

Yapay Zeka ve Anestezi

Artificial Intelligence and Anesthesia

Çiğdem Yıldırım Güçlü

Ankara Üniversitesi Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Ankara, Türkiye

Öz

Yapay zeka makinelere problem çözme, nesne ve kelime tanıma, dünya durumlarının çıkarımı ve karar verme gibi işlevleri yerine getirme ve akıl yürütme yeteneği veren algoritmaların çalışması olarak tanımlanmakla birlikte artık tıbbın pek çok alanında kullanılmaktadır. Anesteziyolojinin temel görevi hastanın kliniği olmakla birlikte çok fazla veri ile hareket etmesi gerekmektedir. Bu da yapay zeka ve anestezi birlikteliğini gün geçtikçe artırmaktadır.

Anahtar Kelimeler: Yapay Zeka, Anestezi, Anestezi Derinliği

Abstract

Artificial intelligence is defined as the study of algorithms that give machines the ability to reason and perform functions such as problem solving, object and word recognition, inference of world situations and decision making, and it has been shown to be usable in many fields of medicine. While the main task of anesthesiology is the patient's clinic, processing lots of data also needs to be concerned. This improves the coexistence of artificial intelligence and anesthesia day by day.

Key Words: Artificial Intelligence, Anesthesia, Depth Of Anesthesia

Giriş

Yapay zeka, makinelere problem çözme, nesne ve kelime tanıma, dünya durumlarının çıkarımı ve karar verme gibi işlevleri yerine getirme ve akıl yürütme yeteneği veren algoritmaların çalışması olarak tanımlanmaktadır (1). Yapay zekanın genellikle yalnızca bilgisayarlarla veya robotlarla ilgili olduğu düşünülse de, kökleri felsefe, psikoloji, dilbilim ve istatistik dahil olmak üzere birçok alanda bulunur.

Yapay zeka uygulamaları, radyoloji ve patolojide büyük ölçüde tanı uygulamalarından kardiyoloji ve cerrahide daha terapötik ve girişimsel uygulamalara kadar yer bulmaktadır. Tıpta yapay

zeka teknolojilerinin geliştirilmesi ve uygulanması büyümeye devam ederken, her alandaki klinisyenlerin bu teknolojilerin ne olduğunu ve daha güvenli, daha verimli, daha uygun maliyetli bakım sunmak için nasıl kullanılabileceğini anlamaları önemlidir. Anesteziyoloji açısından bakıldığında, perioperatif ve yoğun bakım, ağrı yönetimi ve ilaç farmakodinamiği dahil olmak üzere klinik bakımın birçok unsuruna değindiği için yapay zekadaki ilerlemelerden potansiyel olarak faydalanmak için iyi bir konuma sahiptir.

Yapay Zekada Makine Öğrenimi ve Öğrenme Algoritmaları

Yapay zekanın ana alt alanlarından biri olarak makine öğreniminin sınıflandırılmasıdır. Makine öğrenimi, programların

Yazışma Adresi/Address for Correspondence: Çiğdem Yıldırım Güçlü

Ankara Üniversitesi Tıp Fakültesi, Anesteziyoloji ve Reanimasyon Anabilim Dalı, Ankara, Türkiye

Tel.: +90 532 457 66 48 E-posta: drcigdemylidrm@yahoo.com.tr ORCID ID: orcid.org/0000-0002-8416-3418

Geliş Tarihi/Received: 11.11.2022 Kabul Tarihi/Accepted: 23.11.2022

©Telif Hakkı 2022 Ankara Üniversitesi Tıp Fakültesi

Ankara Üniversitesi Tıp Fakültesi Mecmuası, Galenos Yayınevi tarafından yayınlanmıştır.

Yayınlanan tüm içerik CC BY-NC-ND lisansı altındadır.



açık programlama olmadan verilerden öğrenmesine ve bunlara tepki vermesine olanak tanır. Makine öğrenimi yoluyla analiz edilebilecek veriler çok çeşitlidir ve sayısal veriler, resimler, metin ve konuşma veya sesi içerir, ancak bunlarla da sınırlı değildir. Makine öğrenimini, bir sorunu çözmek için kullanılan öğrenme algoritmasının türünü dikkate almaktır.

Denetimli öğrenme, bir duruş işaretinin tanımlanması veya bir fotoğraftaki bir kedinin tanınması gibi önceden belirlenmiş bir çıktıyı tahmin etmek için bir algoritmanın/algoritmaların eğitildiği görev odaklı bir süreçtir. Denetimli öğrenme, hem bir eğitim veri seti hem de bir test veri seti gerektirir. Eğitim veri seti, makinenin bir girdi ile istenen çıktı arasındaki ilişkileri analiz etmesine ve öğrenmesine izin verirken, test veri seti, algoritmanın performansının yeni veriler üzerinde değerlendirilmesine izin verir.

Denetimsiz öğrenme, bir veri kümesi içindeki kalıpları veya yapıyı tanımlayan algoritmaları ifade eder. Bu, hastaları, ilaçları veya diğer grupları sınıflandırmanın yeni yollarını bulmak için faydalı olabilir.

Takviyeli Öğrenme, bir algoritmanın belirli bir görevi denemesi (örneğin, bir hastaya inhalasyon anestezisi vermesi, araba sürmesi) ve sonraki hatalarından ve başarılarından ders alması istendiği süreci ifade eder (2). Takviyeli öğrenmeye biyolojik bir benzetme, edimsel koşullandırmadır; burada klasik örnek, gıda temelli ödül kullanımı yoluyla bir kolu itmeyi öğretti bir faredir.

Yapay Zekada Kullanılan Teknikler

Bulanık mantık (fuzzy logic) - Tarihi bakış

Bulanık mantık kendi başına mutlaka yapay zeka olmasa da, yapay zeka tabanlı işlevleri kolaylaştırmak için diğer çerçeveler içinde kullanılmıştır. Standart mantık yalnızca doğru (sayısal değer 1,0) ve yanlış (0,0 sayısal değer) kavramlarına izin verir, ancak bulanık mantık kısmi gerçeğe (yani, 0,0 ile 1,0 arasında sayısal bir değer) izin verir. Bulanık mantık genellikle, kesin matematiksel fonksiyonların fenomenleri doğru bir şekilde modellemediği kontrol sistemlerinde büyük ölçüde kullanılan kural tabanlı sistemleri (örneğin, eğer... o zaman sistemleri) kullanır. Örneğin, hafif kalp hızı (KH), kan basıncının; hafif kategorilere ayrılmış normalleştirilmiş değerlerine dayalı olarak hafif, orta ve şiddetli hipovolemi varlığını tahmin etmek için bulanık mantık kullanılarak hipovolemiyi saptamak için bir anestezi monitörü geliştirildi (3).

Bu tür kuralların geliştirilmesi, makinenin izlemesi için uygun bir kural kümesi belirlemek için uzman insan girdisi gerektirir ve bulanık mantık ve diğer uyarlanabilir kontrol mekanizmalarındaki erken çalışmalar, kesin olmayan bilgilere veya eksik verilere yönelik daha modern yaklaşımların keşfedilmesi için temel oluşturmaya yardımcı olur. Alanda daha

yeni araştırmalar, bulanık sistemlerin kural işlevlerini tetiklemek için verileri daha iyi değerlendirmek ve kullanmak için yapay zeka yaklaşımlarından faydalandı.

Klasik Makine Öğrenimi

Makine öğrenimi, görevlerini gerçekleştirmek için verilerdeki özellikleri kullanır. İstatistiksel analizdeki bir örneğe benzetmek için, özellikler bir lojistik regresyondaki bağımsız değişkenlere benzer olacaktır. Klasik makine öğreniminde, özellikler, karmaşık verilerin analizinde algoritmalara rehberlik etmeye yardımcı olmak için uzmanlar tarafından seçilir.

Sinir Ağları ve Derin Öğrenme

Günümüzde makine öğreniminde iş yapmak için en popüler yöntemlerden biri sinir ağlarının kullanılmasıdır. Her ağ, verileri tanımlayan özelliklerden oluşan bir girdi katmanından, girdi özellikleri üzerinde farklı matematiksel dönüşümler gerçekleştiren en az bir gizli nöron katmanından ve sonuç veren bir çıktı katmanından oluşur. Her katman arasında, girdi-çıkı haritalarına bağlı olarak farklı ağırlıklara parametrelenen nöronlar arasında çoklu bağlantılar bulunur. Bu nedenle, sinir ağları, belirli bir görevi (örneğin, görüntü tanıma, veri sınıflandırma) gerçekleştirmek için farklı makine öğrenme algoritmalarının çalışabileceği bir çerçevedir. Çeşitli veri türlerini analiz etmedeki esneklikleri göz önüne alındığında, sinir ağları, artık doğal dil işleme ve bilgisayarla görme de dahil olmak üzere yapay zekânın diğer alt alanlarına uygulanan bir tekniktir.

Bayesian metodu:

Bayes teoremi, o olayı etkileyebilecek faktörler hakkındaki önceki bilgilere veya verilere dayalı olarak bir olayın olasılığının bir tanımını sağlar. Tıp literatüründeki birçok çalışmada, ilgili çalışma popülasyonunun bir temsili olarak belirli bir veri örneğinde meydana gelen olayların sıklığına dayalı olarak hipotez testinin yapıldığı, istatistiklere sık kullanılan bir yaklaşım uygulanır. Bayes teknikleri, spam filtreleme, finansal modelleme ve klinik testlerin değerlendirilmesi gibi birçok yaygın göreve dâhil edilmiştir.

Anesteziyolojide Yapay Zeka Uygulamaları

1) Anestezi derinliği izleme

Anestezi derinliği izleme; intraoperatif farkındalık riskini azaltmaya yönelik araştırma çabaları ve anestezi sırasında elektroensefalografide (EEG) düşük bispektral indeks (BIS) ve burst baskılanmanın daha kötü sonuçlarla ilişkili olabileceğini öne süren önceki literatürler sonucunda, BIS ve EEG ölçüm yöntemleri yapay zeka alanında yer bulmuştur (4,5). Makine öğrenimi yaklaşımları, anestezi derinliğini ölçmek kullanılan EEG tabanlı sinyaller gibi karmaşık veri akışlarını analiz etmek uygundur.

Ayrıca düşük ortalama arter basıncının postoperatif mortalite ile ilişkisi nedeniyle ortalama arter basıncı ve yapay zeka arasında bağlantı kurulmuştur (6).

BIS gibi anestezi derinliği indeks parametrelerinin kullanımının popülaritesi arttıkça, BIS'ye yaklaşmak amacıyla diğer EEG parametreleri aracılığıyla EEG verilerini analiz etmek için sinir ağları ve diğer makine öğrenimi yaklaşımları kullanıldı (7).

Daha yeni makaleler, anestezi derinliğini tahmin etmek için EEG sinyallerini daha doğrudan analiz etmek için yapay zeka teknikleri ve spektral analizi kullanmıştır. Bu makaleler, mevcut her bir değişkenin faydasını en üst düzeye çıkaran tahminler oluşturmak için doğrusal ve doğrusal olmayan verileri birlikte verimli bir şekilde değerlendirebilen modeller oluşturmada yapay zeka tekniklerinin gücünü vurgulamaktadır. BIS ve EEG, tanımlanan makalelerin çoğunluğunun konusu olsa da, diğer klinik sinyaller de araştırılmıştır.

Zhang ve arkadaşları, hastalardan orta gecikmeli işitsel uyarılmış potansiyelleri kaydetmişler ve bu sinyallerin doğruluğunu değerlendirmek için, hastaların uyanık olduklarını (%96,8 doğruluk), yeterli anestezi alma (%86 doğruluk) ve genel anesteziden çıkma durumlarını değerlendirmek için sinir ağlarını kullandılar (%86,6 doğruluk). Ek olarak, KH değişkenliği gibi klinik değişkenler, Richmond ajitasyon-sedasyon skalası ile ölçülüp yaklaşık sedasyon seviyesi için araştırılmıştır (8).

2) Anestezi yönetiminin kontrolü

Anesteziye kontrol sistemleri ileri beslemeli ve geri beslemeli sistemlerin açıklamalarının yanı sıra farklı kapalı döngü sistemlerinin çok sayıda örneği ile ayrıntılı olarak tanımlanmıştır (9).

Anestezinin otomatik olarak verilmesi aynı zamanda bir makine tarafından anestezi derinliğinin belirlenmesini gerektirdiğinden, kontrol yaklaşımları klinik belirtilerin veya anestezi derinliğinin vekil belirteçlerinin ölçülmesini gerektirir. Bu nedenle, anesteziye kontrol sistemi araştırmalarının evrimi, anestezi derinliğini tahmin etmek için kullanılan çeşitli hedeflerde açıkça görülmektedir.

1990'larda, anesteziye verilmemesinin nasıl düzenleneceğini belirlemek için kontrol sistemlerine sinyal olarak kan basıncı gibi klinik işaretler ve ölçümler kullanılırdı. Anestezi derinliğini ölçmek için yeni metrikler geliştirildikçe, hedefler BIS gibi ölçüm değerlerine kaydırıldı. İlk çalışmalar, bir hedef BIS'ye ulaşmak için anestezi dağıtımını ayarlamak için tamamen ampirik yaklaşımlar kullanılarak yapılmış. BIS'nin kullanımı daha yaygın hale geldikçe, araştırmacılar, hedef ölçü olarak BIS'yi kullanarak anesteziye kontrolü elde etmek için daha karmaşık bulanık mantık sistemleri veya pekiştirmeli öğrenme kullanmaya başladılar (10).

Makine öğrenimini kullanan kontrol sistemleri ayrıca nöromusküler blokajın verilmesini otomatikleştirmek için kullanılmıştır, bu sistemler aynı zamanda nöromusküler blokajın kontrolünü daha da iyileştirmek için ilaç farmakokinetiğinin tahminini de içermektedir (11).

3) Olay öngörme

Perioperatif bakım risk tahmini için, makine öğrenimi, sinir ağları ve bulanık mantıkta çeşitli tekniklerin tümü uygulanmıştır. Örneğin, propofolün indüksiyon bolus dozunun hipnotik etkisini (BIS ile ölçüldüğü gibi) tahmin etmek için sinir ağları kullanılmış (duyarlılık %82,35, özgüllük %64,38 ve eğrinin altında kalan alan 0,755) ve değeri aştığı bulunmuştur (12).

Sinir ağları ayrıca, nöromusküler blokajdan ve indüksiyon sonrası veya spinal anestezi sırasındaki hipotansif epizodlardan iyileşme oranını tahmin etmek için kullanılırken, diğer makine öğrenimi yaklaşımları, ameliyat öncesi hasta genel durumu (yani, ASA durumu), otomatik olarak sınıflandırmak için test edilmiştir. Pediatrik cerrahide, zor laringoskopi bulguları bilinçli sedasyon sırasında solunum depresyonunu tanımlar ve optimal anestezi yöntemine karar vermede yardımcı olur.

Yoğun bakım ünitesi (YBÜ) veritabanı çalışmaları, morbiditeyi, ventilasyondan ayrılmayı, klinik bozulmayı, mortaliteyi, veya yeniden hastaneye yatışı tahmin etmek ve sepsisi saptamak için makine öğrenimi modellerini kullanmıştır.

Yoğun bakıma yönelik makine öğrenimi yaklaşımları, yalnızca büyük veri tabanı çalışmalarıyla sınırlı kalmamıştır. Sepsis tahmini için, bir makine öğrenimi uyarı sisteminin kullanımı ile (özellikler olarak altı yaşamsal belirti parametresi kullanan) bir elektronik sağlık kaydına dayalı uyarı sistemini karşılaştıran tek merkezli bir randomize kontrol çalışmada, makine öğrenimi uyarı sistemi daha iyi performans göstermiştir (13).

4) USG ile yönlendirme

Ultrason temelli prosedürlerde, ultrason görüntü sınıflandırması elde etmek için yapay zeka tekniklerinin kullanılması yaygın kullanılan bir yöntemdir. Bir çalışmada, kas, kemik ve hatta akustik gölge gibi diğer potansiyel olarak benzer görünen ultrason görüntülerini ayırt etmek için yapay zekadan faydalanılmış ve %94,5±%2,9 doğruluk oranı bulunmuştur (14).

5) Ağrı yönetimi

Ağrı yönetimi de yapay zekanın kullanılabileceği alanlardan biridir. Ben-İsrail ve ark. (15) elektif cerrahi geçiren 25 hastadan kaydedilen fotopletizmogramların ve deri iletkenlik dalga formlarının makine öğrenimi analizine dayanan bir nosisepsiyon seviyesi indeksi geliştirdi.

6) Ameliyathane lojistiği

Ameliyathane lojistiği ile ilgili faktörleri analiz etmek için örneğin; ameliyathane zamanının programlanması veya anestezi uzmanlarının hareketlerinin ve eylemlerinin izlenmesi gibi alanlarda yapay zekadan faydalanılır. Combes ve ark. (16) personel, prosedür ve personel başına ameliyathane kullanımı ve anestezi sonrası bakım ünitesi kullanımı hakkında kapsamlı bilgiler içeren bir hastane veritabanını, ekibe dayalı olarak bir ameliyatın süresini tahmin etmek için bir sinir ağı eğitmek için elektronik sağlık kaydıyla birlikte operasyon türü ve hastanın ilgili tıbbi geçmişini kullandı ve ancak, modellerinin tahmin doğruluğu hiçbir zaman %60'ı geçmedi.

Analizleri, mankenli simüle edilmiş ameliyathanelerle sınırlı olmasına rağmen, yazarlar, anestezi uzmanlarının odadaki çeşitli ekipmanlarla etkileşimine dayanarak hasta güvenliği üzerindeki potansiyel etkileri daha iyi anlamak için gerçek hastalarla benzer izleme uygulamalarının kullanılmasını önerdiler.

Uygulama Yapan Klinisyenler için Yapay Zekanın Etkileri

Bu zaman çerçevesinde derin öğrenme ve pekiştirmeli öğrenmede meydana gelen hızlı ilerlemeler, üç faktörün bir "büyük patlamasına" bağlandı: (1) büyük veri kümelerinin mevcudiyeti, (2) büyük performanslar için donanımın ilerlemesi, paralel işleme görevleri (örneğin, makine öğrenimi için grafik işleme birimlerinin kullanımı) ve (3) yapay zeka mimarileri ve algoritmaları için yeni bir gelişme dalgası.

Modern anesteziyoloji pratiği, anestezi uzmanının her hasta için birden fazla veri akışını toplamasını, analiz etmesini ve yorumlamasını gerektirir. Sağlık sistemi analogdan dijital verilere giderek daha fazla geçtiğinden, pratisyen klinisyenlerden günlük görevlerini yerine getirmek için sürekli genişleyen, veri yoğun iş akışlarına güvenmelerini bekledi. Elektronik sağlık kaydı ve anestezi bilgi yönetim sistemi, klinisyenlere sunulan arayüzlerden sadece ikisidir (17). Neyse ki, klinik değişkenlerin (örneğin hayati belirtiler, ilaç teslim zaman damgaları, vb.) otomatik olarak çıkarılmasına izin veren bilgi yönetim sistemleri, anestezi uzmanları üzerindeki dokümantasyon yükünü hafifletmiştir. Aynı zamanda, klinisyen anestezi ve kritik bakımın sağlanması için artan miktarda mevcut veriyi en iyi nasıl yorumlayacağını düşünmelidir. Yapay zeka teknolojilerinin uygulanması, artık elektronik olarak yakalanan verilerin klinik faydasını maksimize etmede klinisyene yardım etmeyi vurgulamalıdır.

Anestezi altındaki hastaların intraoperatif ve YBÜ'de izlenmesi, sedasyonu ve fizyolojik desteği güvenli bir şekilde sürdürmek için anestezi uzmanlarının, nöromüsküler blokajın ve kardiyovasküler ilaçların titre edilmesi konusundaki deneyimine dayanmaktadır. Tıp teknolojisi ilerledikçe, bir hastanın anestesisini güvenli bir şekilde yönetmek için, anestezi uzmanlarının artık birden fazla kaynağı tartması ve dikkate alması beklenmektedir.

Anestezi sırasında EEG kullanımındaki eksiklikler ve engeller, karmaşık, büyük veri kümelerini analiz etmede üstün olduğu için yapay zeka tarafından hafifletilebilir. Ayrıca, intraoperatif farkındalık nispeten nadir bir olay olduğundan, farkındalığı çevreleyen veri kıtlığı sorunlarının üstesinden gelmek için büyük veri yaklaşımlarından yararlanılabilir. Bu, gelecekteki yapay zeka sistemlerinin geliştirilmesi için uygun bir eğitim materyali kaynağı sağlayabilecek sağlam veri kümeleri oluşturmada ve düzenlemenin önemini daha da vurgulamaktadır.

Yeterli veri ile, gerçek zamanlı olay tahmini, hedef kontrollü infüzyonların otomatik ayarlanması ve bilgisayar destekli veya hatta robotik olarak otonom ultrason kılavuzlu prosedürler gibi durumlarda yapay zeka çok faydalı olabilir. Bununla birlikte, intraoperatif farkındalık gibi olayların doğru bir şekilde değerlendirilmesi, üzerinde anlaşmaya varılan ölçüm standartlarına ve ayrıca verilerin iyi bir şekilde açıklanmasına bağlı olacaktır.

Verilerin iyi bir şekilde açıklanması, tıpta yapay zekanın başarısı için kritik öneme sahiptir. Yapay zeka araştırması, teşhis ve tedavide insan performansını tahmin etmeye veya tahminde insan yeteneklerini aşmaya çalıştığından, yapay zekanın kararlarının ve tahminlerinin doğruluğunun değerlendirilmesinin, yapay zekayı karşılaştırdığımız kabul edilmiş standartlara dayandığını hatırlamalıyız. Kabul edilen bazı standartlar nesnel ve değişmezdir: ölüm tahmini, hasta ölümlerini kaydeden verilere karşı doğrulanabilir. Ancak, kabul edilen diğer standartlar yoruma tabidir. Ultrason rehberliğinde incelediğimiz çalışmalarda yapıların, yer işaretlerinin vb. tanımlanması için seçilen makine öğrenimi yönteminin eğitimi, eğitim setindeki hedefin insan tarafından etiketlenmesine (yani denetimli öğrenme) bağlıdır. Bu nedenle, yapay zeka yönteminin doğruluğunun değerlendirilmesi, aynı zamanda, güvenilir, tutarlı insan tarafından oluşturulan etiketlere sahip olmanın önemini vurgulayarak, makine etiketinin insaninkine karşılaştırılmasına da dayanır.

Ultrasonlardaki yapıların tanımlanması, acemi ve deneyimli sonografi uzmanları arasında değişebilir. Bu nedenle, bir makine öğrenimi çalışması veya cihaz geliştirme için, deneyimli sonografi uzmanlarının eğitim verilerini etiketlemesini ve bir makinenin performansını karşılaştırdığımız standart olmasını sağlamak önemli olacaktır.

BIS, uygun bir anestezi derinliğini yaklaşık olarak tahmin etmek için tek bir sayısal değer kullanılabileceğinden yapay zeka için uygun kabul edilmiş standart bir hedef sağlar; ancak, son klinik literatür, anestezi derinliğini ölçmede BIS'nin yararını sorguladığından, klinisyenler ve araştırmacılar, yapay zekaları eğitmek için güvenli, geçerli hipnoz hedef belirteçlerini belirlemek için işbirliği yapmak zorunda kalacaklar.

Yapay Zekanın Sınırlamaları ve Etik Etkileri

Yapay zeka teknolojileriyle beklenen sağlık hizmetlerinde beklenen devrim görülmezse, gerçekçi olmayan beklentiler yapay zekâ ile nihai hayal kırıklığına neden olabilir. Algoritmaların şeffaflığını artırmak için açıklanabilir yapay zeka konusunda çaba sarf edilmektedir. Açıklanabilir yapay zekânın amacı, nihai amacı şeffaflık düzeyini geliştirmek ve dolayısıyla insan güvenini ve insan güvenliğini artırmak amacıyla bulgularını (örneğin, tahminini oluşturmak için hangi özelliklere güvenmiş olabileceğini göstererek) daha kolay açıklayabilen modeller üretmektir (18).

Kaynaklar

1. Bellman R. An introduction to artificial intelligence: Can computers think? San Francisco, Boyd & Fraser Pub Co, 1978.
2. Sutton RS, Barto AG: Reinforcement Learning: An Introduction, MIT press Cambridge, 1998.
3. Baig MM, Gholamhosseini H, Kouzani A, et al. Anaesthesia monitoring using fuzzy logic. J Clin Monit Comput. 2011;25:339-347.
4. Fritz BA, Maybrier HR, Avidan MS. Intraoperative electroencephalogram suppression at lower volatile anaesthetic concentrations predicts postoperative delirium occurring in the intensive care unit. Br J Anaesth. 2018;121:241-248.
5. Kertai MD, Pal N, Palanca BJ, et al. Association of perioperative risk factors and cumulative duration of low bispectral index with intermediate-term mortality after cardiac surgery in the B-Unaware Trial. Anesthesiology. 2010;112:1116-11127.
6. Sessler DI, Sigl JC, Kelley SD, et al. Hospital stay and mortality are increased in patients having a "triple low" of low blood pressure, low bispectral index, and low minimum alveolar concentration of volatile anesthesia. Anesthesiology. 2012;116:1195-1203.
7. Ortolani O, Conti A, Di Filippo A, et al. EEG signal processing in anaesthesia. Use of a neural network technique for monitoring depth of anaesthesia. Br J Anaesth. 2002;88:644-648.
8. Nagaraj SB, Biswal S, Boyle EJ, et al. Patient-Specific Classification of ICU Sedation Levels From Heart Rate Variability. Crit Care Med. 2017;45:e683-e690.
9. Dumont GA, Ansermino JM. Closed-loop control of anesthesia: a primer for anesthesiologists. Anesth Analg. 2013;117:1130-1138.
10. Shieh JS, Kao MH, et al. Genetic fuzzy modelling and control of bispectral index (BIS) for general intravenous anaesthesia. Med Eng Phys. 2006;28:134-148.
11. Shieh JS, Fan SZ, Chang LW, et al. Hierarchical rule-based monitoring and fuzzy logic control for neuromuscular block. J Clin Monit Comput. 2000;16:583-592.
12. Lin CS, Li YC, Mok MS, et al. Neural network modeling to predict the hypnotic effect of propofol bolus induction. Proc AMIA Symp. 2002:450-3.
13. Shimabukuro DW, Barton CW, Feldman MD, et al. Effect of a machine learning-based severe sepsis prediction algorithm on patient survival and hospital length of stay: a randomised clinical trial. BMJ Open Respir Res. 2017;4:e000234.
14. Smistad E, Lovstakken L, Carneiro G, et al: Vessel Detection in Ultrasound Images Using Deep Convolutional Neural Networks, Med Image Comput Comput Assist Inter, Springer, 2016. p. 30-8.
15. Ben-Israel N, Kliger M, Zuckerman G, et al. Monitoring the nociception level: a multi-parameter approach. J Clin Monit Comput. 2013;27:659-668.
16. Combes C, Meskens N, Rivat C, et al: Using a KDD process to forecast the duration of surgery. Int J Prod Econ. 2008;112:279-293
17. Liem VGB, Hoeks SE, van Lier F, et al. What we can learn from Big Data about factors influencing perioperative outcome. Curr Opin Anaesthesiol. 2018;31:723-731.
18. Hashimoto DA, Witkowski E, Gao L, et al. Artificial Intelligence in Anesthesiology: Current Techniques, Clinical Applications, and Limitations. Anesthesiology. 2020;132:379-394.