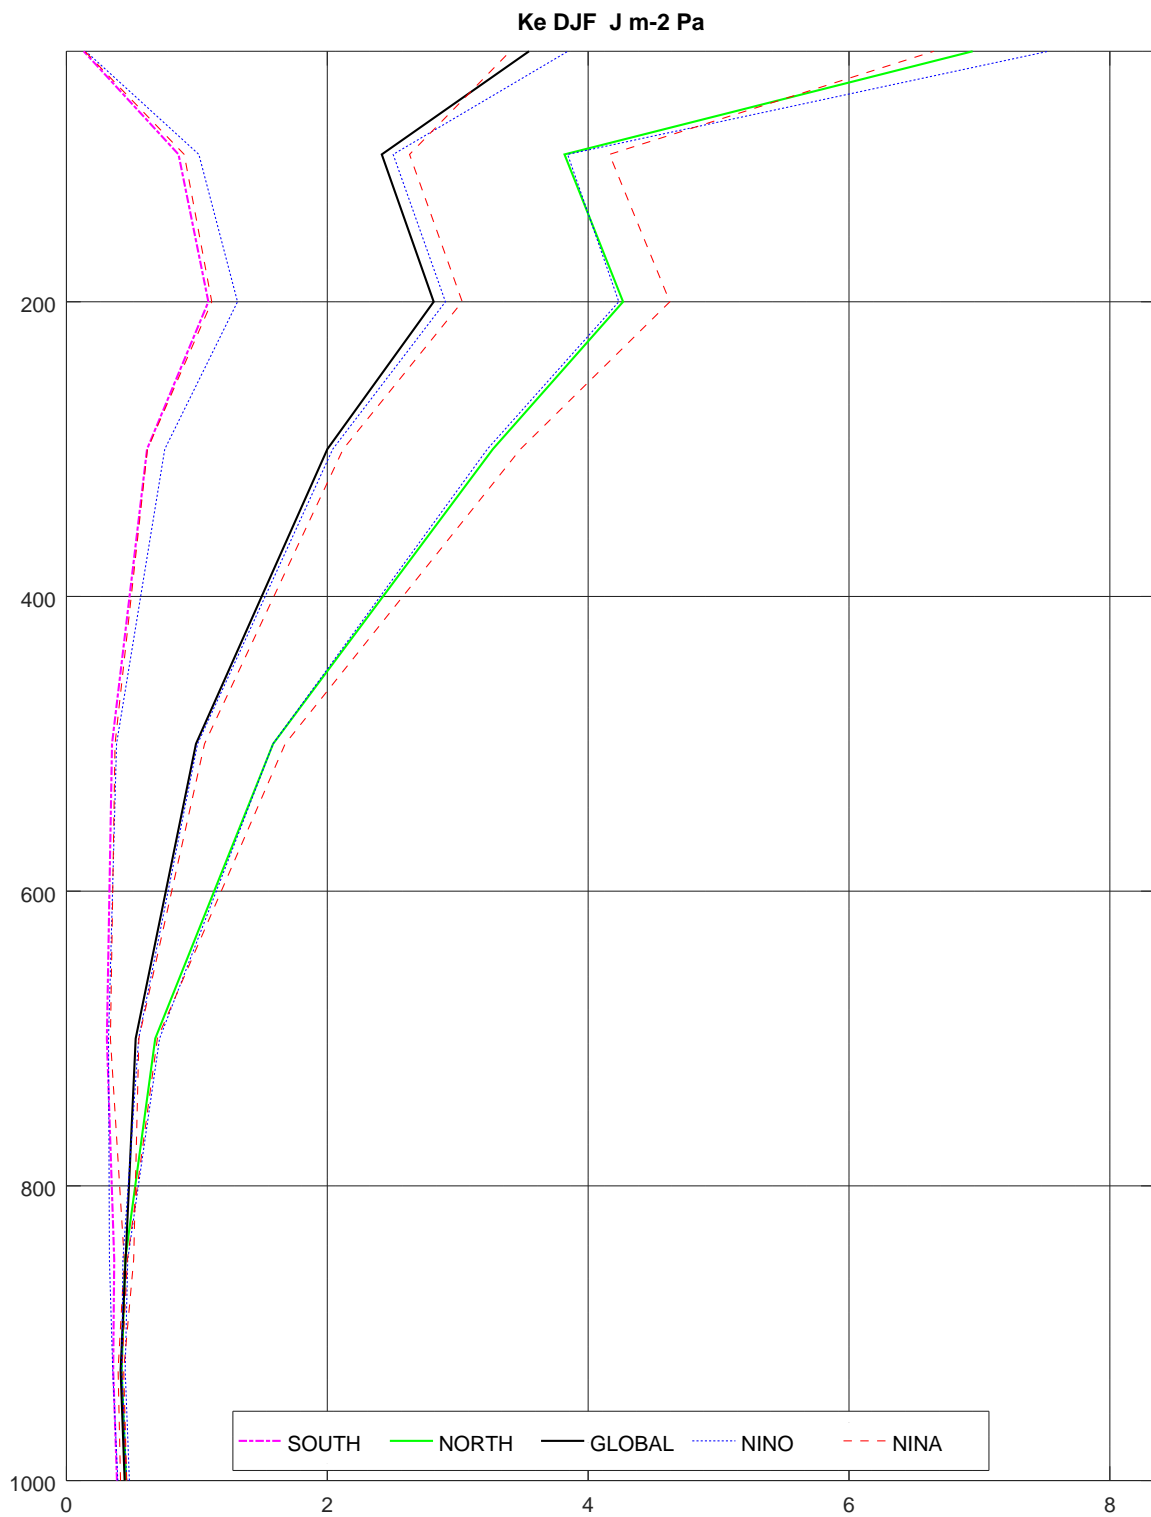
Promotrimo li vertikalni profil vrtložne kinetičke energije na slikama 4.18 - 4.20 vidimo da je doprinos ENSO događaja najizraženiji samo u višim slojevima. Najviše energije u ovom članu uočavamo tijekom DJF sezone kad je na sjevernoj hemisferi i najveći utjecaj La Niña događaja, dok za južnu hemisferu u istoj sezoni najveći doprinos energiji daje El Niño. Za cijelu atmosferu u DJF sezoni utjecaj La Niña prevladava, a El Niño najviše utječe na sam vrh promatranog dijela atmosfere. Utjecaj ENSO događaja u DJF sezoni vidi se već i na slojevima oko 600 hPa.



Slika 4.18. Vertikalni presjek vrtložne kinetičke energije ($\text{J m}^{-2} \text{ Pa}$) za južnu, sjevernu i sveukupnu atmosferu za cijelu godinu

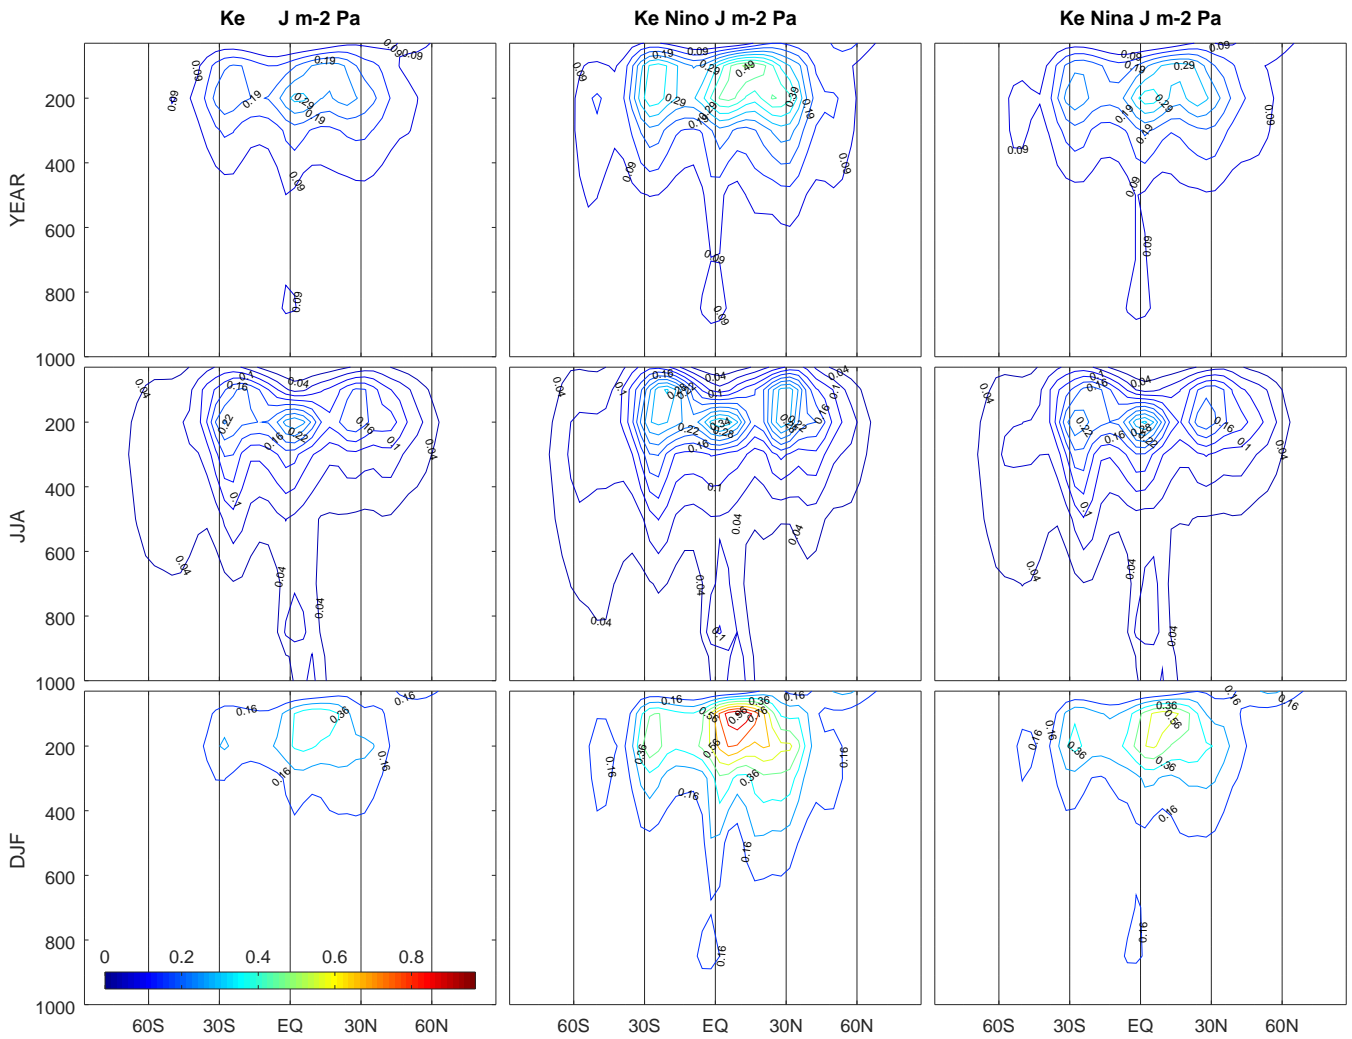


Slika 4.19. Vertikalni presjek vrtložne kinetičke energije ($J m^{-2} Pa$) za južnu, sjevernu i sveukupnu atmosferu za JJA sezonu



Slika 4.20. Vertikalni presjek vrtložne kinetičke energije ($J m^{-2} Pa$) za južnu, sjevernu i sveukupnu atmosferu za DJF sezonu

U vertikalnom profilu JJA sezona je energetski bliže godišnjem srednjaku, dok se na južnoj hemisferi uočavaju manje sezonske promjene. U vertikalnim profilima JJA sezone primjetan je još utjecaj La Niña događaja, dok je na godišnji prosjek jači utjecaj El Niño događaja na južnu hemisferu, a La Niña događaja na sjevernu hemisferu i globalno.



Slika 4.21. Longitudinalno-vertikalni presjek kinetičke potencijalne energije($J m^{-2} Pa$) za DJF i JJA sezone te cijelu godinu sa srednjim stanjem, te za El Niño i La Niña događaje

Preostaje još promotriti sliku 4.21 s longitudinalno-vertikalnim presjekom vrtložne kinetičke energije. Na slikama vidimo maksimum K_E na sjevernoj hemisferi, sa slabijim maksimumom na južnoj hemisferi. Također, primjetno je da u JJA sezoni imamo i razdvajanje maksimuma na sjevernoj hemisferi na dva različita maksimuma od kojih je jedan bliži ekvatoru, dok se drugi zadržava na 30° sjeverno. Na godišnjoj razini utjecaj El Niño događaja jača oba maksimuma, ali dominantno ima utjecaj na sje-

vernu hemisferu. La Niña na godišnjem srednjaku doprinosi povećanjem energije na sjevernoj hemisferi, dok je na južnoj primjetna preraspodjela energije k polu. U JJA sezoni imamo tri maksimuma koji najviše jačaju pod utjecajem El Niño događaja, a nešto slabije i tokom La Niña događaja kad je naglasak više na južnoj hemisferi. U DJF sezoni vidimo spajanje ekvatorskog i sjevernog maksimuma u jedan centralni maksimum. Za La Niña događaja član K_E raste pa dva maksimuma postaju izraženija, a najprimjetniji je utjecaj El Niño događaja koji dovodi do izrazitog porasta energije oko Ekvatora te izraženim porastom južnog maksimuma. Također, dio energije se iz prosječne raspodjele u DJF sezoni tokom El Niño i La Niña događaja preraspodijeljuje k nižim slojevima atmosfere od izvora u višim slojevima oko ekvatora.

5. Zaključak

Cilj rada bio je promotriti utjecaj događaja ENSO na komponente Lorenzovog energetskog ciklusa na temelju simulacija modelom SPEEDY. Srednje vrijednosti članova Lorenzovog ciklusa prikazane su za razdoblje od 1855. do 2010. godine zajedno sa srednjim vrijednostima za to razdoblje u vertikalnom i longitudinalno vertikalnom profilu. Rezultati su također odvojeni za godišnje i sezonske (DJF i JJA) srednjake, te za južnu i sjevernu hemisferu te ukupnu atmosferu.

Među članovima srednjeg stanja uočeni su trendovi porasta vrijednosti energije na promatranom razdoblju, a u svim članovima postoje i višegodišnje oscilacije. Uočena je sezonska ovisnost svih članova (P_M , K_M , P_E i K_E) tako da su većeg iznosa na zimskoj hemisferi. Utjecaj faza ENSO-a izražen je u DJF sezoni, vjerojatno zbog najvećeg intenziteta ENSO-a u toj sezoni. Relativno najveći utjecaj (i preko 10%) utvrdili smo za član K_E iako je isti član niži od očekivanih vrijednosti dobivenih iz mjerenja. Utjecaj ENSO-a na ostale članove mijenja iznose energije i do 3%. Događaji El Niño povećavaju energiju srednjeg strujanja, a La Niña događaji smanjuju, dok za energiju makroporemećaja utjecaj faza ENSO-a ovisi o sezoni i hemisferi. Utjecaj ENSO-a vidljiv je i u prostornoj raspodjeli energije. Za sve članove se to odnosilo na povećanje ili smanjenje iznosa nekih od postojećih maksimuma u longitudinalno-vertikalnoj raspodjeli energije, najviše između 30° južno i sjeverno, ali i izvan tog područja, ovisno o članu. Rezultat možemo povezati s fizikalnim procesom daljinskog utjecaja ENSO-a koji se odvija putem Rossbyjevih valova kako navodi (Trenberth et al. (1998)).

Za model SPEEDY uspješno je pokazan daljinski utjecaj Rossbyjevim valovima u radu Herceg Bulić i Branković (2007) te stoga možemo smatrati vjerodostojnim rezultate koji pokazuju utjecaj ENSO-a na komponente Lorenzovog ciklusa. Međutim, zbog kompleksnosti procesa vezanih uz energiju makroporemećaja model SPEEDY ih ne reproducira vjerno već ih podcijenjuje u odnosu na izmjerene vrijednosti. Razlog tome mogu biti pojednostavljene parametrizacije modela, gruba prostorna skala koja onemogućuje prikaz poremećaja male skale, ali i korištenje mjesečnih vrijednosti u izračunu čime se gubi određena informacija o tranzijentnim poremećajima.

Neovisno, ovaj rad pokazuje utjecaj ENSO-a na članove Lorenzovog energetskog ciklusa. Za bolje određivanje komponenti Lorenzovog ciklusa predlaže se korištenje rezultata simulacija kompleksnijih modela, ali i dodatni testovi osjetljivosti.

Literatura

- Chapra, S. (2009). *Numerical Methods for Engineers* (6 ed.). New York: McGraw-Hill.
- Davey, M., A. Brookshaw, i S. Ineson (2014). The probability of the impact of ENSO on precipitation and near-surface temperature. *Climate Risk Management* 1, 5 – 24.
- Eaton, J. W., D. Bateman, S. Hauberg, i R. Wehbring (2017). *GNU Octave version 4.2.1 manual: a high-level interactive language for numerical computations*.
- Herceg Bulić, I. i Č. Branković (2007). ENSO forcing of the northern hemisphere climate in a large ensemble of model simulations based on a very long sst record. *Climate Dynamics* 28(2), 231–254.
- Holton, J. R. (2004). *An introduction to dynamic meteorology* (4 ed.). Burlington: Elsevier Academic Press.
- Kim, Y.-H. i M.-k. Kim (2012). Examination of the global Lorenz energy cycle using MERRA and NCEP-reanalysis 2. *Climate Dynamics* 40.
- Kucharski, F., F. Molteni, M. P. King, R. Farneti, I.-S. Kang, i L. Feudale (2013). On the need of intermediate complexity general circulation models: A “SPEEDY” example. *Bulletin of the American Meteorological Society* 94(1), 25–30.
- Lorenz, E. N. (1955). Available potential energy and the maintenance of the general circulation. *Tellus* 7(2), 157–167.
- Marquet, P. (2017). The last paper "On the theory of storm" (Zur Sturmtheorie) published by Max Margules in 1906. *Meteorologische Zeitschrift* 23(11), 481–497.
- Oort, A. H. (1964). On estimates of the atmospheric energy cycle. *Monthly Weather Review* 92(11), 483–493.
- Peixóto, J. P. i A. H. Oort (1974). The annual distribution of atmospheric energy on a planetary scale. *Journal of Geophysical Research (1896-1977)* 79(15), 2149–2159.
- Salby, M. L. (2012.). *Fundamentals of atmospheric physics*. San Diego: Academic Press.
- Schulzweida, U. (2019). CDO User Guide.
- Trenberth, K. E., G. W. Branstator, D. Karoly, A. Kumar, N.-C. Lau, i C. Ropelewski (1998). Progress during toga in understanding and modeling global teleconnections associated with tropical sea surface temperatures. *Journal of Geophysical Research: Oceans* 103(C7), 14291–14324.