

Εφαρμογές Τεχνητής Νοημοσύνης Artificial Intelligence (AI)

ΠΜΣ «ΛΟΙΜΩΞΙΟΛΟΓΙΑ» 2019-2021



apouliak@med.uoa.gr
apou1967@gmail.com

Δρ. Α. Πουλιάκης
Φυσικός Ηλεκτρονικός Ραδιοηλεκτρολόγος
Ιατρική Σχολή Ε.Κ.Π.Α.
Β' Εργαστήριο Παθολογικής Ανατομικής
Π.Γ.Ν. «ΑΤΤΙΚΟΝ»

Στόχοι

- Επιγραμματικά ιστορικά στοιχεία
- Νοημοσύνη, ευφυΐα, τεχνητή νοημοσύνη (ΤΝ)
- Τεχνητά νευρωνικά δίκτυα
- Βήματα για την κατασκευή συστημάτων ΤΝ
- Παραδείγματα εφαρμογών στην ιατρική

Μυθολογία

- Έχουμε αναφορές από τη μυθολογία που φαίνεται να δείχνουν την επιθυμία του ανθρώπου για νοήμονες μηχανές
- Ο Τάλος θεωρείται το πρώτο ρομπότ που κατασκευάστηκε ποτέ ή δημιουργήθηκε από τη φαντασία




Ιστορία

- Ο μηχανισμός των Αντικυθήρων, γνωστός και ως αστρολάβος των Αντικυθήρων
- Αναλογικός, μηχανικός υπολογιστής και όργανο αστρονομικών παρατηρήσεων



Αυτόματα

- Μηχανές με δυνατότητα κίνησης
- Κατασκευάζονταν από την αρχαιότητα με τη βοήθεια του ατμού και υδραυλικής πίεσης
- Και αργότερα με τη βοήθεια ελατηρίων



Ρομπότ



Boston Dynamics

**The
Guardian**

Amazon Alexa

- A [virtual assistant AI](#),
- Voice interaction
- music playback
- making to-do lists
- [setting alarms](#)
- streaming podcasts
- playing audiobooks
- providing weather, traffic, sports, and other real-time information, such as [news](#).
- Alexa can also control several [smart devices](#) using itself as a [home automation](#) system.

- Users are able to extend the Alexa capabilities by installing "skills" (additional functionality developed by third-party vendors, in other settings more commonly called [apps](#) such as weather programs and audio features).

Αυτόνομα οχήματα (self driving cars)

- Self-driving car, (autonomous vehicle (AV)) connected and autonomous vehicle (CAV), driverless car, robo-car, or robotic car
- Έχουν τη δυνατότητα να «μετράνε» τον περιβάλλοντα χώρο και να κινούνται με ασφάλεια χωρίς ανθρώπινη παρέμβαση.
- Χρησιμοποιούν πολλούς αισθητήρες για να συλλέξουν στοιχεία από το περιβάλλον και να τα επεξεργαστούν σε πραγματικό χρόνο:
 - radar, lidar, sonar, GPS, odometry και συστήματα μέτρησης αδράνειας (επιταχυνσιόμετρα και γυροσκόπια).
 - Συστήματα ελέγχουν χρησιμοποιούν τις πληροφορίες και καθορίζουν τρόπους πλοήγησης / αντίδρασης καθώς και τα εμπόδια και οδική σήμανση.

Under the bonnet

How a self-driving car works

Signals from **GPS (global positioning system)** satellites are combined with readings from tachometers, altimeters and gyroscopes to provide more accurate positioning than is possible with GPS alone

Lidar (light detection and ranging) sensors bounce pulses of light off the surroundings. These are analysed to identify lane markings and the edges of roads

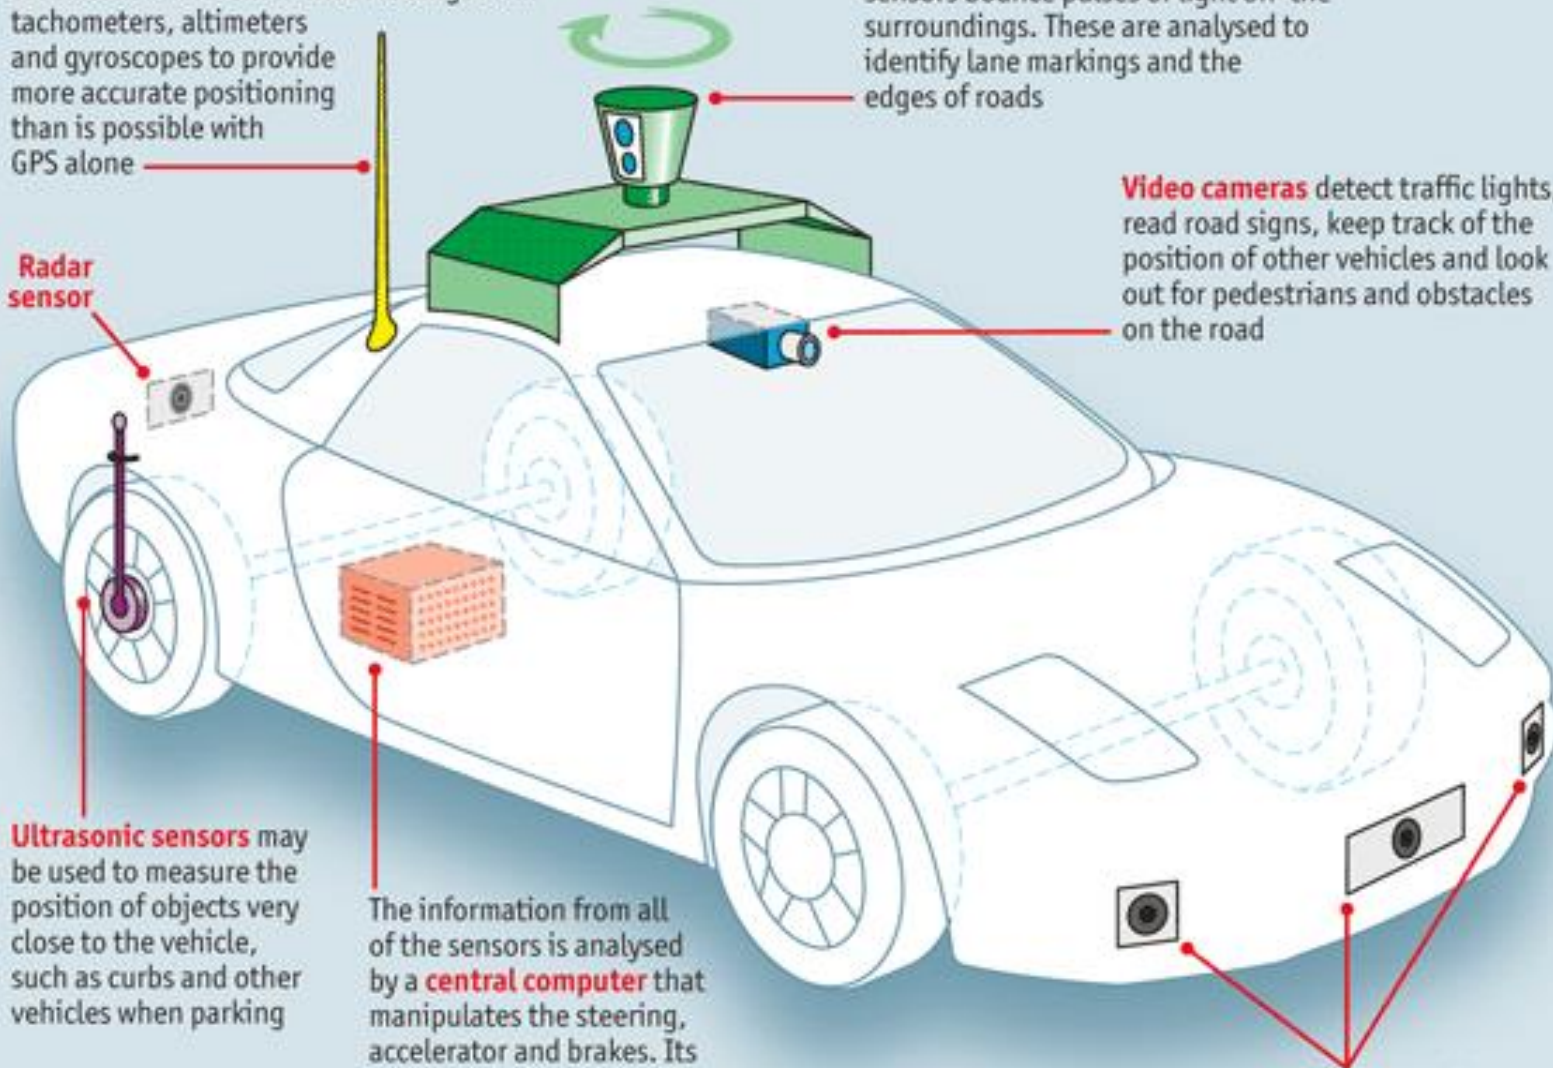
Video cameras detect traffic lights, read road signs, keep track of the position of other vehicles and look out for pedestrians and obstacles on the road

Radar sensor

Ultrasonic sensors may be used to measure the position of objects very close to the vehicle, such as curbs and other vehicles when parking


The information from all of the sensors is analysed by a **central computer** that manipulates the steering, accelerator and brakes. Its software must understand the rules of the road, both formal and informal

Radar sensors monitor the position of other vehicles nearby. Such sensors are already used in adaptive cruise-control systems



Νοημοσύνη

- Τι είναι ;;;;
- το σύνολο των γνωστικών ικανοτήτων του ανθρώπου, δηλαδή η αντίληψη, η μνήμη, ο συνειρμός, η φαντασία, η προσοχή και η διάνοηση, και ειδικότερα η ικανότητα προσαρμογής σε νέες καταστάσεις και η ικανότητα να αντιλαμβάνεται ομοιότητες, διαφορές και σχέσεις



According to the manufacturer, Sophia uses:

1. Artificial intelligence
2. Visual data processing and facial recognition
3. Imitates human gestures and facial expressions
4. Is able to answer certain questions and to make simple conversations on predefined topics (e.g. on the weather).
5. Uses voice recognition (speech-to-text) technology
6. is designed to get smarter over time

7. speech-synthesis ability also allows her to sing

8. The AI program analyses conversations and extracts data that allows it to improve responses in the future.

Μηχανισμοί της Νοημοσύνης

Για περισσότερο από 2500 χρόνια, φιλόσοφοι (Αριστοτέλης, Ηράκλειτος, Descartes ...), προσπάθησαν να περιγράψουν τον μηχανισμό

1. της μάθησης
2. της απομνημόνευσης
3. της όρασης
4. της αντίληψης και
5. του συλλογισμού

Τα ερευνητικά πεδία της Τεχνητής Νοημοσύνης σχετίζονται σε αυτές τις δεξιότητες και στην αντίληψη και την συλλογιστική.

Παραδείγματα συστημάτων Τεχνητής Νοημοσύνης είναι π.χ. το ηλεκτρονικό σκάκι ηλεκτρονικά παιχνίδια, διάγνωση ασθενειών με υπολογιστή.

Ερευνητές από άλλες επιστημονικές περιοχές καταφεύγουν στην Τεχνητή Νοημοσύνη για να βρουν εργαλεία και να αυτοματοποιήσουν τα λογικά βήματα που χρησιμοποιούν στη ρουτίνα τους.

Τεχνητή νοημοσύνη

- Barr και Feigenbaum: «Τεχνητή Νοημοσύνη είναι ο τομέας της επιστήμης, που ασχολείται με τη σχεδίαση ευφυών (νοημόνων) υπολογιστικών συστημάτων, δηλαδή συστημάτων που επιδεικνύουν χαρακτηριστικά που σχετίζονται με τη νοημοσύνη στην ανθρώπινη συμπεριφορά»

Δεν είναι ο μοναδικός ορισμός

Ένας από τους εγκυκλοπαιδικούς ορισμούς για την τεχνητή νοημοσύνη ερμηνεύεται ως η ικανότητα της μηχανής να μπορεί να μιμείται την ανθρώπινη συμπεριφορά και την ευφυΐα.


Ευφυΐα

Σημαντικό να το γνωρίζετε

- Ευφυΐα θεωρείται η δυνατότητα του εγκεφάλου να σκέφτεται, να εκλογικεύει, να αντιλαμβάνεται αφηρημένες έννοιες, να λύνει προβλήματα και να μαθαίνει και κυρίως να κατανοεί και να προβλέπει.
- Στον ανθρώπινο εγκέφαλο η ευφυΐα φαίνεται να προκύπτει ως αποτέλεσμα της σύνθετης διασύνδεσης των νευρώνων και ως ένα βαθμό φαίνεται επίσης να συνδέεται και με τη συνείδηση.
- Η ευφυΐα εκτείνει τον κόσμο που αντιλαμβανόμαστε πέραν των αισθήσεών μας και μας κάνει και λειτουργούμε επιτυχώς σε αυτόν.

Από Wikipedia

Δοκιμασία Turing



- Ο Alan Turing, το 1950 εμπνεύστηκε μία δοκιμασία (δοκιμασία Turing → Turing test)
- Βασίζεται σε μία σειρά από ερωτήσεις που υποβάλει ένας άνθρωπος – εξεταστής ταυτόχρονα σε έναν άνθρωπο και σε μία μηχανή, χωρίς να γνωρίζει εκ των προτέρων που απευθύνεται.
- Αν ο εξεταστής δεν καταφέρει να ξεχωρίσει τον άνθρωπο από τη μηχανή, τότε η μηχανή πετυχαίνει τη δοκιμασία και θεωρείται ευφυής.
- Παρότι η αποτελεσματικότητα της δοκιμασίας Turing εξαρτάται από πολλούς παράγοντες, θεωρείται μέχρι σήμερα ένα καλό μέτρο σύγκρισης της Φυσικής (βιολογικής) με την Τεχνητή Νοημοσύνη

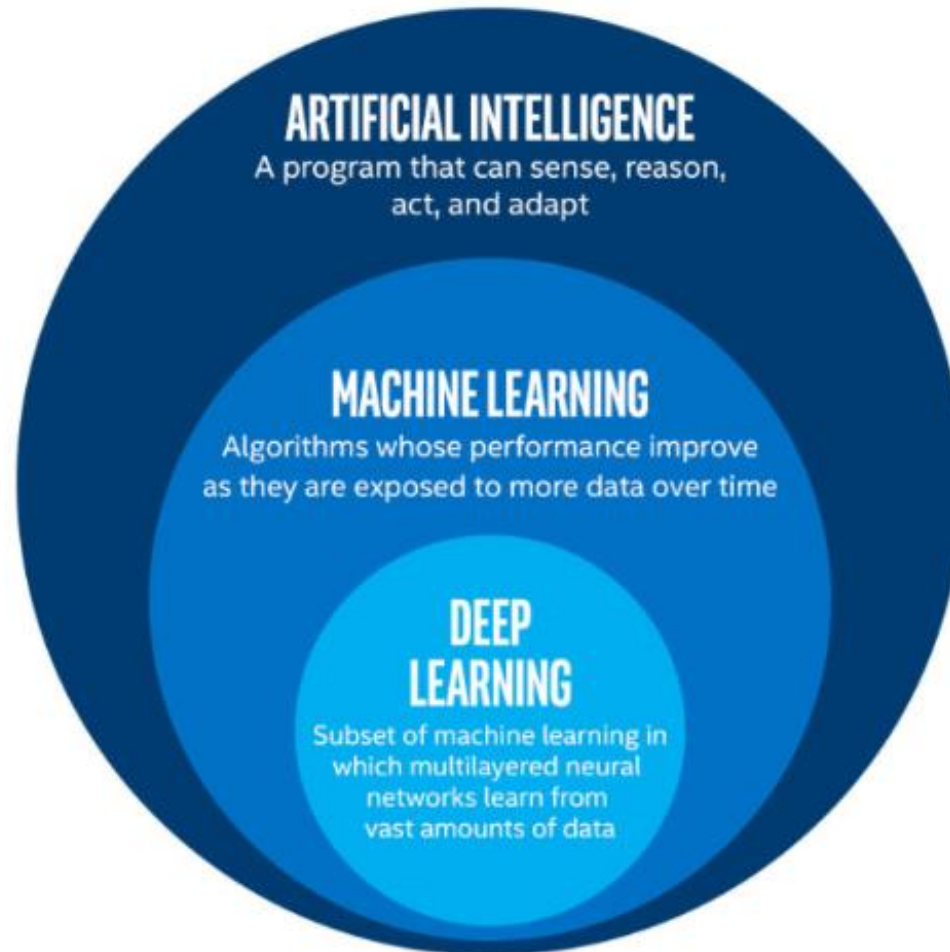
Σημαντικό να το γνωρίζετε

Προσεγγίσεις στην Τεχνητή Νοημοσύνη

Είδος τεχνητής νοημοσύνης	Διεργασίες
Ισχυρή τεχνητή νοημοσύνη (Strong AI, General AI)	Ότι και ο άνθρωπος αθροιστικά
Ασθενής τεχνητή νοημοσύνη (Weak AI, narrow AI)	Περιορισμένο αριθμό διεργασιών που μπορεί να εκτελέσει ο άνθρωπος


Συστήματα που σκέφτονται όπως ο άνθρωπος «Η αυτοματοποίηση λειτουργιών που σχετίζονται με την ανθρώπινη σκέψη, όπως η λήψη αποφάσεων, η επίλυση προβλημάτων, η μάθηση...»	Συστήματα που σκέφτονται ορθολογικά «Η μελέτη νοητικών ικανοτήτων με την χρήση υπολογιστικών μοντέλων»
Συστήματα που δρουν όπως ο άνθρωπος «Η τέχνη της δημιουργίας μηχανών που κάνουν λειτουργίες, οι οποίες, όταν πραγματοποιούνται από ανθρώπους, απαιτούν νοημοσύνη»	Συστήματα που δρουν ορθολογικά «Η μελέτη της σχεδίασης ευφυών πρακτόρων»

Τεχνητή νοημοσύνη → μάθηση μηχανών




Νευρωνικά δίκτυα και.....

Βιολογικοί νευρώνες (γράφημα)




Συνάψεις



..... Τεχνητά νευρωνικά δίκτυα

Τεχνητοί νευρώνες




Οι λειτουργίες που πραγματοποιούνται σε κάθε νευρώνα είναι οι ακόλουθες (με σειρά εκτέλεσης)


1. Ο κάθε νευρώνας πολλαπλασιάζει κάθε είσοδο του με το αντίστοιχο βάρος
2. Τα γινόμενα των εισόδων με τα βάρη προστίθενται (από τον αθροιστή)
3. Το άθροισμα των γινομένων φιλτράρεται (δίδεται σαν είσοδος) από μια μη γραμμική συνάρτηση και το αποτέλεσμα είναι η έξοδος του νευρώνα.

Η γνώση/μνήμη αποθηκεύεται στα βάρη των συνάψεων

Δίκτυο νευρώνων σε έμβριους οργανισμούς




<https://www.bioalternatives.com/en/catalogue/hippocampal-neuron-network-glutamate-intoxicated/>



<https://www.sciencephoto.com/media/796913/view/cortical-neurons-sem>

Δίκτυο Τεχνητών Νευρώνων [ή Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ)]



Τυπική δομή ενός πολυστρωματικού δικτύου με φορά προς τα εμπρός (feed forward).

Έχει
Ένα στρώμα εισόδου
Ένα στρώμα εξόδου και
Ενδιάμεσα ένα κρυφό στρώμα
Όλοι οι νευρώνες ενός στρώματος
συνδέονται με τους νευρώνες του αμέσως
επόμενου στρώματος

Είναι δυνατόν να έχει ένα ή περισσότερα κρυφά στρώματα.

Multilayer feedforward Artificial Neural Network


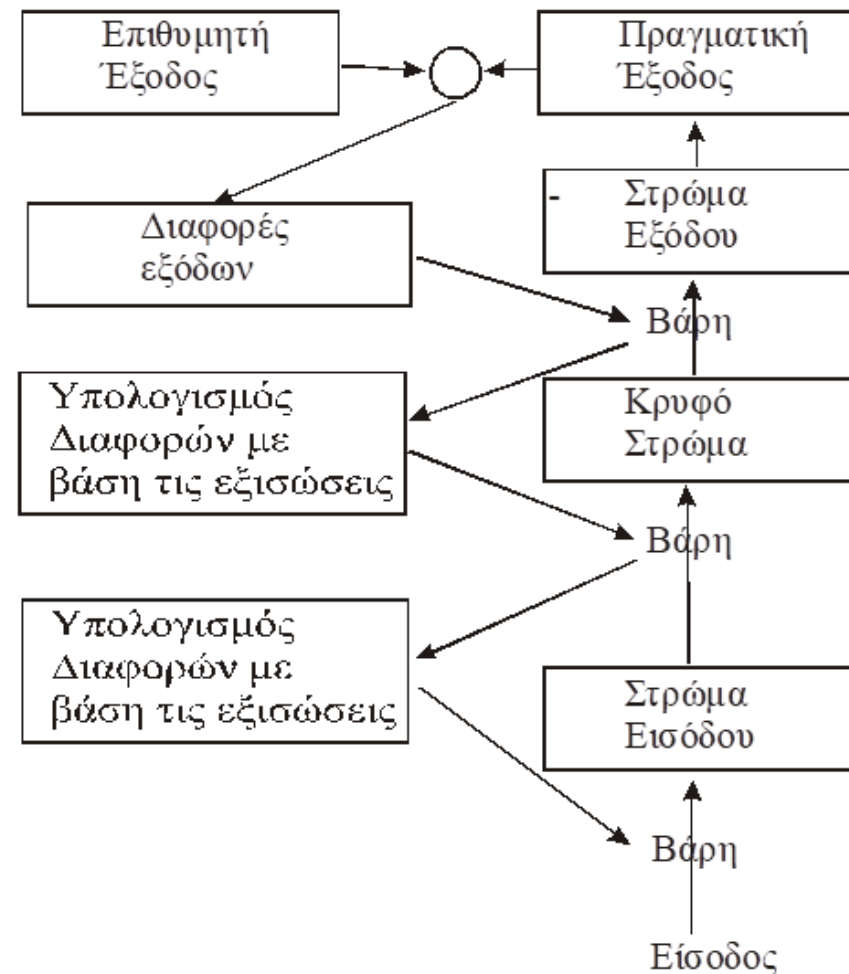
Και πώς μαθαίνει ?!?

Χρησιμοποιείται ένας αλγόριθμος εκπαίδευσης

Π.χ.

Ο αλγόριθμος οπισθοδρομικής διάδοσης του σφάλματος (back propagation of the error)

Πρακτικά αν ή έξοδος του ΤΝΔ είναι κοντά στην πραγματική έξοδο τότε τα βάρη όσων νευρώνων συνεισφέρουν προς αυτή την έξοδο επιβραβεύονται σε διαφορετική περίπτωση «τιμωρούνται»



Επιβλεπόμενα & μη επιβλεπόμενα ΤΝΔ

Επιβλεπόμενα

Κατά τη διαδικασία εκπαίδευσης είναι απαραίτητο να γνωρίζουμε την έξοδο που απαιτούμε από το ΤΝΔ να παράξει

Η πλειοψηφία των διαφορετικών αρχιτεκτονικών ΤΝΔ είναι επιβλεπόμενες

Μη επιβλεπόμενα

Κατά τη διαδικασία εκπαίδευσης δεν γνωρίζουμε την έξοδο

Το ΤΝΔ οργανώνει από μόνο του ομάδες με ομοειδή δεδομένα (εισόδους)



Αλλά μετά το βαθμονομούμε (ορίζουμε κάθε ομάδα σε ποια κατηγορία ανήκει)

Παράδειγμα μη επιβλεπόμενου ΤΝΔ Σε ταξινόμηση κυτταρολογικών αλλοιώσεων

Self Organizing Map (SOM)

SOM με χρωματική
κωδικοποίηση, σύμφωνα με το
αποτέλεσμα της κυτταρολογικής
εξέτασης και με υπόβαθρο (+ ή -)
τη βαθμονόμηση των κόμβων,
σύμφωνα με την ιστολογική
διάγνωση: $\geq\text{CIN2}$ (+), $\leq\text{CIN1}$ (-)

Κυψελοειδής
διάταξη
νευρώνων



Μπλε χρώμα για τα περιστατικά που είναι κυτταρολογικώς
αρνητικά, πράσινο για τις χαμηλόβαθμες αλλοιώσεις
(LGSIL) και κίτρινο, πορτοκαλί για τις υψηλόβαθμες
αλλοιώσεις (ASC-H, HGSIL)

Τι είναι τα Τεχνητά Νευρωνικά Δίκτυα

- Τα ΤΝΔ είναι δίκτυα από απλούς υπολογιστικούς κόμβους (τεχνητούς νευρώνες), διασυνδεδεμένους μεταξύ τους.
- Εμπνευσμένα από το κεντρικό νευρικό σύστημα, το οποίο προσπαθούν να προσομοιώσουν αλλά σε πολύ πιο απλοποιημένη μορφή

Σημαντικό να το γνωρίζετε

Πολυπλοκότητα ΤΝΔ



Neuroscience Scholars Program
Diversity. Community. Careers.

DEADLINE: FEBRUARY 19

APPLY NOW

JNeurosci
THE JOURNAL OF NEUROSCIENCE

An Official Journal of



search

Advanced Search

Submit a Manuscript

HOME CONTENT ALERTS FOR AUTHORS EDITORIAL BOARD ABOUT SUBSCRIBE

Previous

Next

Featured Article | BRIEF COMMUNICATIONS

Isotropic Fractionator: A Simple, Rapid Method for the Quantification of Total Cell and Neuron Numbers in the Brain

Suzana Herculano-Houzel and Roberto Lent

Journal of Neuroscience 9 March 2005, 25 (10) 2518-2521; DOI: <https://doi.org/10.1523/JNEUROSCI.4526-04.2005>

Article Figures & Data Info & Metrics eLetters PDF

Abstract

Stereological techniques that estimate cell numbers must be restricted to well defined structures of isotropic architecture and therefore do not apply to the whole brain or to large neural regions. We developed a novel, fast, and inexpensive method to quantify total numbers of neuronal and non-neuronal cells in the brain or any dissectable regions thereof. It consists of transforming highly anisotropic brain structures into homogeneous, isotropic suspensions of cell nuclei, which can be counted and identified immunocytochemically as neuronal or non-neuronal. Estimates of total cell

In this issue




Journal of Neuroscience
Vol. 25, Issue 10
9 Mar 2005
[Table of Contents](#)
[About the Cover](#)
[Index by author](#)

Intel packs 8 million digital neurons onto its brain-like computer

Using 64 Loihi processors, the company takes a notable step toward a digital brain.



Stephen Shankland July 15, 2019 6:30 AM PDT



Intel fits 16 neuromorphic Loihi chips on its Nahuku board. It uses 64 of the research chips to make its 8-million neuron Pohoiki Beach computer.

Intel

<https://www.jneurosci.org/content/25/10/2518>

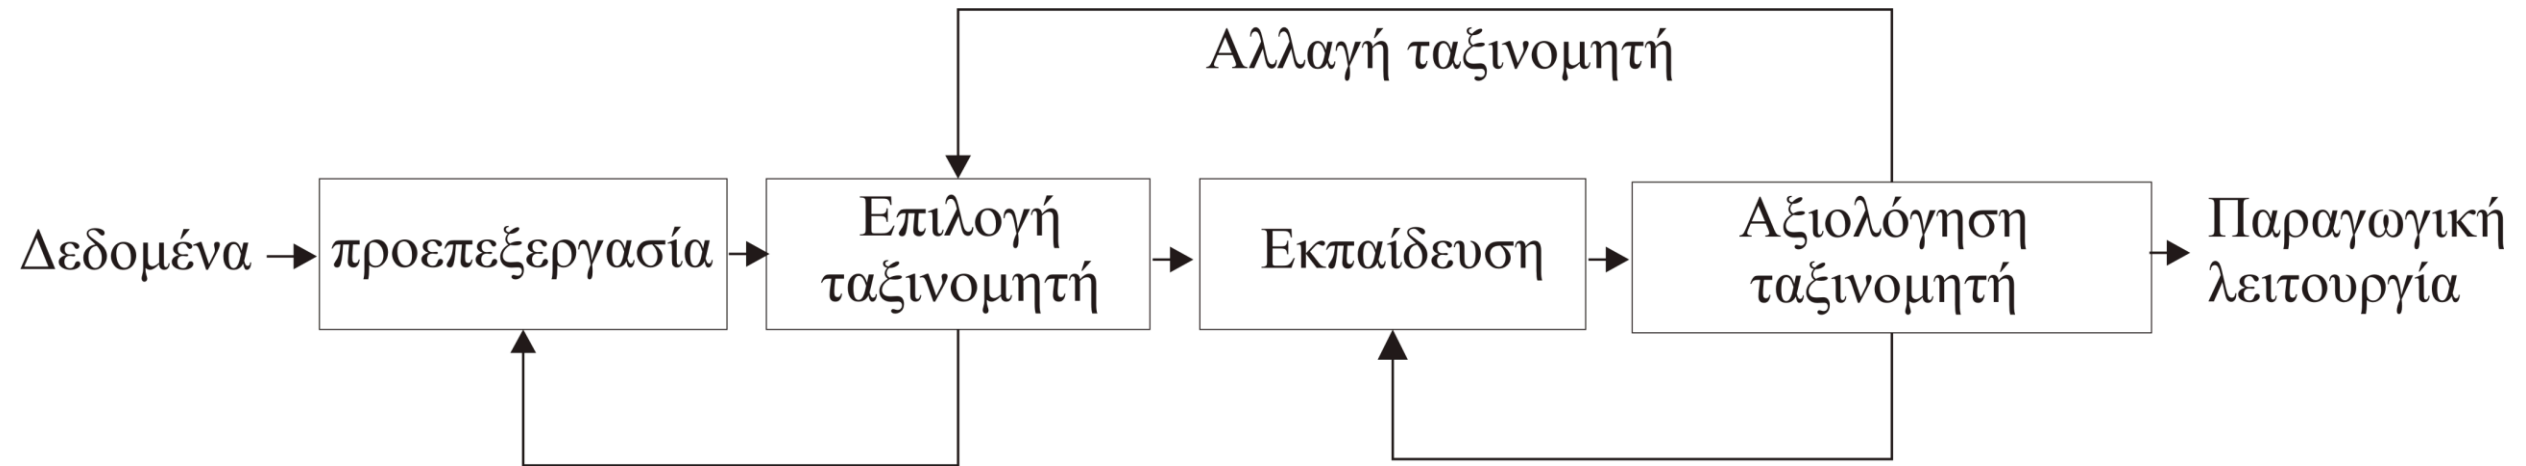
Αριστοτέλης (335 π.Χ.): «Από όλα τα ζώα ο άνθρωπος έχει τον μεγαλύτερο εγκέφαλο σε αναλογία με το μέγεθός του»

	Υπερυπολογιστής	Προσωπικός Υπολογιστής	Ανθρώπινος Εγκέφαλος
Υπολογιστικές Μονάδες	10 ⁴ CPUs 10 ¹² τρανζίστορ	4 CPUs 10 ⁹ τρανζίστορ	10 ¹¹ νευρώνες
Μονάδες μνήμης	10 ¹⁴ bits RAM 10 ¹⁵ bits δίσκος	10 ¹¹ bits RAM 10 ¹³ bits δίσκος	10 ¹¹ νευρώνες 10 ¹⁴ συνάψεις
Κύκλος ρολογιού	10 ⁻⁹ secs	10 ⁻⁹ secs	10 ⁻³ secs
Εντολές/sec	10 ¹⁵	10 ¹⁰	10 ¹⁷

“It is odds on that a machine - or organ - with sluggishly functioning components and a parallel mode of operation would be able to thrash a computer with high speed components but a sequential mode of operation”

J. Copeland, *Artificial Intelligence*. Oxford: Blackwell Publishers, 1993.

Η ροή (βήματα) για τη δημιουργία ενός συστήματος με κάποια ικανότητα νοημοσύνης (ταξινομητής)



Προ-επεξεργασία

Αφαίρεση των δεδομένων που δεν είναι ολοκληρωμένα

Τυποποίηση δεδομένων

Κανονικοποίηση τους ώστε όλα τα χαρακτηριστικά να θεωρούνται πως είναι ισοδύναμα κατά την ταξινόμηση

**Χωρισμός στο σύνολο εκπαίδευσης και ελέγχου
(ενδεχομένως και σε τρία μέρη)**

Επιλογή κατάλληλου ταξινομητή (ΤΝΔ)

Είναι συνάρτηση του προβλήματος που απαιτείται να επιλυθεί

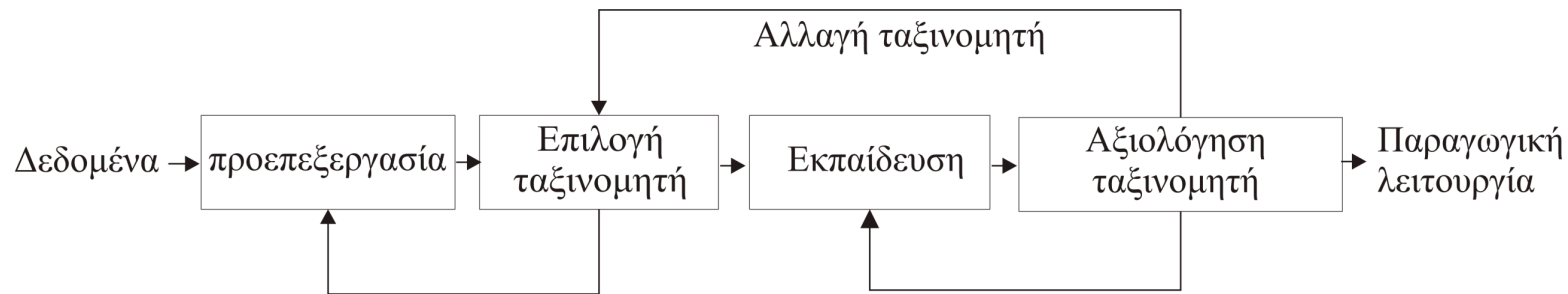
π.χ. ΤΝΔ του τύπου οπισθοδρομικής διάδοσης του σφάλματος είναι ιδανικά για την προσέγγιση συνεχών συναρτήσεων

δίκτυα του τύπου LVQ (Learning Vector Quantization) είναι προτιμότερα για την επίλυση προβλημάτων clustering/ομαδοποίησης

Είναι δυνατόν να απαιτηθεί και νέα προ-επεξεργασία κυρίως στο στάδιο την κανονικοποίησης, π.χ. σε στα νευρωνικά δίκτυα οπισθοδρομικής διάδοσης του σφάλματος η μέγιστη και ελάχιστη τιμή των δεδομένων εξαρτάται από την επιλεγμένη σιγμοειδή συνάρτηση.

Εκπαίδευση και Αξιολόγηση

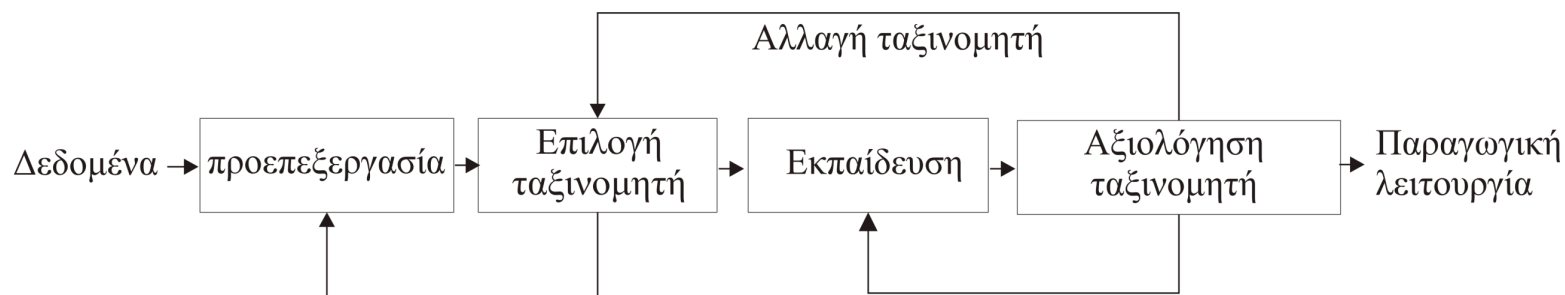
Το επόμενο βήμα είναι η εκπαίδευση με τη βοήθεια του συνόλου εκπαίδευσης και στη συνέχεια η αξιολόγηση με τη βοήθεια του συνόλου δοκιμών.



Δυναμική διαδικασία

Σε περίπτωση που δεν επιτυγχάνονται ικανοποιητικά αποτελέσματα είναι δυνατόν να επαναληφθεί η προπαρασκευή με ταυτόχρονη αλλαγή των παραμέτρων του ΤΝΔ ή ακόμα και με αλλαγή του μοντέλου ΤΝΔ.

Μετά από τις απαραίτητες επαναλήψεις μέχρι να επιτευχθούν ικανοποιητικά αποτελέσματα και το τελικό συντονισμό του ΤΝΔ, το ευφυές σύστημα λήψης απόφασης έχει πλέον εκπαιδευτεί και μπορεί να χρησιμοποιηθεί σε μια παραγωγική λειτουργία



Δείκτες απόδοσης

Δείκτης Απόδοσης	Εξίσωση	Περιγραφή
Αληθώς Θετικό (TP)	Καμία, είναι ο αριθμός των περιστατικών	Το περιστατικό θεωρείται ως TP εάν αναγνωρίζεται ως Θετικό από την εφαρμοζόμενη μέθοδο και είναι πράγματι Θετικό
Αληθώς Αρνητικό (TN)	Καμία, είναι ο αριθμός των περιστατικών	Το περιστατικό θεωρείται ως TN εάν αναγνωρίζεται ως Αρνητικό από την εφαρμοζόμενη μέθοδο και είναι πράγματι Αρνητικό
Ψευδώς Θετικό (FP)	Καμία, είναι ο αριθμός των περιστατικών	Το περιστατικό θεωρείται ως FP εάν αναγνωρίζεται ως Θετικό από την εφαρμοζόμενη μέθοδο και είναι πράγματι Αρνητικό
Ψευδώς Αρνητικό (FN)	Καμία, είναι ο αριθμός των περιστατικών	Το περιστατικό θεωρείται ως FN εάν αναγνωρίζεται ως Αρνητικό από την εφαρμοζόμενη μέθοδο και είναι πράγματι Θετικό
Ευαισθησία ή Ποσοστό Αληθώς Θετικών (TPR)	Ευαισθησία = $TP/P = TP/(TP+FN)$	Μετράει το ποσοστό των Θετικών που είναι σωστά αναγνωρισμένα ως Θετικά
Ειδικότητα ή Ποσοστό Αληθώς Αρνητικών (TNR)	Ειδικότητα = $TN/N = TN/(TN+FP)$	Μετράει το ποσοστό των Αρνητικών που είναι σωστά αναγνωρισμένα ως Αρνητικά
Θετική Προγνωστική Αξία (PPV)	$PPV = TP/(TP+FP)$	Το ποσοστό των Θετικών Αποτελεσμάτων που είναι πράγματι Θετικά
Αρνητική Προγνωστική Αξία (NPV)	$NPV = TN/(TN+FN)$	Το ποσοστό των Αρνητικών Αποτελεσμάτων που είναι πράγματι Αρνητικά
Ψευδώς Θετικό Ποσοστό (FPR) ή fall-out ή Ποσοστό false alarm	$FPR = FP/N = FP/(TN+FP) = 1 - \text{Ειδικότητα} = 1 - TNR$	Η αναλογία μεταξύ του αριθμού των αρνητικών ευρημάτων που έχουν λανθασμένα κατηγοριοποιηθεί ως Θετικά (Ψευδώς Θετικά) και του ολικού αριθμού των πραγματικών Αρνητικών ευρημάτων. Η πιθανότητα της λανθασμένης εκτίμησης μιας περίπτωσης ως Θετική. Είναι το αποτέλεσμα που δείχνει ότι μια δεδομένη κατάσταση υπάρχει, ενώ στην πραγματικότητα δεν υπάρχει.
Ψευδώς Αρνητικό Ποσοστό (FNR)	$FNR = FN/P = FN/(TP+FN) = 1 - \text{Ευαισθησία} = 1 - TPR$	Η αναλογία μεταξύ του αριθμού των Θετικών ευρημάτων που έχουν λανθασμένα κατηγοριοποιηθεί ως Αρνητικά (Ψευδώς Αρνητικά) και του ολικού αριθμού των πραγματικών Θετικών ευρημάτων. Η πιθανότητα της λανθασμένης εκτίμησης μιας περίπτωσης ως Αρνητική.
Συνολική Ακρίβεια ή Ακρίβεια (OA)	$OA = (TP+TN)/(TP+TN+FP+FN) = (TP+TN)/(P+N)$	Μέτρηση που υποδηλώνει το ποσοστό επιτυχίας μιας μεθόδου.



Μειονεκτήματα των ΤΝΔ

- Υπερεκπαίδευση: Το σύστημα δεν γενικεύει, δηλαδή ενώ υπάρχει υψηλή επίδοση στο σύνολο εκπαίδευσης υπάρχει φτωχή απόδοση στο σύνολο δοκιμών
- Απαιτείται μεγάλος αριθμός δεδομένων
- Δεν υπάρχει αιτιολόγηση του μηχανισμού απόφασης

Σημαντικό να το γνωρίζετε

Νέες τεχνικές → Βαθιά μάθηση (deep learning)

- Μια νέα κατηγορία αλγορίθμων εκπαίδευσης (αλλά και δομών ΤΝΔ) στα οποία χρησιμοποιούνται πολλαπλά στρώματα (άρα βαθιές δομές → deep).
- Κάθε στρώμα χρησιμοποιείται για τη σταδιακή αναγνώριση από απλοποιημένες δομές σε σταδιακά πιο λεπτομερείς δομές π.χ. ακμές σε εικόνες μέχρι σταδιακά αντικείμενα ή άλλες δομές όπως γράμματα και πρόσωπα.



Χρήσεις βαθιάς μάθησης

Εφαρμογές σε **όραση υπολογιστή** (computer vision), αναγνώριση λόγου (speech recognition), επεξεργασία δεδομένων από κοινωνικά δίκτυα (social networks), μεταφράσεις (machine translation), διάφορα πεδία βιοπληροφορικής (bioinformatics), σχεδιασμός φαρμάκων, **ανάλυση ιατρικών εικόνων**. Και γενικά σε εφαρμογές που απαιτείται υψηλή εξειδίκευση αλλά και απλές διαδικασίες.

Εφαρμογές

ΤΝΔ στην παθολογική ανατομική/ανάλυση εικόνας

THE LANCET

Artificial neural networks in pathology and medical laboratories

Richard Dybowski, Vanya Gant

Clinical pathology laboratories are busier than ever.¹ Small pathology laboratories are merging with larger ones, which concentrates more work of the same repetitive nature in one place. As in the car industry, laboratory managers have turned to machines for these repetitive tasks because it is easier to recover the initially high capital cost of automation with high turnover. Machines now handle many types of clinical sample and are almost invariably linked to inexpensive high-performance microcomputers; these in turn have so enhanced the housekeeping aspects of a modern clinical pathology laboratory that "laboratory life before the computer" is almost impossible to comprehend.

This integration of the computer within pathology laboratories, as record keeper, process controller, data tracker, and number cruncher, owes its success to the fact that computers excel in doing the same job very quickly without error, often unsupervised, 24 hours a day. It is easy to see how this leads to decreased sample turnaround time, a commodity increasingly demanded by managers and valued by clinicians. These roles for computers are perfectly tailored to the repetitive actions of the computer microprocessor chip; but they are really doing nothing more than acting as very fast electric filing cabinets. This article describes how artificial neural networks can extend the capabilities of computers within clinical pathology.

Classifying data: when is more than speed needed?

Programming a computer management is straight "dumb" rote for computer pathologists and laboratory relevant to clinical path to specify as a computer decision making. To would be advantageous sample throughput but in pathology, decisions the ability to classify malignant?" "Is the isolated site relevant?" "I

Many strategies have been developed to enable computers to classify data, the three principal ones being statistics, machine-learning techniques (such as decision trees),² and artificial neural networks.

Some samples that reach the pathology laboratory yield crisp data ("The serum sodium is . . ." or "There is a meningococcus in this blood culture . . ."); in other words, single numerical values or descriptors. Such data can be interpreted as being within a statistically defined normal range or not, and can be flagged as such by the simplest of hand-held computers. Other data are more complex, both in the relations between the features and

Chemical pathology	Microbiology	Histopathology
Numbers (physical measurements) eg. "Serum Na" = . . .	Numbers; descriptors (colony counts; identification of microorganisms) eg. ">10 ⁶ E coli per mL"	Complex figures; imprecise linguistic statements eg. "The section shows . . ."


Figure 1: Spectrum of pathology data as seen by clinicians

their interpretation (ie, assigned class). One example would be the technical identification steps required for, and the interpretation of, a mixed growth of coliforms and enterococci in an ileal conduit urine. Even more complex examples can be found in histopathology and cytology, where data are almost invariably figurative with complex correlations between the features, and where reports are almost always in words (figure 1). Here samples are even more difficult for machines to classify because analysis is intimately linked to interpretation, and


subject to individual difficult to train a machine es on a cervical cytology fy such features into, for to "moderate" dysplastic defined quite differently only is there no absolute a cell or of a cytological ent of normality but also it unds of such "normality" nages are so complex that requires a highly adaptive

thematical function which (eg, clinical features) to an likelihood of streptococcal o a data set is modified by rtificial neural network is a sion model, the flexibility ural connections within the advantage of flexibility when he used a network to classify peripheral blood

Lancet 1995; 346: 120
See Commentary page
Infection and Immunity Lab
UMDS (St Thomas' Campus)
London SE1 7EH, UK (R Dy
Correspondence to: Dr Vanya Gant



Συστήματα ψηφιοποίησης εικόνων



Διαδικασία ψηφιοποίησης και μετρήσεων σε εικόνες



Ήδη από την περίοδο που τα ΤΝΔ ήταν ένα σημαντικό πεδίο έρευνας

Εφαρμογή



Translational AI and Deep Learning in Diagnostic Pathology

Ahmed Serag, Adrian Ion-Margineanu, Hammad Qureshi, Ryan McMillan, Marie-Judith Saint Martin, Jim Diamond, Paul O'Reilly[†] and Peter Hamilton^{*†}

Life Sciences R&D Hub, Digital and Computational Pathology, Philips, Belfast, United Kingdom

There has been an exponential growth in the application of AI in health and in pathology. This is resulting in the innovation of deep learning technologies that are specifically aimed at cellular imaging and practical applications that could transform diagnostic pathology. This paper reviews the different approaches to deep learning in pathology, the public grand challenges that have driven this innovation and a range of emerging applications in pathology. The translation of AI into clinical practice will require applications to be embedded seamlessly within digital pathology workflows, driving an integrated approach to diagnostics and providing pathologists with new tools that accelerate workflow and improve diagnostic consistency and reduce errors. The clearance of digital pathology for primary diagnosis in the US by some manufacturers provides the platform on which to deliver practical AI. AI and computational pathology will continue to mature as researchers, clinicians, industry, regulatory organizations and patient advocacy groups work together to innovate and deliver new technologies to health care providers: technologies which are better, faster, cheaper, more precise, and safe.

Keywords: pathology, digital pathology, artificial intelligence, computational pathology, image analysis, neural network, deep learning, machine learning

OPEN ACCESS

Edited by:

April Khademi,
Ryerson University, Canada

Reviewed by:

Fernando Schmitt,
University of Porto, Portugal
Salvatore Lorenzo Rienne,
Humanitas Research Hospital, Italy

*Correspondence:

Peter Hamilton


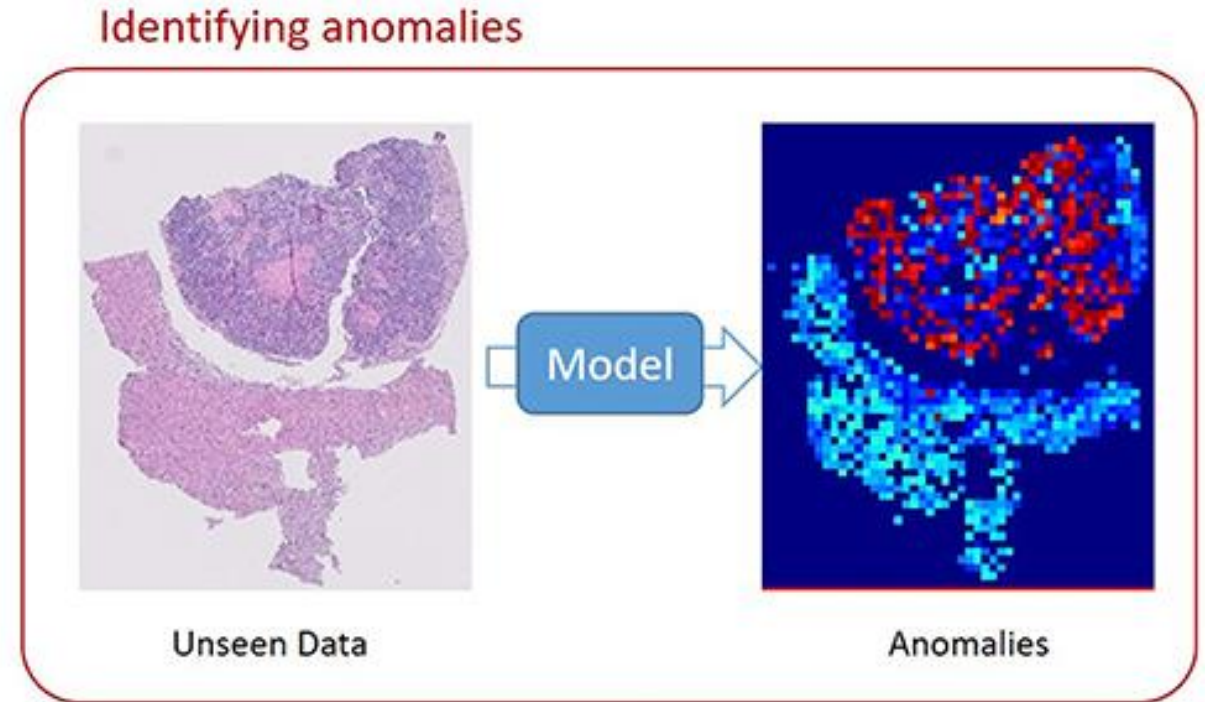
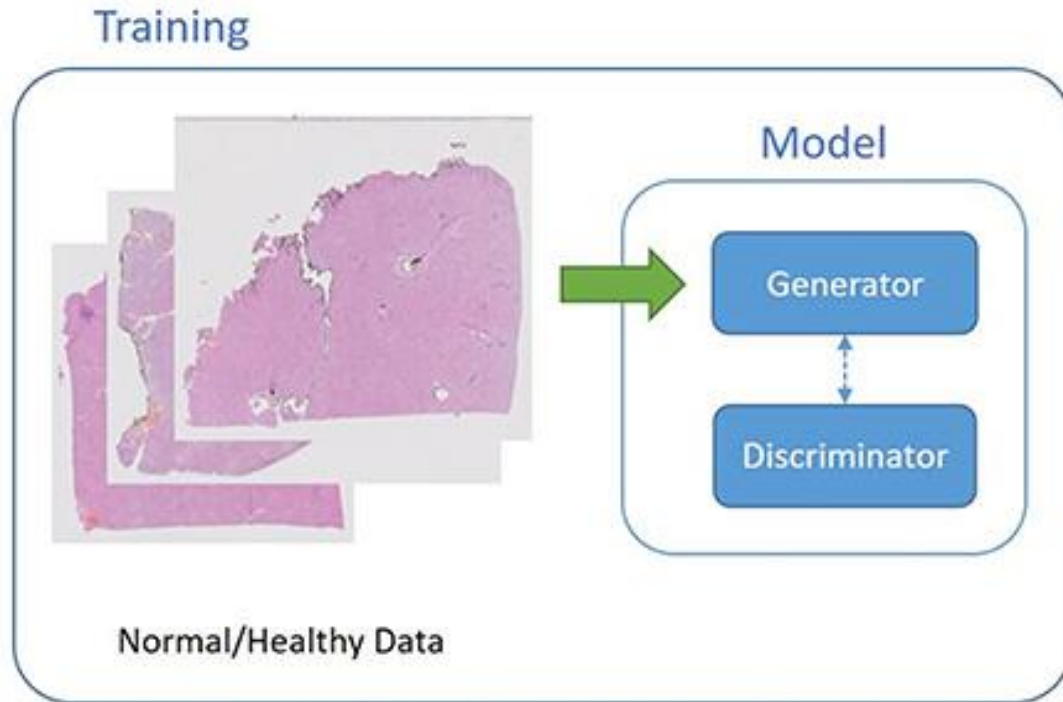


FIGURE 4 | PD-L1 imaging in lung cancer. Deep learning can be used to identify and distinguish positive | negative tumor cells and positive | negative inflammatory cells.

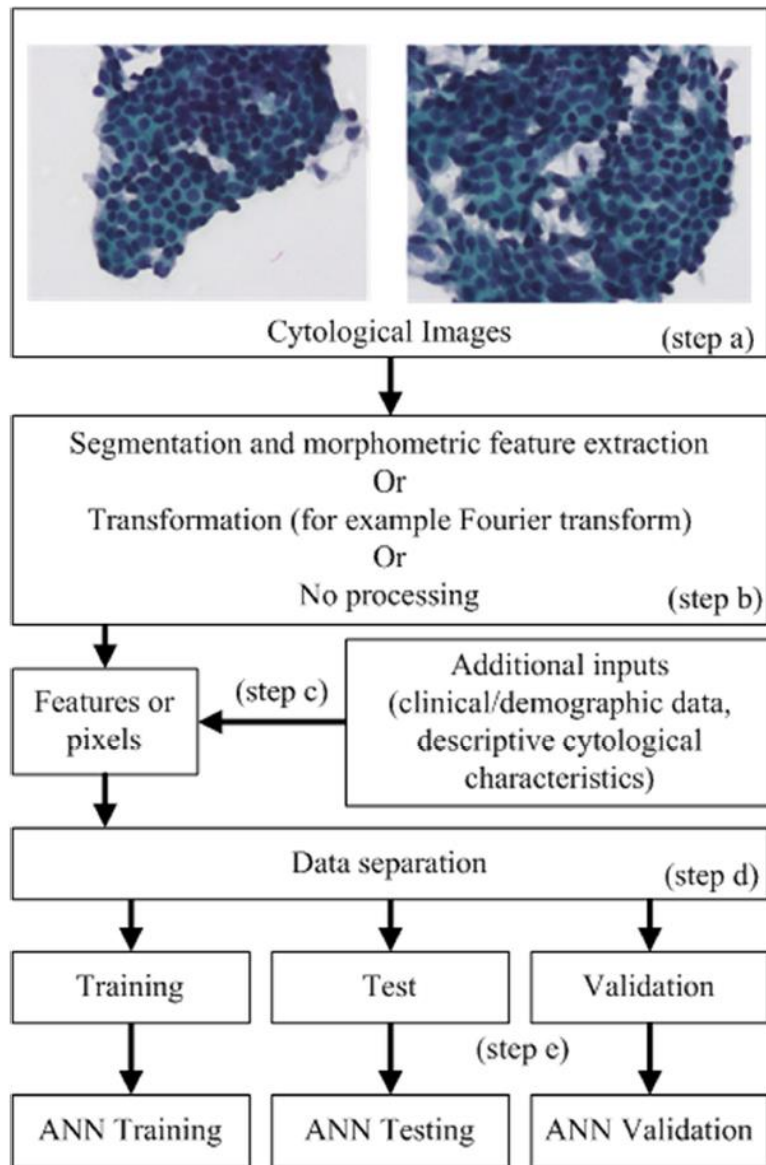
Μη επιβλεπόμενο ΤΝΔ σε εντοπισμό «ασυνήθιστων» δομών



Translational AI and Deep Learning in Diagnostic Pathology

Ahmed Serag, Adrian Ion-Margineanu, Hammad Qureshi, Ryan McMillan, Marie-Judith Saint Martin, Jim Diamond, Paul O'Reilly¹ and Peter Hamilton^{2}*

Παράδειγμα στη διάγνωση από το μικροσκόπιο



Artificial Neural Networks as Decision Support Tools in Cytopathology: Past, Present, and Future



Abraham Poulidakis¹, Efrossyni Karakitsou², Niki Margari¹, Panagiotis Bountris³, Maria Haritou⁴, John Panayiotides², Dimitrios Koutsouris³ and Petros Karakitsos¹

¹Department of Cytopathology, National and Kapodistrian University of Athens, Medical School, Attikon University Hospital, Athens, Greece. ²2nd Department of Pathology, National and Kapodistrian University of Athens, Medical School, Attikon University Hospital, Athens, Greece. ³Biomedical Engineering Laboratory, National Technical University of Athens, Athens, Greece. ⁴Institute of Communication and Computer Systems, Athens, Greece.

ABSTRACT

OBJECTIVE: This study aims to analyze the role of artificial neural networks (ANNs) in cytopathology. More specifically, it aims to highlight the importance of employing ANNs in existing and future applications and in identifying unexplored or poorly explored research topics.

STUDY DESIGN: A systematic search was conducted in scientific databases for articles related to cytopathology and ANNs with respect to anatomical places of the human body where cytopathology is performed. For each anatomic system/organ, the major outcomes described in the scientific literature are presented and the most important aspects are highlighted.

RESULTS: The vast majority of ANN applications are related to cervical cytopathology, specifically for the ANN-based, semi-automated commercial diagnostic system PAPNET. For cervical cytopathology, there is a plethora of studies relevant to the diagnostic accuracy; in addition, there are also efforts evaluating cost-effectiveness and applications on primary, secondary, or hybrid screening. For the rest of the anatomical sites, such as the gastrointestinal system, thyroid gland, urinary tract, and breast, there are significantly less efforts relevant to the application of ANNs. Additionally, there are still anatomical systems for which ANNs have never been applied on their cytological material.

CONCLUSIONS: Cytopathology is an ideal discipline to apply ANNs. In general, diagnosis is performed by experts via the light microscope. However, this approach introduces subjectivity, because this is not a universal and objective measurement process. This has resulted in the existence of a gray zone between normal and pathological cases. From the analysis of related articles, it is obvious that there is a need to perform more thorough analyses, using extensive number of cases and particularly for the nonexplored organs. Efforts to apply such systems within the laboratory test environment are required for their future uptake.

KEYWORDS: artificial neural networks, neural networks, artificial intelligence, cytopathology, cytology, review, automation, computer-assisted diagnosis, decision support

CITATION: Poulidakis et al. Artificial Neural Networks as Decision Support Tools in Cytopathology: Past, Present, and Future. *Biomedical Engineering and Computational Biology* 2016;7:1-18 doi:xxx.

TYPE: Review

RECEIVED: November 4, 2015. **RE-SUBMITTED:** January 17, 2016. **ACCEPTED FOR PUBLICATION:** January 19, 2016.

ACADEMIC EDITOR: Kayvan Najarian, Editor in Chief

PEER REVIEW: Six peer reviewers contributed to the peer review report. Reviewers' reports totaled 1612 words, excluding any confidential comments to the academic editor.

FUNDING: Author should state fund sources here. Funding information will appear with this statement. The authors confirm that the funder had no influence over the study design, content of the article, or selection of this journal. If no funding sources exist, this text will be shown. (Author(s) disclose no external funding sources.)

COMPETING INTERESTS: Authors disclose no potential conflicts of interest.

COPYRIGHT: © the authors, publisher and licensee Libertas Academica Limited. This is an open-access article distributed under the terms of the Creative Commons CC-BY-NC 3.0 License.

CORRESPONDENCE: apoulia@med.uoa.gr; apou1967@gmail.com

Paper subject to independent expert single-blind peer review. All editorial decisions made by independent academic editor. Upon submission manuscript was subject to anti-plagiarism scanning. Prior to publication all authors have given signed confirmation of agreement to article publication and compliance with all applicable ethical and legal requirements, including the accuracy of author and contributor information, disclosure of competing interests and funding sources, compliance with ethical requirements relating to human and animal study participants, and compliance with any copyright requirements of third parties. This journal is a member of the Committee on Publication Ethics (COPE). Provenance: the authors were invited to submit this paper.

Published by Libertas Academica. Learn more about this journal.

Introduction

Computer science and artificial intelligence have enabled the development of computer-aided systems to support clinical diagnosis or therapeutic and treatment decisions. Many machine learning methodologies such as neural networks,¹⁻⁷ discriminant analysis,^{1,8,9} classification and regression trees,^{10,11} genetic algorithms,¹² and recently, deep learning¹³⁻¹⁵ have been successfully used in medicine, whereas other techniques are in the center of current research studies.

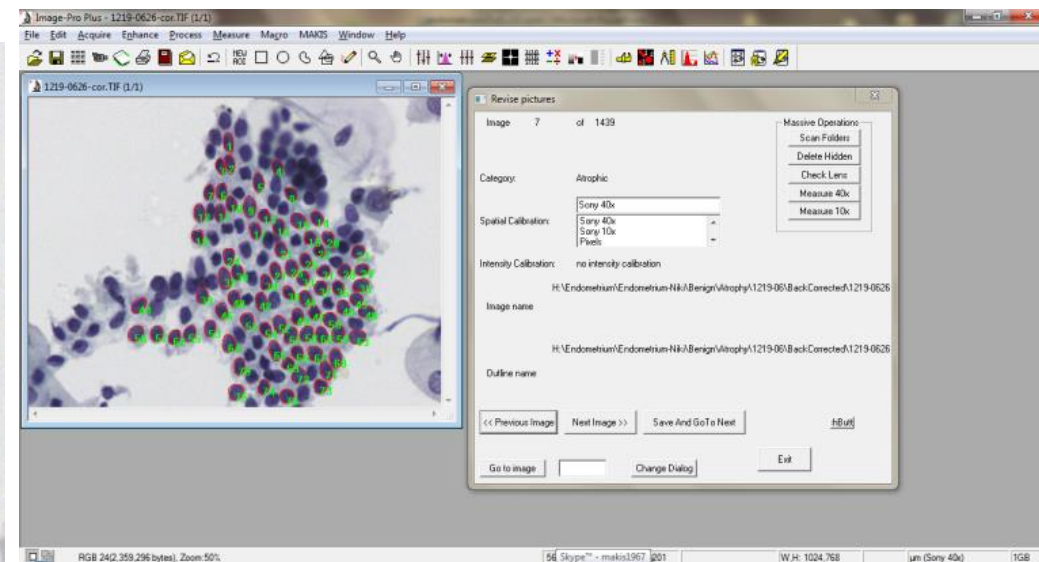

Cytopathology is a relatively new medical discipline, which in most countries is considered to be a branch of pathology. In cytopathology, diseases are studied and diagnosed at a cellular level (free cells or small tissue fragments traditionally examined via the microscope). This discipline was founded by Papanicolaou in 1928¹⁶ and became popular

when he proposed the worldwide known Pap test. This test is used as a screening tool for detecting precancerous cervical lesions and thus preventing cervical cancer (CxCa).^{17,18} However, CxCa is not the sole disease that cytopathology deals with. Even in its early days,¹⁹⁻²¹ cytopathology was commonly used to investigate thyroid lesions, fluids in body cavities (peritoneal, pleural, pericardial, and cerebrospinal), and in almost the total range of body sites. In addition, cell study is not only used for cancer diagnosis, but it can also be employed for the diagnosis of infectious diseases and inflammatory conditions (eg, viruses, fungi, and bacteria). One of the major advantages of cytopathology practice is its noninvasive or minimally invasive nature, ie, the biological material is extracted from the patients in a painless manner (eg, cells are extracted using a brush,

Μετρήσεις σε ψηφιακές εικόνες

Cases number			
Training set	NO	YES	Grand Total
Adeno Ca	1	1	2
Atrophy	13	13	26
Endometrioid Ca	24	24	48
Endometrioid Ca-grade I	4	4	8
Hyperplasia with atypia	3	4	7
Hyperplasia without atypia	19	18	37
Proliferative phase	28	28	56
Secretory phase	17	18	35
Serous Ca	2	2	4
Grand Total	111	112	223
Nuclei number			
Adeno Ca	90	78	168
Atrophy	1269	1285	2554
Endometrioid Ca	2482	2527	5009
Endometrioid Ca-grade I	384	394	778
Hyperplasia with atypia	333	380	713
Hyperplasia without atypia	1994	1800	3794
Proliferative phase	2849	2945	5794
Secretory phase	1707	1953	3660
Serous Ca	188	179	367
Grand Total	11296	11541	22837


Ασθενείς → εικόνες



Ανάλυση εικόνων

Geometric	Densitometric/textural
Nucleus area	Integrated optical density
Nucleus major axis	Mean value of nucleus red color
Nucleus minor axis	Mean value of nucleus green color
Aspect ration	Mean value of nucleus blue color
Maximum caliper	Mean value of optical density
Minimum caliper	Maximum value of optical density
Average value of caliper	Minimum value of optical density
Maximum nucleus radius	Standard deviation of optical density
Minimum nucleus radius	Margination
Radius ratio	Heterogeneity
Nucleus perimeter	
Nucleus roundness	
Fractal dimension	

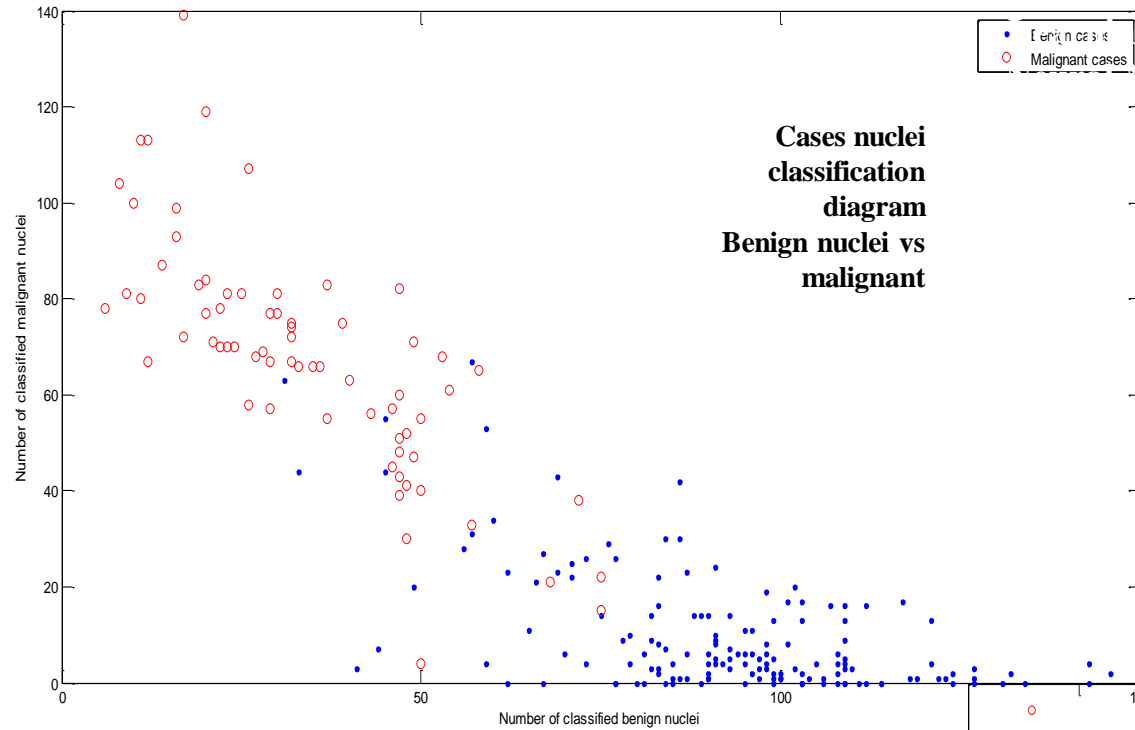
μετρήσεις



ΤΝΔ

Ταξινόμηση μεμονωμένου
πυρήνα ως
καλοήθη ή κακοήθη

Αποτελέσματα



Case classification results by LVQ NN

		Assigned class		
		Benign	Malignant	
True class	Benign	72	5	Training set
	Malignant	2	32	
True class	Benign	74	3	Test set
	Malignant	3	32	

Overall accuracy: 94.17%

No significant difference between training and test set

Performance


Nuclei

Sensitivity=	66.48%
Specificity=	90.43%
PPV=	75.57%
NPV=	85.84%
FPR=	9.57%
FNR=	33.52%
OA=	83.05%

Cases

Threshold 35%

Sensitivity=	92.75%
Specificity=	94.16%
PPV=	87.67%
NPV=	96.67%
FPR=	5.84%
FNR=	7.25%
OA=	93.72%



Πρόγνωση επιδημιολογικών στοιχείων


Έξοδος από το ΤΝΔ

Variable	Source	Description	Number of Observations
Occurrences	KCDC	Daily number of confirmed infectious disease diagnoses	576
Naver	Naver Data Lab	Daily Naver search frequency	
Twitter	Twitter	Daily number of Twitter mentions	
Temperature	KMA	Average daily temperature for all of South Korea	
Humidity		Average daily humidity for all of South Korea	

Είσοδοι στο ΤΝΔ

Article


Predicting Infectious Disease Using Deep Learning and Big Data

Sangwon Chae, Sungjun Kwon and Donghyun Lee * 

Department of Business Administration, Korea Polytechnic University, 237 Sangdaehak-ro, Siheung-si, Gyeonggi-do 15073, Korea; chaesw1993@kpu.ac.kr (S.C.); solomonseal@kpu.ac.kr (S.K.)

* Correspondence: madeby2@gmail.com; Tel.: +82-031-8041-0761

Received: 22 June 2018; Accepted: 24 July 2018; Published: 27 July 2018



Abstract: Infectious disease occurs when a person is infected by a pathogen from another person or an animal. It is a problem that causes harm at both individual and macro scales. The Korea Center for Disease Control (KCDC) operates a surveillance system to minimize infectious disease contagions. However, in this system, it is difficult to immediately act against infectious disease because of missing and delayed reports. Moreover, infectious disease trends are not known, which means prediction is not easy. This study predicts infectious diseases by optimizing the parameters of deep learning algorithms while considering big data including social media data. The performance of the deep neural network (DNN) and long-short term memory (LSTM) learning models were compared with the autoregressive integrated moving average (ARIMA) when predicting three infectious diseases one week into the future. The results show that the DNN and LSTM models perform better than ARIMA. When predicting chickenpox, the top-10 DNN and LSTM models improved average performance by 24% and 19%, respectively. The DNN model performed stably and the LSTM model was more accurate when infectious disease was spreading. We believe that this study's models can help eliminate reporting delays in existing surveillance systems and, therefore, minimize costs to society.

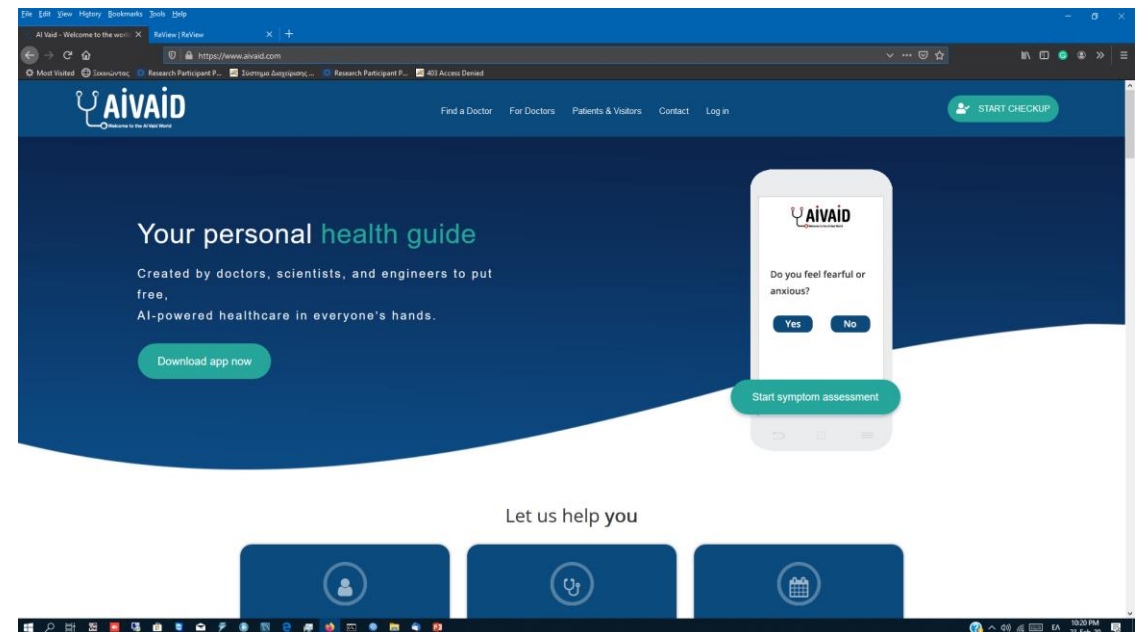
Keywords: infectious disease prediction; deep neural network; long short-term memory; deep learning; social media big data

Υποβοήθηση διάγνωσης

- Λογισμικό διάγνωσης ασθενειών που βασίζεται σε πιθανοτική ανάλυση έχει πλέον αποκτήσει τις ικανότητες έμπειρων θεραπευτών σε πολλές ειδικότητες.
- Κάποια από αυτά διατίθενται ελεύθερα στο διαδίκτυο, π.χ. <http://easydiagnosis.com/> <https://www.aivaid.com/>
- Διαθέσιμα και σε ασθενείς

Symptomate gives you an accurate evaluation of your health

- 1 Enter symptoms
- 2 Answer a few questions
- 3 Done! You will receive information about:
 - ✓ possible causes of your symptoms
 - ✓ options for what to do next
 - ✓ suggested lab tests



Άλλες εφαρμογές στη λοιμωξιολογία

RESEARCH ARTICLE

The effect of climate change on cholera disease: The road ahead using artificial neural network

Zahra Asadgol¹, Hamed Mohammadi^{2†*}, Majid Kermani^{1,3}, Alireza Badirzadeh⁴, Mitra Gholami^{1,3†*}

1 Department of Environmental Health Engineering, School of Public Health, Iran University of Medical Sciences, Tehran, Iran, **2** Department of Environmental Health Engineering, School of Public Health, Zanzan University of Medical Sciences, Zanzan, Iran, **3** Research Center for Environmental Health Technology, Iran University of Medical Sciences, Tehran, Iran, **4** Department of Parasitology and Mycology, School of Medicine, Iran University of Medical Sciences, Tehran, Iran

† MG and HM are joint corresponding authors on this work.
* gholamim@iums.ac.ir (MG); ham19@iums.ac.ir (HM)



OPEN ACCESS

Citation: Asadgol Z, Mohammadi H, Kermani M, Badirzadeh A, Gholami M (2019) The effect of climate change on cholera disease: The road ahead using artificial neural network. PLOS ONE 14(11): e0224813. <https://doi.org/10.1371/journal.pone.0224813>

Editor: A. P. Dimri, Jawaharlal Nehru University, INDIA

Received: July 4, 2019

Accepted: October 22, 2019

Published: November 6, 2019

Copyright: © 2019 Asadgol et al. This is an open access article distributed under the terms of the [Creative Commons Attribution License](https://creativecommons.org/licenses/by/4.0/), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Data Availability Statement: All relevant data are within the paper.

Funding: This work was financially supported by the Iran National Science Foundation Grant number 96001762 to Mitra Gholami. This article has been extracted from the Ph.D. thesis written by Zahra Asadgol in the Department of Environmental Health Engineering, School of Public Health at Iran University of Medical Sciences. The funders had no role in study design, data collection and analysis,

Abstract

Climate change has been described to raise outbreaks of water-born infectious diseases and increases public health concerns. This study aimed at finding out these impacts on cholera infections by using Artificial Neural Networks (ANNs) from 2021 to 2050. Daily data for cholera infection cases in Qom city, which is located in the center of Iran, were analyzed from 1998 to 2016. To determine the best lag time and combination of inputs, Gamma Test (GT) was applied. General circulation model outputs were utilized to project future climate pattern under two scenarios of Representative Concentration Pathway (RCP2.6 and RCP8.5). Statistical downscaling was done to produce high-resolution synthetic time series weather dataset. ANNs were applied for simulating the impact of climate change on cholera. The observed climate variables including maximum and minimum temperatures and precipitation were tagged as predictors in ANNs. Cholera cases were considered as the target outcome variable. Projected future (2020–2050) climate in previous step was carried out to assess future cholera incidence. A seasonal trend in cholera infection was seen. Our results elucidated that the best lag time was 21 days. According to the results of downscaling tool, future climate in the study area by 2050 will be warmer and wetter. Simulation of cholera cases indicated that there is a clear trend of increasing cholera cases under the worst scenario (RCP8.5) by the year 2050 and the highest cholera cases observe in warmer months. The precipitation was recognized as the most effective input variable by sensitivity analysis. We observed a significant correlation between low precipitation and cholera infection. There is a strong evidence to show that cholera disease is correlated with environment variables, as low precipitation and high temperatures in warmer months could provide the swifter bacterial replication. These conditions in Iran, especially in the central parts, may raise the cholera infection rates. Furthermore, ANNs is an executive tool to simulate the impact of climate change on cholera to estimate the future trend of cholera incidence for adopting protective measures in endemic areas.

Cholera. Daily cholera prevalence data from January 1998 to December 2016 were collected from the records of "The Centers for Disease Control and Prevention" at Qom University of Medical Sciences. Systematic cholera surveillance has been started working from 1998 epidemic in Qom, Iran; therefore, there was not available any cholera data for previous year. The suspected cholera cases were diagnosed by the conventional culture technique and confirmed as cholera case-counts.

Meteorological data. Meteorological data were collected from Iran Meteorological Organization (IMO) for the period of 1976 to 2016. Data were collected regarding daily minimum

Using artificial intelligence to reduce diagnostic workload without compromising detection of urinary tract infections.

Burton RJ^{1,2}, Albur M³, Eberl M^{4,5}, Cuff SM⁴.

Author information

Abstract

BACKGROUND: A substantial proportion of microbiological screening in diagnostic laboratories is due to suspected urinary tract infections (UTIs), yet approximately two thirds of urine samples typically yield negative culture results. By reducing the number of query samples to be cultured and enabling diagnostic services to concentrate on those in which there are true microbial infections, a significant improvement in efficiency of the service is possible.

METHODOLOGY: Screening process for urine samples prior to culture was modelled in a single clinical microbiology laboratory covering three hospitals and community services across Bristol and Bath, UK. Retrospective analysis of all urine microscopy, culture, and sensitivity reports over one year was used to compare two methods of classification: a heuristic model using a combination of white blood cell count and bacterial count, and a machine learning approach testing three algorithms (Random Forest, Neural Network, Extreme Gradient Boosting) whilst factoring in independent variables including demographics, historical urine culture results, and clinical details provided with the specimen.

RESULTS: A total of 212,554 urine reports were analysed. Initial findings demonstrated the potential for using machine learning algorithms, which outperformed the heuristic model in terms of relative workload reduction achieved at a classification sensitivity > 95%. Upon further analysis of classification sensitivity of subpopulations, we concluded that samples from pregnant patients and children (age 11 or younger) require independent evaluation. First the removal of pregnant patients and children from the classification process was investigated but this diminished the workload reduction achieved. The optimal solution was found to be three Extreme Gradient Boosting algorithms, trained independently for the classification of pregnant patients, children, and then all other patients. When combined, this system granted a relative workload reduction of 41% and a sensitivity of 95% for each of the stratified patient groups.

CONCLUSION: Based on the considerable time and cost savings achieved, without compromising the diagnostic performance, the heuristic model was successfully implemented in routine clinical practice in the diagnostic laboratory at Severn Pathology, Bristol. Our work shows the potential application of supervised machine learning models in improving service efficiency at a time when demand often surpasses resources of public healthcare providers.

KEYWORDS: Algorithms; Diagnostic decision making; Laboratory medicine; Machine learning; Urinary tract infection



Ευχαριστώ για την προσοχή σας

Α. Πουλιάκης
apouliak@med.uoa.gr
apou1967@gmail.com